



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA CIVIL

**DISEÑO ESTRUCTURAL DE MUROS Y COLUMNAS DE HORMIGÓN
ARMADO MEDIANTE LA IMPLEMENTACIÓN DE REDES NEURONALES
ARTIFICIALES**

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA INGENIERÍA,
MENCIÓN INGENIERÍA ESTRUCTURAL, SÍSMICA Y GEOTÉCNICA

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL

CHRISTIAN ENRIQUE SOLEDISPA CORONEL

PROFESOR GUÍA:
LEONARDO MASSONE SÁNCHEZ

MIEMBROS DE LA COMISIÓN:
FABIÁN ROJAS BARRALES
DIEGO LÓPEZ GARCÍA

SANTIAGO DE CHILE
2023

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE MAGÍSTER EN CIENCIAS
DE LA INGENIERÍA
POR: CHRISTIAN ENRIQUE SOLEDISPA CORONEL
FECHA: 2023
PROF. GUÍA: LEONARDO MASSONE SÁNCHEZ

DISEÑO ESTRUCTURAL DE MUROS Y COLUMNAS DE HORMIGÓN ARMADO MEDIANTE LA IMPLEMENTACIÓN DE REDES NEURONALES ARTIFICIALES

La etapa de diseño, para proyectos constructivos de edificaciones habitacionales de hormigón armado, requiere de una constante interacción entre las oficinas de arquitectura y las de cálculo con el fin de mejorar la distribución de espacios habitables cumpliendo con los requerimientos estructurales normativos. Varios estudios aprovechan la amplia cantidad de datos generados por el traspaso de información entre ambas oficinas para crear modelos de aprendizaje automático, que permiten agilizar los procesos de diseño y la toma de decisiones. Una reciente investigación, propone un modelo basado en redes neuronales artificiales (ANN) capaz de predecir el largo y espesor de los rectángulos que forman los muros en el plano de arquitectura para el plano final de ingeniería. La limitación del modelo, es que no predice muros que no fueron considerados dentro del diseño arquitectónico inicial. Se resolvió el problema, creando un modelo basado en redes neuronales convolucionales (CNN), sin embargo, para que las predicciones de muros obtuvieran resultados aceptables, se requería una base de datos 137 veces más grande que la del primer modelo y varios filtros para el ensamblaje de los resultados gráficos finales que generaban un gran costo computacional y entregaba una imagen borrosa de la predicción. En consecuencia a lo anterior, esta tesis plantea una nueva metodología para proponer muros y columnas que no fueron considerados en el diseño arquitectónico, pero necesarios para la configuración estructural, a través de un modelo ANN. La primera etapa de este estudio consistió en crear una base de datos a partir de los planos de arquitectura e ingeniería de 165 edificios construidos en Chile, mediante una función Mapeo, capaz de crear vecindades dentro los planos y extraer características geométricas y topológicas de los muros dentro de ellas. Como segunda etapa, se entrenó un modelo ANN para la predicción de los segmentos de muros no considerados en arquitectura, haciendo uso de un vector de características que plantea la necesidad de muros según la relación entre las vecindades creada de los planos de arquitectura e ingeniería para condiciones como el espesor, la conectividad entre muros, la distancia entre elementos, zona sísmica, tipo de suelo de fundación, y otros parámetros de ingeniería, logrando resultados destacados en cuanto al coeficiente de determinación (R^2) de 0,954 para el largo, 0.93 para el espesor, 0.94 para el ángulo y 0.967 para su posición (x, y). La tercera etapa, consta de un análisis de normalización entre las predicciones y los rectángulos reales de ingeniería que no fueron considerados por arquitectura, obteniendo que el 80 % de los pisos, mantiene una relación de área de $\pm 1 m^2$. Finalmente, con un plano de arquitectura, este modelo puede proponer distintas soluciones a la necesidad de muros nuevos para el plano estructural, logrando reducir la cantidad de datos usados para el entrenamiento y la validación a un 8 % en comparación al modelo que utiliza CNN y la solución gráfica se logra de una manera más eficiente y con valores fijos para las dimensiones de rectángulos predichos.

*Para mis padres,
gracias por nunca perder la fé.*

Agradecimientos

Quiero expresar mi gratitud a Dios por darme la fuerza y la perseverancia necesarias para completar esta tesis. Sin Su amor y guía, no habría sido posible alcanzar este logro.

Agradecer a mis padres, quienes han sido un soporte en mi vida y en mi educación. Su apoyo incondicional y amor han sido la razón de mi éxito y logros. Su confianza en mí y su constante motivación han sido la fuente de mi fuerza en momentos difíciles. Su sacrificio y esfuerzo han sido una inspiración constante para mí. No tengo palabras suficientes para expresar cuánto significan para mí. Los amo con todo mi corazón y siempre estaré agradecido por todo lo que han hecho por mí.

Un agradecimiento especial a Vicente, mi primer amigo en la universidad, desde que nos conocimos y desde entonces hemos tenido muchos momentos inolvidables. Siempre ha estado ahí para mí, sin juzgarme ni criticarme, simplemente escuchándome y apoyándome en todo lo que necesito. Su amistad es una de las cosas más valiosas que tengo en mi vida. Nunca podré expresar lo agradecido que estoy por su amistad y apoyo. Además, junto con Karen, en época de pandemia, la compañía que me brindaron hicieron una gran diferencia en mi vida. Con videollamadas, juegos y mensajes, nos mantuvimos conectados y apoyándonos mutuamente y en momentos de incertidumbre, su optimismo y buen humor me recordaron que siempre hay algo por lo cual estar agradecido, no podría haber llegado hasta aquí sin ellos.

Quiero expresar mi más sincero agradecimiento a la familia Rivera, a la tía Stela, la tía Chari, tía Gladys, Justin, Erik, Paul, Isabelita, Juanito, Yomara y John, quienes me han brindado un hogar y me han acogido como uno más de su familia desde que llegué a Chile. Su amistad y comprensión han significado mucho para mí. Gracias por su apoyo incondicional, su tiempo, sus consejos, las comidas, las fiestas y todas las veces que me han ayudado. Han sido un verdadero pilar para mí en este país vecino. Les estoy profundamente agradecido por todo lo que han hecho por mí.

Quisiera agradecer a un grupo de amigos que han sido una parte fundamental de mi vida universitaria, y que son casi como familia para mí. Pauli, Boche, Mauri, Tomi, Pipin, Ale, Caco, Nico, Dani, Leo y ambos Richis, han sido un constante apoyo en mi vida universitaria. Las risas, los juegos, las horas de estudio y los carretes nunca faltaron con ellos cerca. También a Jarita y a Nat, que jugamos hartos partidos de vóley en el grupo organizado.

Quiero brindarle mi agradecimiento a un amigo muy importante, Aaron. Quien ha sido un amigo incondicional durante los viajes, partidos de voley, salidas a comer, idas al cine y todo tipo de juegos. Gracias a tu compañía, he pasado momentos inolvidables y he creado recuerdos que atesoraré para siempre. Has sido un hermano para mí y sé que siempre podré contar

contigo. Muchas gracias, Aaron, por estar siempre presente y por ser una persona tan especial.

Quiero agradecer a tres amigos muy especiales, Pablo Arancibia, Pablo Pizarro y Sebastián Astudillo, quienes me han brindado su apoyo incondicional y me ayudaron mucho para la parte de programación de mi tesis. Gracias a su ayuda, dedicación y paciencia.. mucha paciencia, he logrado avanzar en este proyecto y superar cada obstáculo. Además, Seba es uno de mis amigos más cercanos, siempre nos andamos riendo. Hemos compartido buenos momentos juntos, contándonos anécdotas chistosas, jugando voley, saliendo a comer o comprando ropa. Estoy muy agradecido por su amistad y espero que sigamos siendo amigos.

Agradecer a Francho, que me apoyó en las instancias finales de este trabajo. Tu empatía ayudó mucho ordenando y cuidando las plantitas que crecían en el depa, enseñándome a tener y cuidar un espacio verde e inspirándome para poder terminar con este proyecto. Gracias por apoyar varias de mis ideas locas, por reírte de mis chistes y escucharme cuando necesité desahogarme. Mi mayor confidente en este tiempo, espero seguir contando con tu apoyo y el de Sammy en el futuro.

Quiero agradecer profundamente a mi psicóloga Camila por su invaluable ayuda durante los momentos más difíciles de mi vida. Gracias a su profesionalismo, dedicación y paciencia, he logrado superar obstáculos que pensé que nunca podría superar. Me resulta difícil encontrar las palabras exactas para expresar lo profundamente agradecido que me siento por su incondicional apoyo y el tiempo dedicado hacia mí. ¡Muchas gracias, Camila, por ser una psicóloga tan excepcional y una persona tan maravillosa!

Por último, pero no menos importante, quisiera expresar mi sincero agradecimiento a mi profesor guía, Leonardo Massone. Me siento afortunado de haber contado con su guía y apoyo durante este proceso. Su mentoría ha sido una pieza clave en este logro académico, y estoy agradecido por su contribución a mi formación profesional. Espero que esta tesis sea una muestra de mi gratitud hacia él y que esta amistad continúe en el futuro.

Tabla de Contenido

1. Introducción	1
1.1. Motivación	1
1.2. Hipótesis	7
1.3. Objetivos	7
1.3.1. Objetivo Principal	7
1.3.2. Objetivos Específicos	7
1.4. Alcance por capítulos	7
2. Asociación de Rectángulos	9
2.1. Antecedentes	9
2.2. Función de Asociación	11
2.2.1. Asociación Modificada	13
2.2.2. Resultados	15
3. Construcción de la Base de Datos	18
3.1. Mapeo de rectángulos	18
3.2. Vector de entrada y de salida	24
4. Modelo ANN	31
4.1. Formulación del Modelo	31
4.2. Resultados	32
4.2.1. Resultados Paramétricos	35
4.2.2. Ejemplo de aplicación	39
5. Análisis de Resultados	41
6. Conclusiones	54
Bibliografía	56

Índice de Tablas

2.1.	Datos asociados dentro de los set de datos.	15
3.1.	Cantidad de rectángulos en arquitectura capturados con distintos radios de mapeo.	23
3.2.	Cantidad de rectángulos No Asociados en ingeniería capturados con distintos radios de mapeo.	24
3.3.	Valor n para vector de entrada y de salida según radio de mapeo.	25
4.1.	Resultados del modelo de regresión para los datos considerando el vector de salida para el set de datos C	35
4.2.	Resumen de los resultados de R^2	38

Índice de Ilustraciones

1.1.	Plano arquitectónico de un edificio típico chileno.	2
1.2.	Esquema de la red neuronal profunda ANN para predecir espesor y largo de muros (Pizarro y Massone, 2021).	3
1.3.	Rectángulos de arquitectura vs. Rectángulos de ingeniería obtenidos del modelo ANN de Pizarro (Pizarro, 2021).	3
1.4.	Generación de imagen alrededor de un rectángulo en un plano (Pizarro et al., 2021).	4
1.5.	Modelo de regresión de imágenes UNET-XY (Pizarro et al., 2021).	4
1.6.	Marco del diseño estructural automatizado StructGAN (Liao, Lu, Huang, Zheng y Lin, 2021).	5
1.7.	Marco del diseño estructural automatizado StructGAN-PHY (Lu et al., 2021).	6
2.1.	Visualización de la geometría y topología de varios muros ejemplos utilizando la aplicación web (Pizarro, 2021).	10
2.2.	Organización de los objetos de discretización estructural (Pizarro, 2021).	11
2.3.	Función de normalización $\chi(x)$ propuesta en el cálculo de la puntuación de <i>Asociación</i>	12
2.4.	Planos: Arquitectura vs. Ingeniería. Rectángulos azules y rojos rellenos: Asociados. Rectángulos azules y rojos vacíos: No Asociados. Rectángulos dentro de los círculos: Problema con la asociación.	14
2.5.	Ejemplo rectángulo corto: largo y espesor menores a 65 [cm].	15
2.6.	Ejemplo 1: Antes y después de la modificación de Asociación.	16
2.7.	Ejemplo 2: Antes y después de la modificación de Asociación.	16
2.8.	Histograma de: largo, espesor, área y ángulos para los rectángulos No Asociados.	17
3.1.	Ejemplo: Vecindad creada con un mapeo de 7 [m] radiales.	19
3.2.	<i>Mapeo</i> recorriendo los rectángulos asociados.	20
3.3.	Mapeo capturando los rectángulos para una vecindad de un rectángulo de arquitectura asociado.	21
3.4.	Mapeo capturando los rectángulos no asociados para una vecindad de un rectángulo de ingeniería asociado.	21
3.5.	Representación de alcance de <i>Mapeo</i> para radios de 6 a 30 [m].	22
3.6.	Distribución de rectángulos Asociados para 15 y 30 [m] de radio.	23
3.7.	Distribución de rectángulos No Asociados para 15 y 30 [m] de radio.	24
3.8.	Arreglo de datos para el vector de entrada.	26
3.9.	Arreglo de datos para el vector de salida.	27
3.10.	Histograma de las características del vector de entrada usando el Set de Datos C.	28
3.11.	Comparación del área de los rectángulos en arquitectura capturados por mapeos de 15 y 30 [m] de radios.	29

3.12.	Comparación del área de los rectángulos No Asociados en ingeniería capturados por mapeos de 15 y 30 [m] de radios.	30
4.1.	Esquema del Modelo ANN que predice rectángulos para planos de ingeniería. .	32
4.2.	Curvas de pérdida del modelo (Entrenamiento y Validación).	33
4.3.	Histograma de las características dentro del vector de salida.	33
4.4.	Correlación del modelo para el set de datos C.	34
4.5.	Matriz de confusión del Identificador para el set de datos C.	35
4.6.	Resultados de R^2 usando distintos hiperparametros para mapeos de 6 y 8 [m] radiales.	36
4.7.	Resultados de R^2 usando distintos radios de mapeos.	36
4.8.	Resultados de R^2 según el número de rectángulos No Asociados dentro del vector de salida y radio de mapeo de 30 [m].	37
4.9.	Variación del R^2 de las posiciones x e y según el número de rectángulos No Asociados dentro del vector de salida.	37
4.10.	Plano de arquitectura usado para el ejemplo de aplicación.	39
4.11.	Plano de ingeniería usado para el ejemplo de aplicación con las predicciones correspondientes del modelo ANN.	40
5.1.	Esquema de un plano de ingeniería con los rectángulos No Asociados y sus predicciones: a) Modelo con radio de mapeo de 15 [m]. b) Modelo con radio de mapeo de 30 [m].	41
5.2.	Esquema de un plano de ingeniería con los rectángulos No Asociados y las predicciones asociadas y no asociadas.	42
5.3.	Resultados de la normalización del largo para modelos que usan 15 y 30 [m] radiales en el mapeo.	43
5.4.	Resultados de la normalización del espesor para modelos que usan 15 y 30 [m] radiales en el mapeo.	43
5.5.	Resultados de la normalización del ángulo para modelos que usan 15 y 30 [m] radiales en el mapeo.	44
5.6.	Resultados de la normalización de la posición x para modelos que usan 15 y 30 [m] radiales en el mapeo.	45
5.7.	Resultados de la normalización de la posición y para modelos que usan 15 y 30 [m] radiales en el mapeo.	45
5.8.	Esquema de un plano de ingeniería con los rectángulos No Asociados, las predicciones asociadas y no asociadas; y el promedio de las predicciones asociadas.	46
5.9.	Ejemplo: Rectángulo Predicho Promedio.	46
5.10.	Resultados de la normalización del largo promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.	47
5.11.	Resultados de la normalización del espesor promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.	47
5.12.	Resultados de la normalización del ángulo promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.	48
5.13.	Resultados de la normalización de la distancia x promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.	48
5.14.	Resultados de la normalización de la posición y promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.	49
5.15.	Normalización de áreas para modelos de 15 y 30 [m] radiales.	49
5.16.	Ejemplo: Predicciones para pisos con normalización de área entre 0 y 0.25. . .	50

5.17.	Ejemplo: Predicciones para pisos con normalización de área entre 0.25 y 0.75. .	51
5.18.	Ejemplo: Predicciones para pisos con normalización de área mayores a 0.75. . .	52
5.19.	Ejemplo: a) Planos de ingeniería con las perdiciones superpuestas (rectángulos verdes). b) Planos de ingeniería con la clusterización de las perdiciones superpuestas (rectángulos turquesa).	53

Capítulo 1

Introducción

Dentro de la ingeniería, el principio de la Inteligencia Artificial (IA) tiene como objetivo aprender la relación que existe dentro un conjunto de datos de entrada y salida, incluso si se desconoce la interdependencia o si el fenómeno físico es difícil de interpretar [1]. El aprendizaje automático (Machine Learning) es una disciplina del campo de la Inteligencia Artificial que, a través de algoritmos, dota a los computadores la capacidad de identificar patrones en datos masivos y elaborar predicciones (análisis predictivo). Este aprendizaje permite a los ordenadores realizar tareas específicas de forma autónoma, es decir, sin necesidad de ser programados. El término se utilizó por primera vez en 1959, sin embargo, ha ganado relevancia en los últimos años debido al aumento de la capacidad de computación y al boom de los datos. Las técnicas de aprendizaje automático son, de hecho, una parte fundamental del Big Data.

Los algoritmos de Machine Learning se pueden clasificar en dos categorías principales: aprendizaje no supervisado y aprendizaje supervisado [2]. Los algoritmos de aprendizaje no supervisados aprenden identificando las relaciones en las características de un conjunto de datos, como separar los datos en grupos con un cierto grado de similitud o aplicar técnicas de reducción de dimensionalidad. Por otro lado, los algoritmos aprendizaje supervisado requieren la separación de los datos en los conjuntos de datos de entrenamiento y validación [3]. Los avances en el campo de la IA han tenido una fuerte influencia en las diferentes áreas de la Ingeniería Civil. Los nuevos métodos y algoritmos que están apareciendo permiten a los ingenieros usar estas nuevas técnicas de maneras diferentes y sobre problemas de diversa naturaleza [4]. El propósito de la investigación propuesta consiste en aplicar estas nuevas tecnologías, para ayudar a los profesionales que se involucran en la fase de diseño de los planos estructurales de edificios de hormigón.

1.1. Motivación

El diseño de sistemas de muros que se utiliza en Chile para la mayoría de edificios habitacionales está compuesto por varios elementos de sección transversales o también llamados muros complejos [5, 6] (ver Figura 1.1). Se emplea este diseño para que las estructuras sean lo suficientemente resistentes para soportar la alta demanda sísmica que existe en los suelos chilenos. El proceso de la configuración final de un plano de ingeniería se basa en una ardua interacción entre las oficinas de arquitectura con las oficinas de cálculo donde el pri-

mer enfoque es el definir el espesor y largo de muros y columnas, replantear la ubicación de estos y en algunos casos agregar nuevos muros [7]. Con el fin de cumplir con los requisitos arquitectónicos y estructurales, este proceso interactivo puede llegar a durar un tiempo considerable.

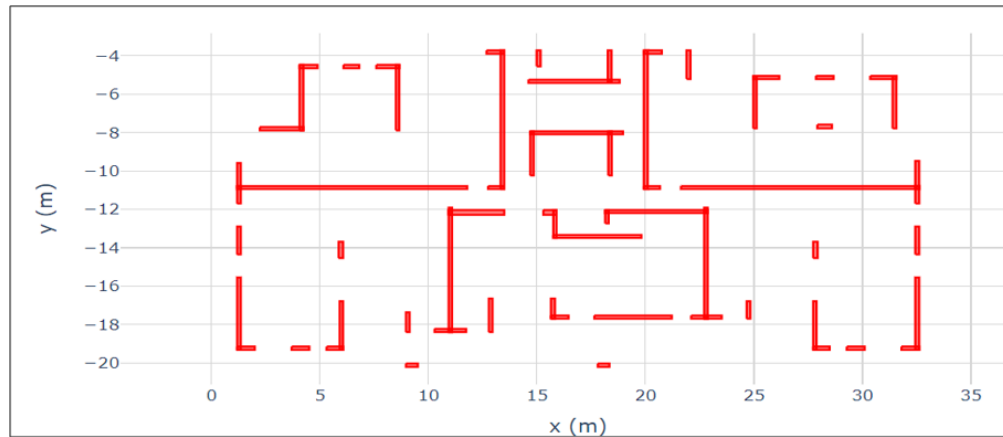


Figura 1.1: Plano arquitectónico de un edificio típico chileno.

De manera de reducir el tiempo en que ambas oficinas establecen el diseño final para este tipo de proyectos, Pizarro et al. [8, 9] introduce un nuevo enfoque de modelos predictivos aplicando algoritmos de Redes Neuronales Artificiales (ANN) y Redes Neuronales Convolucionales (CNN) para determinar la configuración estructural de un edificio habitacional basado en los planos arquitectónicos. Las Redes Neuronales Artificiales hacen referencia a un algoritmo basado en el comportamiento del cerebro humano y se encuentran entre los algoritmos de aprendizaje supervisado más comunes, posee interconexiones entre neuronas que componen una capa y en las diferentes capas de cada sistema formando una red. En biología se define como sinapsis neuronal a la zona de transmisión de impulsos nerviosos eléctricos entre dos células nerviosas (neuronas). Un sistema ejemplar tiene tres capas. La primera o vector de entrada, tiene neuronas que envían datos a través de las sinapsis (poseen un valor numérico denominado peso) a la segunda capa de neuronas, y luego a través de más sinapsis a la última capa de neuronas también llamado vector de salida. Las neuronas reciben la salida de neuronas ponderada linealmente de la capa anterior, aplican una función de activación no lineal y, posteriormente, alimentan a las neuronas conectadas en la capa siguiente. Los pesos de las conexiones se actualizan en el proceso de entrenamiento de la red para minimizar el error de predicción [10, 11]. Por otro lado, las Redes Neuronales Convolucionales son un modelo de inteligencia artificial, se las puede entrenar para que realicen tareas más complejas dado que reciben como entrada imágenes, y aprenden utilizando filtros que detectan rasgos únicos que convolucionan varias veces aprendiendo a clasificar correctamente las imágenes.

Su modelo ANN consiste en la predicción de largo y espesor para los rectángulos que forman el plano de arquitectura en el plano final de ingeniería. Para esto creó una función de asociación que puntuaba características geométricas y topológicas de los rectángulos de arquitectura e ingeniería para relacionarlos entre si e identificar si un rectángulo de arquitectura pertenece o no a un rectángulo dentro de plano de ingeniería. Identificados los rectángulos asociados entre ambos planos, se construye la base de datos, un vector de entrada conformado por 30 características por rectángulo de arquitectura y un vector de salida de con el largo y espesor para el rectángulo asociado de ingeniería. Este modelo entregó un índice de

precisión (R^2) para el largo y el espesor de 0.995 y 0.994 respectivamente. La Figura 1.2 muestra la arquitectura del modelo ANN, está formada por una capa de entrada, 6 capas ocultas completamente conectadas, con 1024 neuronas cada una, y una capa de salida con los valores para predecir el grosor y la longitud de los rectángulos.




Figura 1.2: Esquema de la red neuronal profunda ANN para predecir espesor y largo de muros (Pizarro y Massone, 2021).

La Figura 1.3 muestra un ejemplo de los resultados del modelo para los rectángulos del plano de arquitectura (azules) y los rectángulos dentro del plano de ingeniería (rojos) obtenidos del modelo.

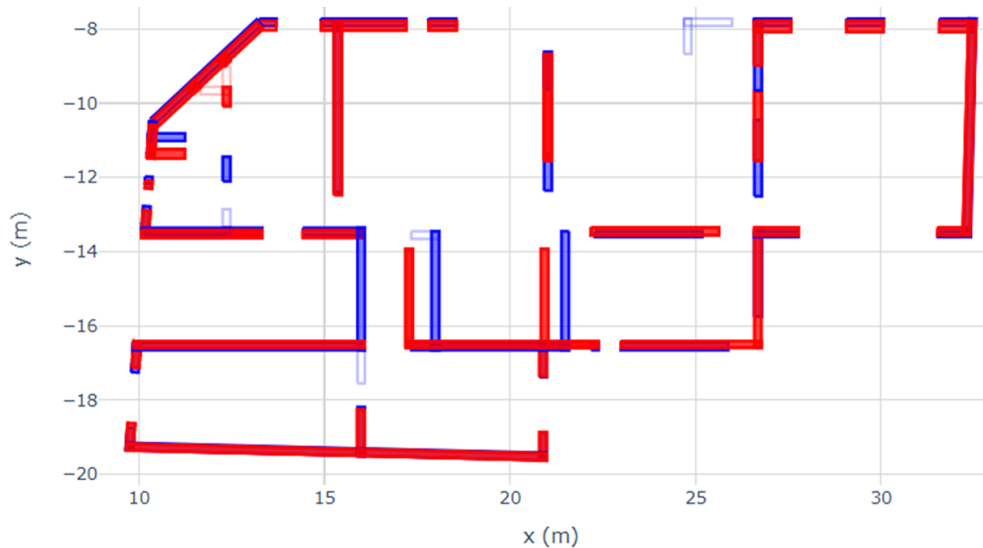


Figura 1.3: Rectángulos de arquitectura vs. Rectángulos de ingeniería obtenidos del modelo ANN de Pizarro (Pizarro, 2021).

El segundo modelo, UNET-XY, usa redes neuronales convolucionales que permiten capturar el ADN del diseño de edificios residenciales con muros de corte en Chile combinando dos predicciones independientes. La primera es la misma que utilizó en modelo ANN donde considera 30 características por rectángulo de arquitectura y la segunda, ocupa el rectángulo de arquitectura como centro para crear una imagen de 10x10 metros con una resolución de 64x64 píxeles (Figura 1.4), usando en total de 4126 datos por imagen. La arquitectura del

modelo se presenta en la Figura 1.5. Como resultado el modelo creaba un plano con una matriz de probabilidad en píxeles, se filtraban los píxeles con mayor probabilidad, creando el plano final de ingeniería. Sin embargo, la cantidad de datos para generar que el algoritmo entregue resultados eficientes era muy grande, además, cerca del 93 al 95 % eran información innecesaria ya que se trataban de píxeles blanco [9].

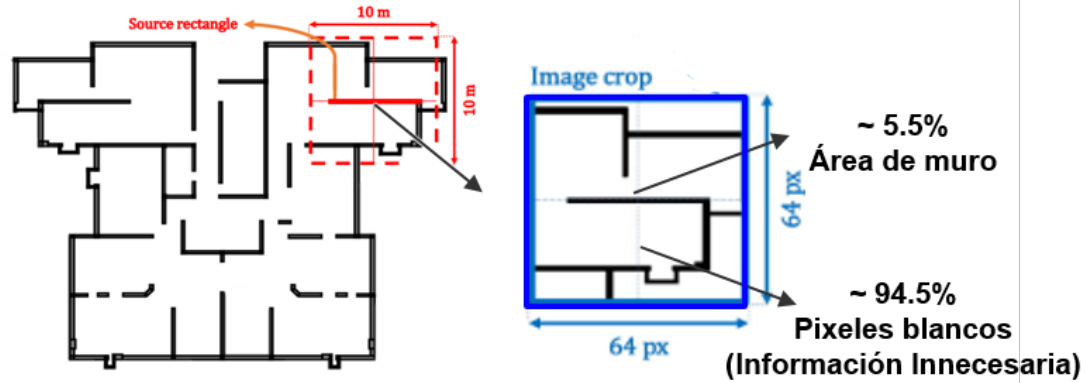


Figura 1.4: Generación de imagen alrededor de un rectángulo en un plano (Pizarro et al., 2021).

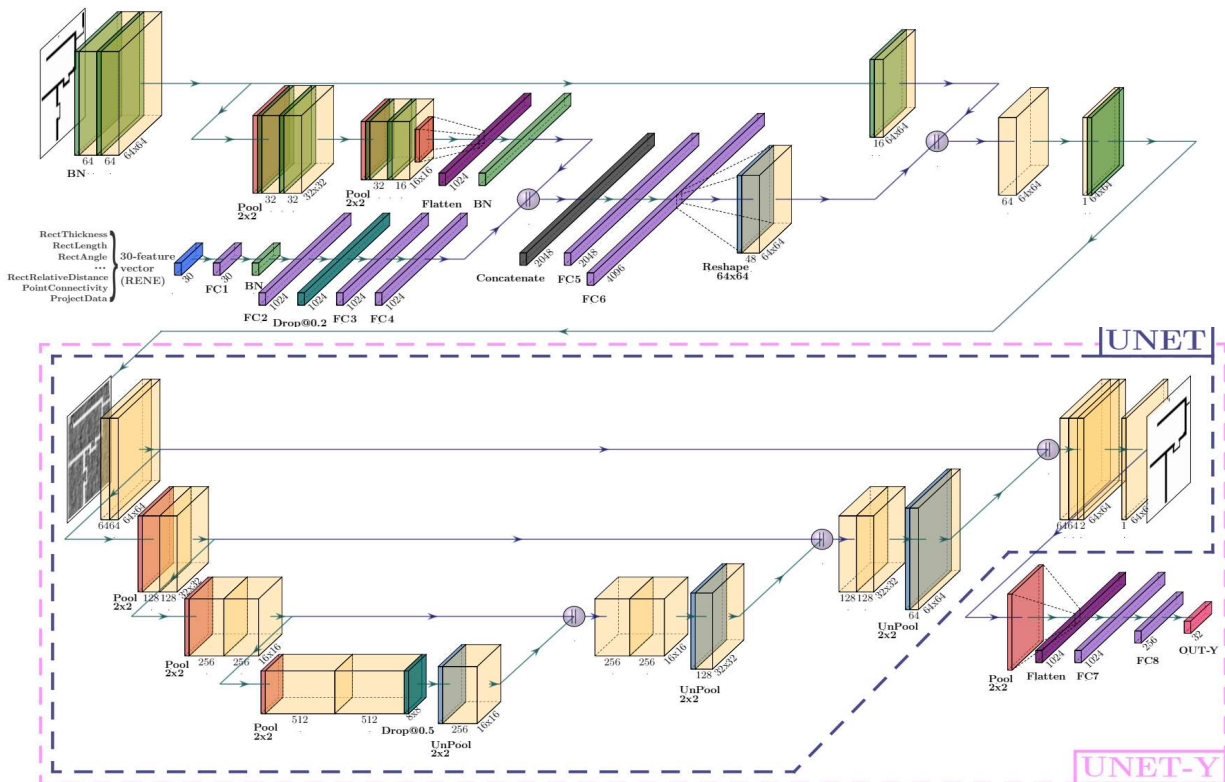


Figura 1.5: Modelo de regresión de imágenes UNET-XY (Pizarro et al., 2021).

Liao et al. [12] y Lu et al. [13], teniendo en cuenta la aplicación cada vez más amplia de

los sistemas de muros de corte en edificios de gran altura y previendo el beneficio masivo del diseño estructural automatizado, proponen modelos de automatización de diseño de muros de corte basado en una Red Generativa Adversaria (GAN) y una Red Generativa Adversaria con un Discriminador Físico, una metodología que forma parte de la rama de la inteligencia artificial. Las arquitecturas son mostradas en las Figuras 1.6 y 1.7. El propósito de estos modelos es aprender de los documentos de diseño de muros de corte existentes y luego realizar el diseño estructural de manera inteligente y rápida.

Desarrollaron una base de datos de documentos representativos de diseño arquitectónico y estructural, similar a lo que propuso Pizarro et al. [9]. Prepararon conjuntos de datos mediante abstracción, semántica, clasificación y parametrización en términos de altura del edificio y categoría de diseño sísmico. El modelo GAN mejoró su competencia en el diseño de muros de corte a través del entrenamiento adversario respaldado por datos y análisis hiperparamétrico. El desempeño del modelo GAN capacitado se evaluó contra las métricas basadas en la matriz de confusión y el enfoque de intersección sobre unión. Finalmente, se llevaron a cabo estudios de caso para evaluar la aplicabilidad, efectividad y adecuación del innovador método de diseño estructural basado en GAN.

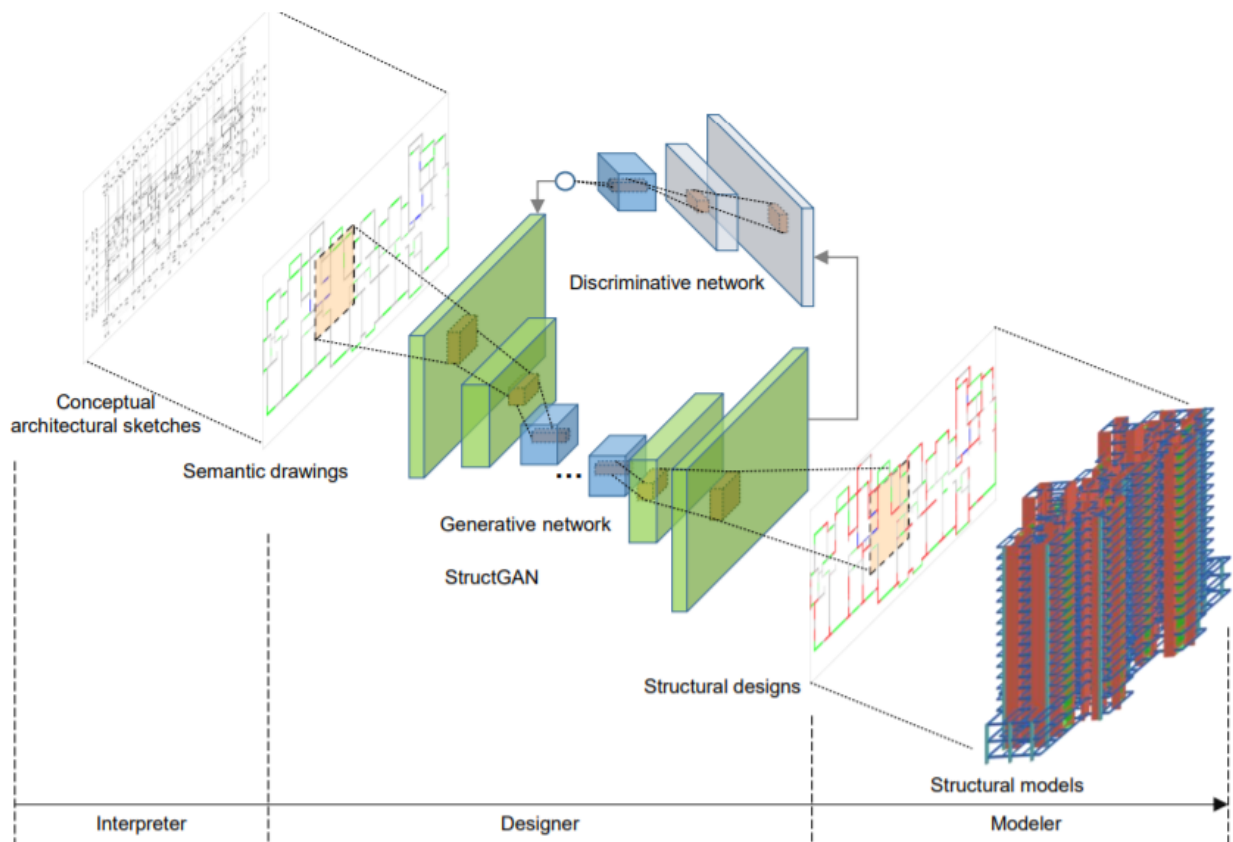


Figura 1.6: Marco del diseño estructural automatizado StructGAN (Liao, Lu, Huang, Zheng y Lin, 2021).

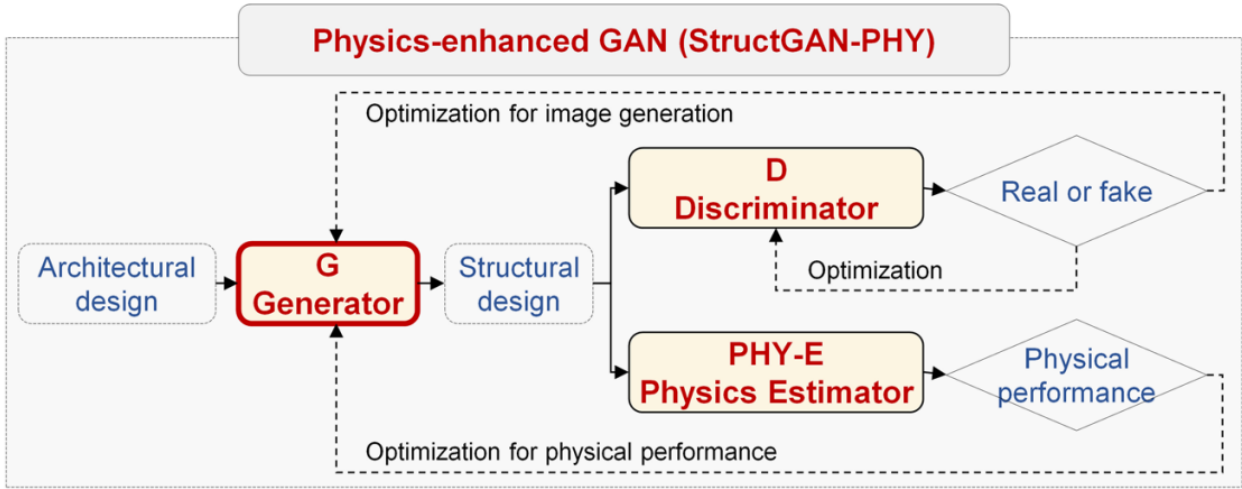


Figura 1.7: Marco del diseño estructural automatizado StructGAN-PHY (Lu et al., 2021).

Los algoritmos de Machine Learning han sido utilizados en distintas aplicaciones dentro de la ingeniería estructural [14, 15]. Los estudios más recientes se centran en el diseño de elementos estructurales, Cheng Guozhong et al. [16] aplica un método inteligente de diseño de muros de corte mediante teoría de grafos, análisis Procrustes y un algoritmo de detección de bordes, que genera el reconocimiento y trazado de los muros en edificios de gran altura. Mediante el uso de modelos GAN, Fei et al. [17] realiza el diseño esquemático de las estructuras de marcos con tubos siendo 150 veces que un ingeniero competente; Pengju Zhao et al. [18] genera un diseño inteligente para vigas y losas, además, utiliza un modelo que utiliza textos dentro de los bocetos arquitectónicos para producir los diseños de muros corte [19]. Existen modelos para diseño estructural de edificios que tienen la intención de reducir el impacto al medio ambiente [20], es así como Kanyilmaz et al. [21] propone una herramienta de algoritmo genético que analiza una amplia gama de materiales seguros, económicos y con bajo contenido de CO₂, para el diseño conceptual de edificios. Combinando algoritmos de aprendizaje automático con la ingeniería estructural, se espera contribuir con mayor creatividad para el diseño de proyectos típicos ampliando la variedad en diseños y poseer una retroalimentación de los mismos en tiempo real [22–24].

Es por lo anterior que siguiendo una metodología alterna a lo desarrollado por Pizarro y Massone [8], se investigará el uso de ANN como un modelo predictivo de rectángulos nuevos en el plano de ingeniería, y así, utilizar una cantidad de datos relativamente menor a la del modelo CNN, pero con un nivel de certeza similar o mayor. Al implementar ANN para proponer los elementos nuevos se espera abarcar como entrada de forma numérica las características geométricas y topológicas para los muros dentro de una imagen con el fin de extraer solo los datos relevantes de los diseños arquitectónicos e ingenieriles. Cada rectángulo dentro de un plano, será el centro de una vecindad circular con que posee un radio fijo, y de la cual, se recuperarán características los muros que estén dentro. A diferencia del modelo CNN, se pueda concentrar la información de los muros con parámetros numéricos exactos y no datos pixelados de imágenes. Se procesará esta información en arreglos que generarán la base de datos para la fase de entrenamiento y de validación del modelo. Se crearán métricas para definir la precisión que existe en los rectángulos que forman los planos de ingeniería reales de cada proyecto y las predicciones del modelo. Se expondrá el análisis de los resultados que

se obtuvieron de las métricas y algunas representaciones gráficas de lo obtenido del modelo. Por último, se presentarán las conclusiones pertinentes del presente estudio.

1.2. Hipótesis

Con la implementación de un modelo ANN, se pueden predecir los muros de planos de ingeniería que no fueron considerados dentro del diseño arquitectónico para edificios residenciales chilenos.

1.3. Objetivos

1.3.1. Objetivo Principal

Desarrollar un programa computacional que pueda proponer muros estructurales no considerados en el diseño arquitectónico edificios habitacionales chilenos, impulsado por un modelo ANN.

1.3.2. Objetivos Específicos

1. Rectificar la función que asocia los elementos dentro del plano de arquitectura con los de ingeniería.
2. Construir una base de datos de edificios que considere las propiedades geométricas y topológicas de cada plano de planta, utilizada para el entrenamiento y evaluación de modelos de aprendizaje automático.
3. Analizar y comparar los resultados del modelo predictivo con los planos reales para todos los proyectos dentro de la base de datos.
4. Evaluar y caracterizar la arquitectura del modelo ANN, sus propiedades y el flujo de datos para optimizar el proceso de predicción.
5. Acoplar los nuevos elementos en los planos de ingeniería y discutir los resultados con el modelo alterno que usa CNN.

1.4. Alcance por capítulos

Capítulo 2: Función de Asociación

En este capítulo se analizarán los antecedentes de la función que asocia los elementos de arquitectura con los de ingeniería. Se explican las modificaciones hechas a la función que asocia los rectángulos de arquitectura con los de ingeniería, de manera que, existan más elementos asociados dentro de la base de datos.

Capítulo 3: Construcción de la Base de Datos

Se explicará la metodología para formar la base de datos que se utilizará en el modelo ANN.

Capítulo 4: Modelo ANN

En el cuarto capítulo se describe el uso de Machine Learning aplicado. La explicación del modelo, características de la arquitectura y los distintos resultados que se obtuvieron a raíz de las diferentes manipulaciones de la base de datos.

Capítulo 5: Análisis de Resultados

El quinto capítulo comprende el análisis de los resultados obtenidos de las predicciones del modelo y la parametrización de los datos que se colocarán en los planos finales de ingeniería.

Capítulo 6: Conclusiones

Finalmente, se mostrarán las conclusiones de la investigación que tuvo esta tesis y se hará una discusión entre el modelo ocupado y el modelo que utiliza CNN.

Capítulo 2

Asociación de Rectángulos

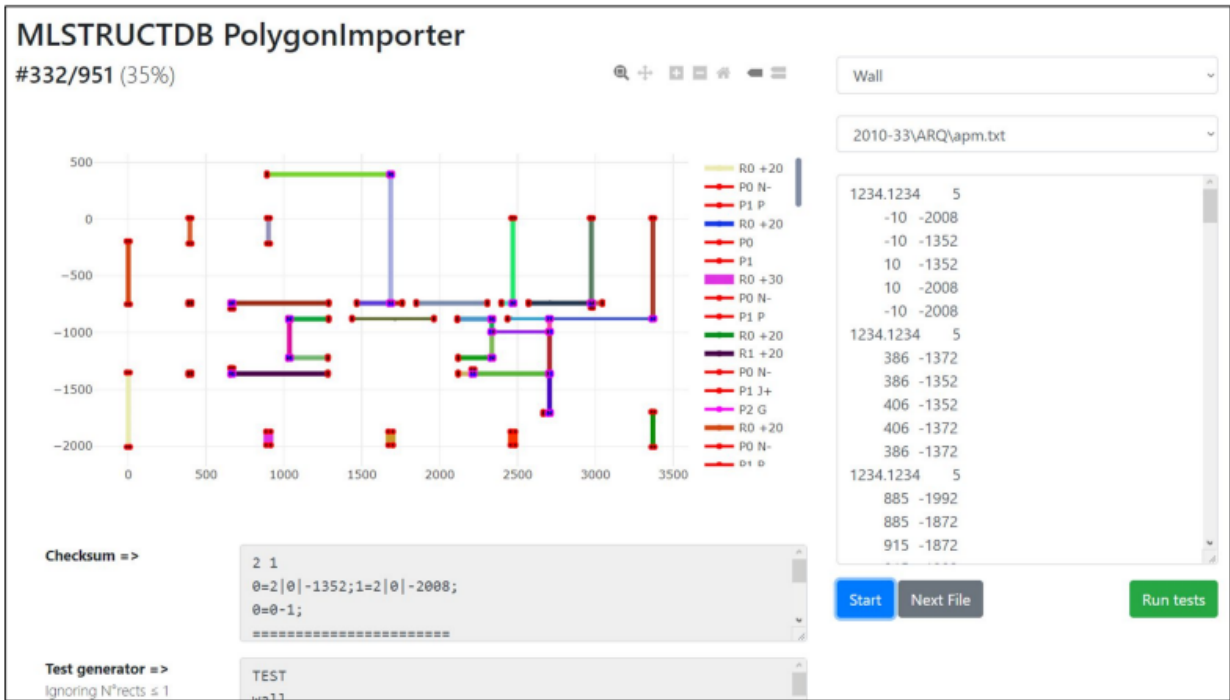
2.1. Antecedentes

Entre las herramientas que se ocuparon para elaborar esta tesis, se contaba con una base de datos que contenía información digitalizada de proyectos de hormigón armado destinados al uso habitacional. Para cada proyecto se poseía información como: los planos de arquitectura, los planos de ingeniería, la ubicación, altura del edificio, número de pisos, zona sísmica, irregularidades estructurales, año de construcción, entre otras. Estos datos fueron proporcionados por la oficina de cálculo Rene Lagos Engineers para tesis anteriores.


Los proyectos cuentan con las siguientes características:

- 165 proyectos edificios residenciales de hormigón armado construidos en Chile.
- 477 planos digitales con 3 tipos de plantas.
- Ubicados en 17 ciudades de todo el país, 65 % de ellos se ubican en la capital, 23 % en ciudades del norte, y en ciudades del sur 12 %.
- Diseñados entre 2004 y 2018, 52 oficinas de arquitectura diferentes y calculados por la misma oficina de ingeniería estructural.
- Los edificios tienen entre 5 y 35 pisos, altura promedio de piso de 2.5 metros, y máximo de 5 estacionamientos subterráneos (sótanos).


Mediante una aplicación web creada por Pizarro [25] (ver Figura 2.1), se manipularon los planos de los proyectos. Un proyecto comprende una colección del primer plano de la planta de arquitectura y el último plano de la planta de ingeniería. Cada planta tiene una imagen, una escala en factor píxel-metro, un desplazamiento que indica el desplazamiento en coordenadas planas respecto a la planta inferior, la altura de la planta y, por último, su posición vertical. Un piso contiene losas y paredes como objetos; la losa en este contexto se almacena como el polígono completo obtenido a partir del dibujo digital, sin considerar aberturas, y su grosor; la pared es una colección de puntos (Point) y rectángulos (Rect).



(a) The software included tools for loading, visualizing, and testing the wall's discretization. A floor example is shown composed of 19 walls, 42 rectangles, and 61 points



(b) Example of a discretized wall



(c) The wall distribution contains objects with different angles, orientations, shapes, and thickness

Figura 2.1: Visualización de la geometría y topología de varios muros ejemplos utilizando la aplicación web (Pizarro, 2021).

Un punto consiste en las coordenadas planas de cada vértice basadas en el sistema de coordenadas del suelo. Un rectángulo es un elemento que representa la discretización del muro, definido de forma única por conectando dos puntos con un determinado grosor y punto de inserción (dirección local). La Figura 2.2 ilustra un esquema simplificado del sistema de objetos; todos los objetos tienen un identificador único utilizado para enlazar y ensamblar la jerarquía lógica.




Figura 2.2: Organización de los objetos de discretización estructural (Pizarro, 2021).

Con la base de datos de los proyectos y mediante la aplicación web, Pizarro construyó una nueva base de datos capaz de determinar la geometría de todos los rectángulos que forman cada uno de los muros con un alto nivel de detalle [25]. Finalmente, con toda esta información se procedió a generar la base de datos que se ocupará en esta investigación. En las siguientes secciones se explicará detalladamente la metodología que se ocupó para crear la base de datos que se utiliza en el algoritmo ANN.

2.2. Función de Asociación

Los rectángulos en los planos de arquitectura conforman el diseño del proyecto, sin embargo, sus dimensiones, la orientación y la posición de estos, no siempre coinciden para el plano de ingeniería. Por lo anterior, Pizarro creó una función de asociación aplicada en los rectángulos de arquitectura e ingeniería para relacionarlos entre sí e identificar si un rectángulo de arquitectura pertenece o no a un rectángulo dentro de plano de ingeniería. La función, **Asociación**, se basa en una ecuación heurística, la cual, para cualquier proyecto, considerando un muro (sección transversal compleja) como una serie de rectángulos o segmentos de muro conectados por puntos únicos en cada piso, asigna un puntaje (entre 0 y 1) a todos rectángulos de la planta arquitectónica con los del plano estructural, considerando como “asociación” cuando se supera un valor por encima de la media más una desviación estándar para un elemento arquitectónico dado.

Para un proyecto, dentro de la misma planta, se escoge un rectángulo dentro del plano de arquitectura y se aplica la función contra todos los rectángulos de ingeniería, de manera que los rectángulos en ingeniería que generen que la función supere el valor objetivo entre todos los puntajes obtenidos, sean considerados como asociados a ese rectángulo en arquitectura. El proceso se repite para todos los rectángulos de arquitectura dentro de una misma planta, para todas las plantas y para todos los proyectos.

El puntaje de **Asociación** se obtiene relacionando características geométricas entre los rectángulos de arquitectura e ingeniería. Los resultados de las relaciones son normalizados mediante una función de normalización no lineal: $\chi(x) = 1 - |\tanh(x)|$ que da mayor importancia a los valores en torno a 0 y a los valores casi nulos fuera del rango $(-3, 3)$ como se muestra en la Figura 2.3.




Figura 2.3: Función de normalización $\chi(x)$ propuesta en el cálculo de la puntuación de *Asociación*.

Finalmente, la función **Asociación** se expresa matemáticamente como:

$$S_c(r_A, r_B) = 0.1d_G + 0.3d_P + 0.1d_A + 0.25d_\theta + 0.2d_L + 0.05d_I \quad (2.1)$$

Donde:

S_c : Puntuación de la asociación.

r_A : Rectángulo de arquitectura.

r_B : Rectángulo de ingeniería.

d_G : La distancia entre los centros geométricos.

$$d_G = \chi \left(\frac{d(r_{AG}, r_{BG})}{D} \right)$$

$d(x, y)$: Distancia euclidiana entre dos polígonos en el plano cartesiano.

r_{AG} : Centro geométrico de r_A .

r_{BG} : Centro geométrico de r_B .

D : 10 % de la distancia diagonal de la planta.

$$D = 0.1\sqrt{B^2 + H^2}$$

B : Ancho de la planta.

H : Altura de la planta.

d_P : La mínima distancia entre polígonos.

$$d_P = \begin{cases} \chi(d_{P_{AB}}) & d_{P_{AB}} < 0.75D \\ S_c(r_A, r_B) \rightarrow 0 & d_{P_{AB}} \geq 0.75D \end{cases}$$

dP_{AB} : Mínima distancia euclidiana entre el polígono de arquitectura y el de ingeniería.

$$dP_{AB} = \min(d(r_{AP}, r_{BP}))$$

r_{AP} : Polígonos de r_A compuestos por cuatro vértices.

r_{BP} : Polígonos de r_B compuestos por cuatro vértices.

d_A : La distancia ortogonal entre los ejes fuertes de los rectángulos.

$$d_A = \chi \left(\frac{d_{\perp}(r_{AP}, r_{BP})}{0.5D} \right)$$

$d_{\perp}(r_{AP}, r_{BP})$: Distancia ortogonal entre los ejes principales de los polígonos.

d_{θ} : La diferencia angular.

$$d_{\theta} = \begin{cases} \chi \left(\frac{\Delta\theta}{30^{\circ}} \right) & \Delta\theta < 45^{\circ} \\ S_c(r_A, r_B) \rightarrow 0 & \Delta\theta \geq 45^{\circ} \end{cases}$$

$\Delta\theta$: Valor absoluto de la diferencia angular entre polígonos.

$$\Delta\theta = |\theta_{r_A} - \theta_{r_B}|$$

θ_{r_A} : Ángulo de r_A con respecto al eje menor del plano del edificio.

θ_{r_B} : Ángulo de r_B con respecto al eje menor del plano del edificio.

d_L : La diferencia entre largos.

$$d_L = \chi \left(\frac{|r_{AL} - r_{BL}|}{r_{AL}} \right)$$

r_{AL} : Largo de r_A .

r_{BL} : Largo de r_B .

d_I : El porcentaje de intersección de las áreas de los polígonos.

$$d_I = \frac{\cap(Area_{r_A}, Area_{r_B})}{Area_{r_A}}$$

$Area_{r_A}$: Área de r_A .

$Area_{r_B}$: Área de r_B .

2.2.1. Asociación Modificada

Mediante una inspección a todos los proyectos dentro de la base de datos de Pizarro, se determinaron casos puntales en donde el desempeño de la función no era ideal, tal como se

muestra en la Figura 2.4. Se propuso modificar *Asociación*, de manera que, se capturen la mayor cantidad de rectángulos de muro que puedan ser asociados (rectángulos No Asociados). Esto mejorará el desempeño del modelo que se usará para la predicción debido a que entenderá mejor la necesidad de rectángulos nuevos no considerados en arquitectura ya que estos rectángulos no son elementos de muros nuevos, más bien, son casos donde el criterio que usa *Asociación* no era el correcto.

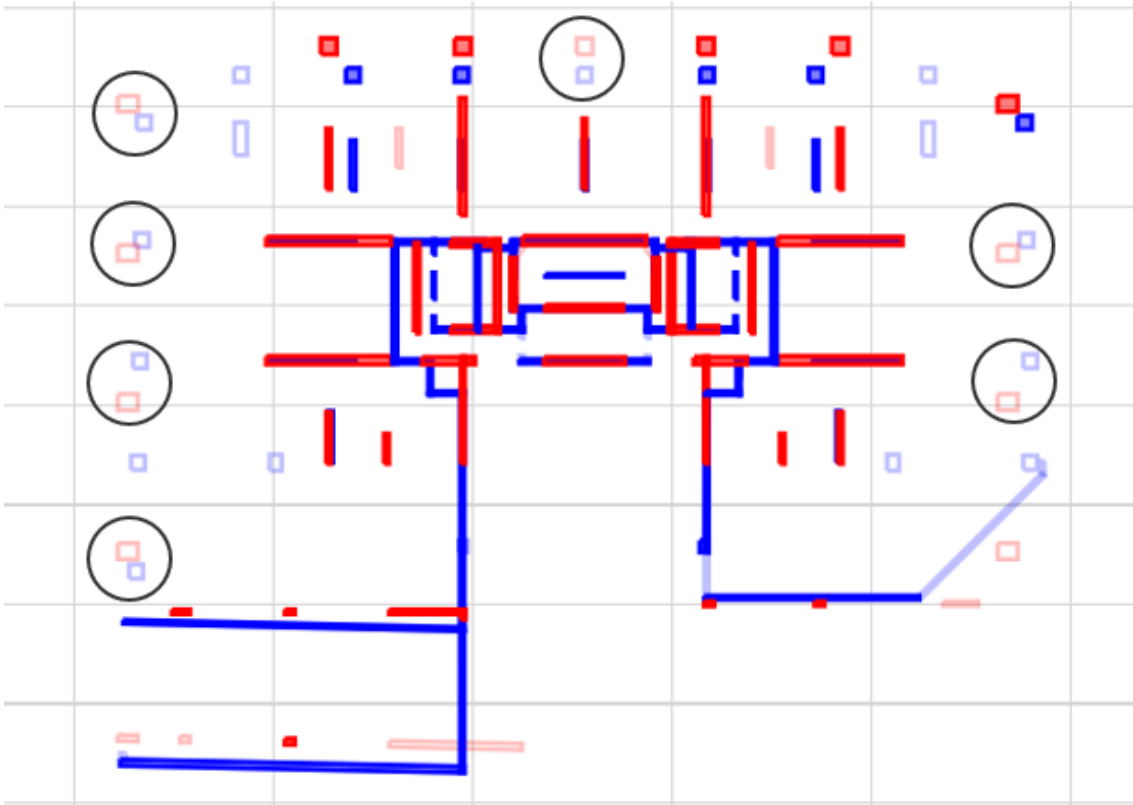


Figura 2.4: Planos: Arquitectura vs. Ingeniería. Rectángulos azules y rojos rellenos: Asociados. Rectángulos azules y rojos vacíos: No Asociados. Rectángulos dentro de los círculos: Problema con la asociación.

Una vez determinado los rectángulos mal asociados, se modificó la codificación para reducir al mínimo elementos mal asociados. Entre los cambios que se efectuaron están: el aumento de la puntuación al factor que se otorga a la mínima distancia entre un rectángulo de arquitectura y uno de ingeniería, de la misma manera se redujo el factor de la distancia entre polígonos, dándole más peso a los elementos que se encuentren más cercanos uno de otros. La ecuación que se utiliza ahora es:

$$S_c(r_A, r_B) = 0.05d_G + 0.35d_P + 0.1d_A + 0.25d_\theta + 0.2d_L + 0.05d_I \quad (2.2)$$

Otro cambio que se realizó fue el rectificar la definición de elementos asociados a los muros cortos o columnas, que al pasar del plano de arquitectura al de ingeniería su dimensión suele cambiar, haciendo que su eje fuerte pueda pasar de un plano de coordenadas a otro, generando que la diferencia angular (d_θ), rechacé la asociación para este tipo de rectángulos. Por lo anterior, se establecieron como muros cortos o columnas a aquellos rectángulos que las dimensiones de su ancho y de su largo fueran menores a 65 [cm] (ver Figura 2.5), para que

puedan obtener el puntaje correspondiente en el factor que determina la diferencia angular, agregando un poco más de holgura en el puntaje final de la asociación.




Figura 2.5: Ejemplo rectángulo corto: largo y espesor menores a 65 [cm].

2.2.2. Resultados

Los cambios que se incorporaron en la función de asociación lograron como resultado mejoras en la cantidad de elementos asociados de alrededor del 5% en relación a los elementos de arquitectura totales. Aplicando la técnica de aumento de datos [26], se construyen 3 sets de datos cambiando la orientación de los planos. Con la modificación de **Asociación**, para el primero (Set de datos A) que consiste en la orientación que viene por defecto en los planos, se agregaron 1743 datos. Para el segundo (Set de datos B), que realiza espejos de los rectángulos $[(x,y) (-x,-y) (-x,y) (x,-y)]$, aumentó cuatro veces la cantidad de datos y se agregaron 6963 rectángulos. El último set de datos (Set de datos C) utiliza las 4 orientaciones del set de datos B y crea una copia del set B girando todos los rectángulos 90° duplicando los resultados con 13833 rectángulos nuevos. A continuación, la Tabla 2.1 muestra un resumen de los resultados obtenidos de la nueva función de asociación. En la primera columna se presentan los sets de datos que se realizaron, las dos siguientes columnas, son la cantidad de rectángulos totales dentro de los planos de ingeniería y de los planos de arquitectura. En las dos últimas columnas, se sitúan la cantidad de rectángulos asociados mediante el criterio que usa Pizarro y **Asociación** Modificada.

Tabla 2.1: Datos asociados dentro de los set de datos.

Set de Datos	Rectángulos Ingeniería	Rectángulos Arquitectura	Rectángulos Asociados (Pizarro, 2021)	Rectángulos Asociados Asociación Modificada
A	42195	36916	32960	34677
B	168780	147651	131853	138762
C	337560	295302	263659	277524

La Figura 2.6 y la Figura 2.7 muestran algunos ejemplos que representan el antes y el después de dos proyectos; y como mejora la asociación al usar la función modificada. La representación de los colores en los rectángulos es la misma que la usada en la Figura 2.4.

Para el ejemplo de la Figura 2.6, se utilizó solo una porción de un plano. Del lado izquierdo se destacó mediante un círculo, un rectángulo del plano de arquitectura que al pasar al de ingeniería, es rotado y no logra ser asociado por Pizarro, mientras que en el lado derecho, una vez modificada la función **Asociación** este par de rectángulos logra ser asociado. Siguiendo la misma metodología, la Figura 2.7 es el resultado de la modificación para la planta entera mostrada en la Figura 2.4.




Figura 2.6: Ejemplo 1: Antes y después de la modificación de Asociación.




Figura 2.7: Ejemplo 2: Antes y después de la modificación de Asociación.

El objetivo que tiene esta tesis es predecir los rectángulos que no fueron considerados en el diseño de arquitectura, por lo que los rectángulos No Asociados son el caso de estudio que usa el modelo de regresión. Se muestra en la Figura 2.8 histogramas del largo, espesor, área y ángulos para los 7518 rectángulos que no fueron asociados por **Asociación**. Se nota que para el largo el rango de valores varía entre 0.3 a 30 [m], siendo que 0.3 puede corresponder a una de las dimensiones para una columna, sin embargo, la mayor cantidad de rectángulos concentra su largo en valores entre 1 y 6 [m], que son valores típicos para los segmentos de muros ocupados en edificios residenciales chilenos. Para el espesor, el rango de valores se encuentra entre 0.12 y 1.1 [m], también dimensiones típicas. Estos rectángulos mantienen un área promedio entre los 0.6 y 0.8 [m²], y sus ángulos en respecto a la orientación de la planta, son mayormente 0 y 90 grados, es decir horizontales o verticales, y muy pocos en diagonal.




Figura 2.8: Histograma de: largo, espesor, área y ángulos para los rectángulos No Asociados.

Capítulo 3

Construcción de la Base de Datos

Es importante definir las características que se dispondrán en los vectores, dado que, la buena calidad de los datos es fundamental para obtener el resultado final deseado. En este capítulo se explica el funcionamiento de algunos programas que se utilizan para crear la base de datos. La base de datos consiste en la construcción de un vector de entrada y uno de salida, los cuales, serán usados en nuestro modelo ANN para la predicción de rectángulos nuevos en los planos de ingeniería.

3.1. Mapeo de rectángulos

Se programó la función *Mapeo* capaz de crear vecindades o sub conjuntos de los planos digitalizados y extraer información de los rectángulos que existen dentro de estos. Una vecindad es creada dentro de una planta usando como centro un rectángulo de arquitectura asociado a alguno de ingeniería y viceversa. Un ejemplo se muestra en la Figura 3.1, para un par de rectángulos asociados (arquitectura e ingeniería), se generan vecindades de 7 [m] radiales y, se obtendrán información de los rectángulos dentro de estas.

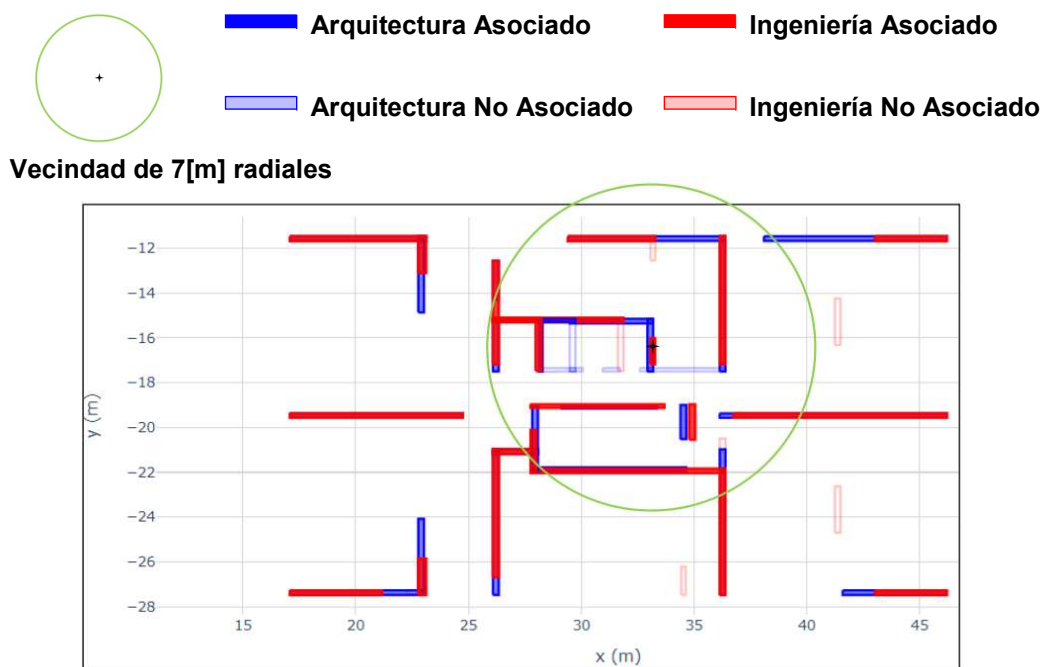


Figura 3.1: Ejemplo: Vecindad creada con un mapeo de 7 [m] radiales.

Dentro de un plano, *Mapeo* ordena los rectángulos según su cercanía al rectángulo central e identifica todos los rectángulos como asociados y No Asociados, aplicación clave para crear los vectores de entrada y de salida, además. La función toma como parámetros: características de un rectángulo, el radio de la vecindad y número de proyecto. El proceso interno que realiza *Mapeo* es:

1. Descargar del proyecto elegido todos los pisos que existen, estos pueden ser: subterráneo, primer piso o piso tipo.
2. Para cada piso del proyecto se utiliza la función *Asociación* para determinar los rectángulos de arquitectura e ingeniera asociados y No Asociados con lo cual se crean cuatro listas representadas por colores:
 - L_Arquitectura (Azul Brillante): Todos los rectángulos de arquitectura que poseen asociación con rectángulos de ingeniería.
 - L_Arquitectura_No_Asociado (Azul Opaco): Todos los rectángulos en arquitectura que no pudieron ser asociados a alguno de ingeniera.
 - L_Ingeniería (Rojo Brillante): Cada rectángulo de ingeniería asociado correspondiente al rectángulo de arquitectura.
 - L_Ingeniería_No_Asociado (Rojo Opaco): Todos los rectángulos en ingeniería que no pudieron ser asociados con alguno de arquitectura.
3. Cada rectángulo dentro de las listas L_Arquitectura y L_Ingeniería es usado como centro para crear una vecindad de “ x ” metros de radiales. La Figura 3.2) muestra la secuencia de como *Mapeo* van creando distintas vecindades para los rectángulos asociados.

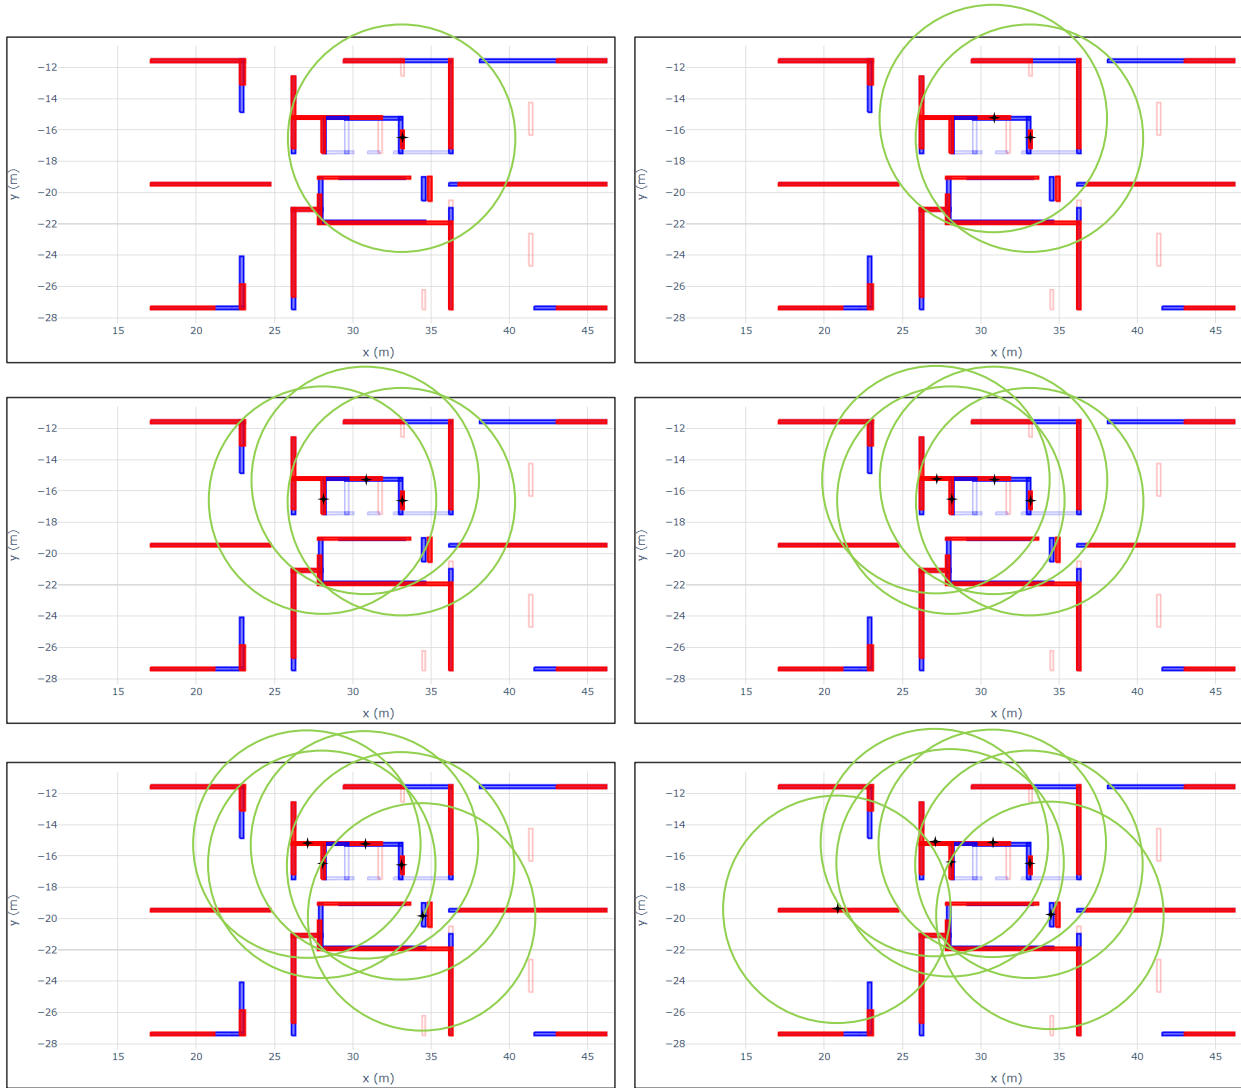


Figura 3.2: *Mapeo* recorriendo los rectángulos asociados.

4. En arquitectura, se obtenían características topológicas por proyecto como: Tipo de suelo, Zona Sísmica, Número de pisos y Números de subterráneos. Además, para cada vecindad, se mapean todos los rectángulos que existen, en la Figura 3.3, estos rectángulos están señalados por una flecha y encerrados en óvalos negros. Además, para cada rectángulo se obtienen las siguientes características:

- Largo.
- Espesor.
- Área.
- Inercia eje x e y.
- Ángulo de dirección.
- Distancia (x, y) al centro de masa de la planta.
- Distancia más cercana a rectángulo.
- Conectividad (Categoría Discreta):
Conectado (1)
No Conectado (2).

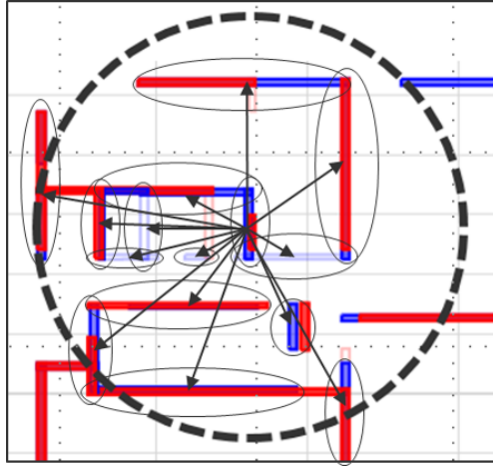


Figura 3.3: Mapeo capturando los rectángulos para una vecindad de un rectángulo de arquitectura asociado.

5. En ingeniería, para cada vecindad, se usa como centros todos los rectángulos de la lista $L_Ingeniería$ pero se mapean solo los rectángulos de la lista $L_Ingeniería_No_Asociado$ que existen. En la Figura 3.4 estos rectángulos están señalados por una flecha y encerrados en óvalos negros. Para cada uno de estos rectángulos se obtienen las siguientes características:

- Largo.
- Espesor.
- Área.
- Ángulo de dirección.
- Distancia (x, y) con respecto al centro de masa de la planta.
- Identificador (Categoría Discreta):
 Parte de un muro (1)
 Gravitacional (2).




Figura 3.4: Mapeo capturando los rectángulos no asociados para una vecindad de un rectángulo de ingeniería asociado.

6. En ingeniería, si dentro de una vecindad no existen rectángulos No Asociados se crea un vector de ceros para esa vecindad.

- Este proceso se repite para los 165 proyectos que existen dentro de la base de datos de los planos digitalizados.

Una vez terminado el mapeo de todos los proyectos, los datos obtenidos se ordenan como un arreglo donde todas las características que conforman un rectángulo se agrupan, todos los rectángulos de una vecindad son parte del mismo vector y cada vecindad es considerada como una muestra. Con la intención de obtener una buena calidad de datos, *Mapeo* se utiliza para distintos radios con una variación entre 6 a 30 metros radiales. La Figura 3.5 muestra un ejemplo de la variación de vecindades según aumenta el radio de mapeo. Un detalle importante es que no se revisaron radios más grandes por la cantidad de tiempo que ocupada *Mapeo* para crear las bases de datos.

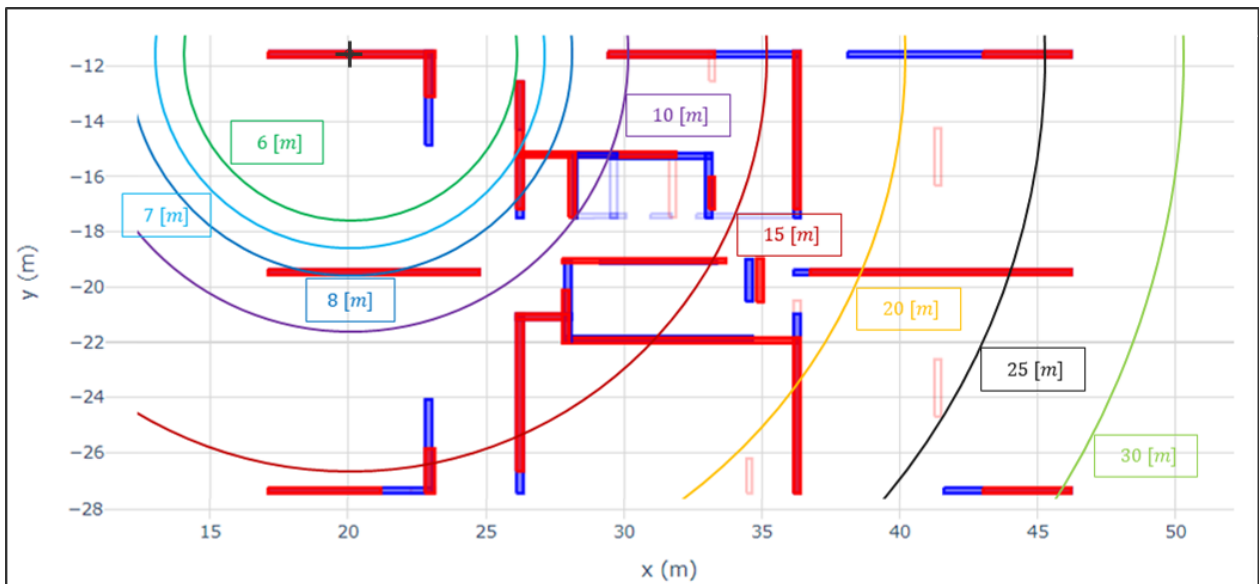


Figura 3.5: Representación de alcance de *Mapeo* para radios de 6 a 30 [m].

Dado que el radio de mapeo es variable, es relevante conocer la cantidad de rectángulos que existen dentro de las vecindades en los planos de arquitectura e ingeniería ya que proporcionan los datos que se utilizarán para construir los vectores de entrada y de salida. Con la cantidad de rectángulos adecuada se podría mejorar el rendimiento e influir en el resultado final del algoritmo ANN. Según la tabla 2.1, para el set de datos A existen 34677 vecindades posibles para la recompilación de datos de los rectángulos, y 277524 para el set de datos C.

Con los rectángulos obtenidos de los planos de arquitectura se construye el vector de entrada de nuestra base de datos. Con un radio de 6 [m] se pueden obtener un máximo de 32 rectángulos y en promedio 8 rectángulos, mientras que, si se aumentaba el radio a 30 [m], existen hasta 173 rectángulos por vecindad y en promedio 67 rectángulos. La Tabla 3.1 muestra los valores máximos y promedios de los rectángulos dentro de una vecindad según el radio de mapeo en arquitectura, mientras que la Figura 3.6, muestra como ejemplo la distribución de rectángulos para 15 y 30 [m] de radio.

Tabla 3.1: Cantidad de rectángulos en arquitectura capturados con distintos radios de mapeo.

Arquitectura		
Radio de la vecindad	Número de rectángulos	
	Máximo	Promedio
6	32	8.3
7	41	11
8	56	13.8
10	61	19.9
15	90	35.6
20	124	49.4
25	157	59.9
30	173	67.6

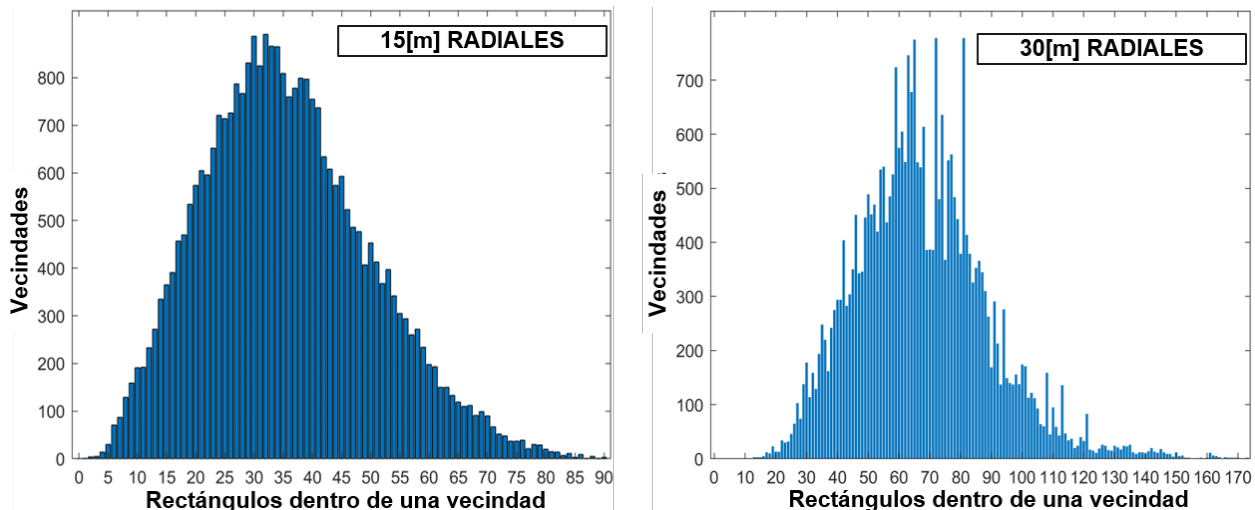


Figura 3.6: Distribución de rectángulos Asociados para 15 y 30 [m] de radio.

Para ingeniería, con un radio de 6 [m] se obtenida un máximo de 15 rectángulo No Asociados entre las vecindades y en promedio un rectángulo no asociado. Igual que en arquitectura, con el aumento del radio se rescata más información de los rectángulos No Asociados, para 20 [m], 25 [m] y 30 [m] se alcanza un máximo de 63 rectángulos No Asociados, aunque el promedio para estos radios es distinto. La Tabla 3.2 muestra los valores máximos y promedios de la cantidad de los rectángulos No Asociados dentro de una vecindad según el radio de mapeo en ingeniería y la Figura 3.7, muestra como ejemplo la distribución de rectángulos No Asociados para 15 y 30 [m] de radio.

Tabla 3.2: Cantidad de rectángulos No Asociados en ingeniería capturados con distintos radios de mapeo.

Ingeniería		
Radio de la vecindad	Número de rectángulos No Asociados	
	Máximo	Promedio
6	15	0.93
7	19	1.35
8	21	1.64
10	28	2.33
15	49	4.32
20	63	6.14
25	63	7.71
30	63	8.92

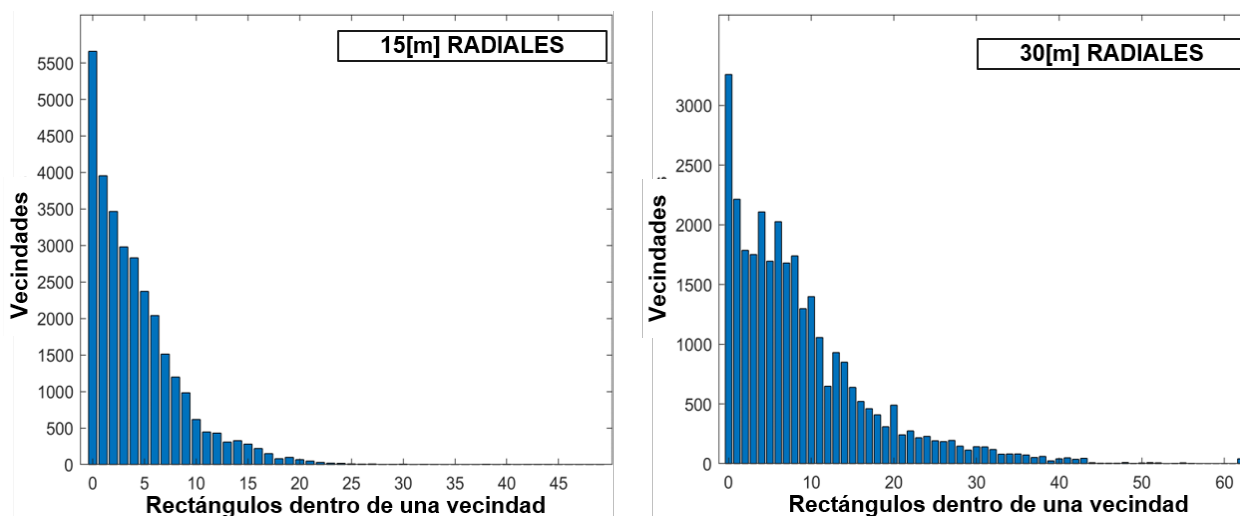


Figura 3.7: Distribución de rectángulos No Asociados para 15 y 30 [m] de radio..

Con lo obtenido de *Mapeo* se empezará a estructurar el vector de entrada y de salida que usará en el modelo ANN.

3.2. Vector de entrada y de salida

El **vector de entrada** se encarga de almacenar la información propuesta de los rectángulos que formar los planos de arquitectura y el **vector de salida** los rectángulos No Asociados de ingeniería. Siguiendo la propuesta de usar una cantidad de datos menor a los 4126 datos por imagen que usa el modelo CNN de Pizarro [9], se abordan dos enfoques para el arreglo

de datos que conformaran los vectores.

El primer enfoque se basa en crear un arreglo $m \times n$ con m como el número de columnas (vecindades) y n el número de filas que varía entre los vectores y que luego será ordenado según el área de los rectángulos. Para la entrada, se determina mediante una operación matemática que se describe de la siguiente manera:

$$n = 4 \text{ Caracts. Únicas} + \max(N_{rects}) \cdot (10 \text{ Caracts. Rectángulos})$$

donde $\max(N_{rects})$ es la máxima cantidad de rectángulos dentro de una vecindad para un mismo radio de mapeo. Debido a que no todas las muestras poseen el mismo máximo de rectángulos para el mismo radio, las filas de los rectángulos con un N_{rect} menor al $\max(N_{rects})$ se completan con valores igual a cero logrando que todas las filas de nuestro arreglo posean el ancho. Se plantea la misma metodología para la salida con la diferencia que la operación para n se reescribe como:



$$n = \max(N_{rectsNoAsociados}) \cdot (6 \text{ Caracts. Rectángulos})$$

siendo $\max(N_{rectsNoAsociados})$ el máximo número de rectángulos No Asociados en entre todas las vecindades de un mismo radio. En la Tabla 3.3 se muestran los resultados de los valores n para el vector de entrada y de salida según la variación del radio de mapeo. Estos valores también se entienden como la cantidad de datos por vecindad que se podrían usar el modelo ANN.

Tabla 3.3: Valor n para vector de entrada y de salida según radio de mapeo.

Radio	n	
	Entrada	Salida
6	324	105
7	414	133
8	564	147
10	614	196
15	904	343
20	1244	441
25	1574	441
30	1734	441


Por último, se ordenan los rectángulos por área de mayor a menor con el fin de que, para la salida, sea prioridad que la predicción del primer rectángulo no asociado corresponda al que más importante y así que vaya descendiendo, y para la entrada, aprender la estructuración de los planos desde los muros más grande a los más chicos. La Figura 3.8 muestra como se crea un arreglo de vector de entrada utilizando **Mapeo** en un plano de arquitectura con una vecindad de 20 [m] radiales.



Muestras	1° rectángulo										2° rectángulo										...	N° rectángulos dentro de la vecindad	
	LARGO	ESPESOR	AREA	ÁNGULO	INERCIAX	INERCIAY	Δx - C.M DE LA PLANTA	Δy - C.M DE LA PLANTA	MIN. DIST. A OTRO RECTÁNGULO	CONECTIVIDAD	LARGO	ESPESOR	AREA	ÁNGULO	INERCIAX	INERCIAY	Δx - C.M DE LA PLANTA	Δy - C.M DE LA PLANTA	MIN. DIST. A OTRO RECTÁNGULO	CONECTIVIDAD			
1° Vecindad																						→	
⋮ ↓																							
N° vecindades																							

Figura 3.8: Arreglo de datos para el vector de entrada.

De igual forma, la Figura 3.9 muestra como se crea un arreglo de vector de salida. Para el rectángulo de ingeniería asociado, se crea una vecindad de 20 [m] radiales y se identifican los rectángulos No Asociados, ordenándolos de mayor a menor área.



- 1°
- 2°
- 3°
- 4°



Muestras	1° rectángulo NO ASOCIADO							2° rectángulo NO ASOCIADO							↓	N° rectángulos NO ASOCIADOS dentro de la vecindad (N° SALIDAS)
1° Vecindad	LARGO	ESPOSOR	AREA	ÁNGULO	Δx - C.M DE LA PLANTA	Δy - C.M DE LA PLANTA	CATEGORIZADOR	LARGO	ESPOSOR	AREA	ÁNGULO	Δx - C.M DE LA PLANTA	Δy - C.M DE LA PLANTA	CATEGORIZADOR		
⋮ ↓																
N° vecindades																

Figura 3.9: Arreglo de datos para el vector de salida.

El segundo enfoque, y el de mayor relevancia, es el de reducir arbitraria el valor n en ambos vectores. Para esto, se encontró una cantidad significativa de rectángulos que sea igual dentro de las vecindades. A medida que el radio de mapeo crece, aumenta la cantidad de rectángulos dentro de las vecindades, pero también aumentan la cantidad de ceros que rellenan el vector cuando la cantidad de rectángulos de una vecindad no alcanza a la máxima dentro de todas

las vecindades, por lo que rellanamos con información innecesaria ambos vectores (relleno de ceros).

Por lo anterior, se examinan distintos valores para N_{rects} y $N_{rectsNoAsociado}$ fijos para los distintos radios de mapeo y se comprueba con cuál de estos valores el rendimiento del modelo pueda llegar a ser óptimo, logrando concentrar la mayor información que existe de los planos, con la mínima cantidad de datos posibles. A continuación, se mostrará el análisis correspondiente a una comparación del área capturada de los planos de arquitectura e ingeniería, por las vecindades usando distintos valores de radio de mapeo, N_{rects} y $N_{rectsNoAsociados}$.

Para el vector de entrada, finalmente se usaron 33 rectángulos como N_{rects} para vecindades de 30 [m] radiales. La Figura 3.10 ilustra el histograma de todos los valores de las características usadas para el set de datos C, algunas características toman valores discretos, como la zona sísmica o el tipo de suelo.

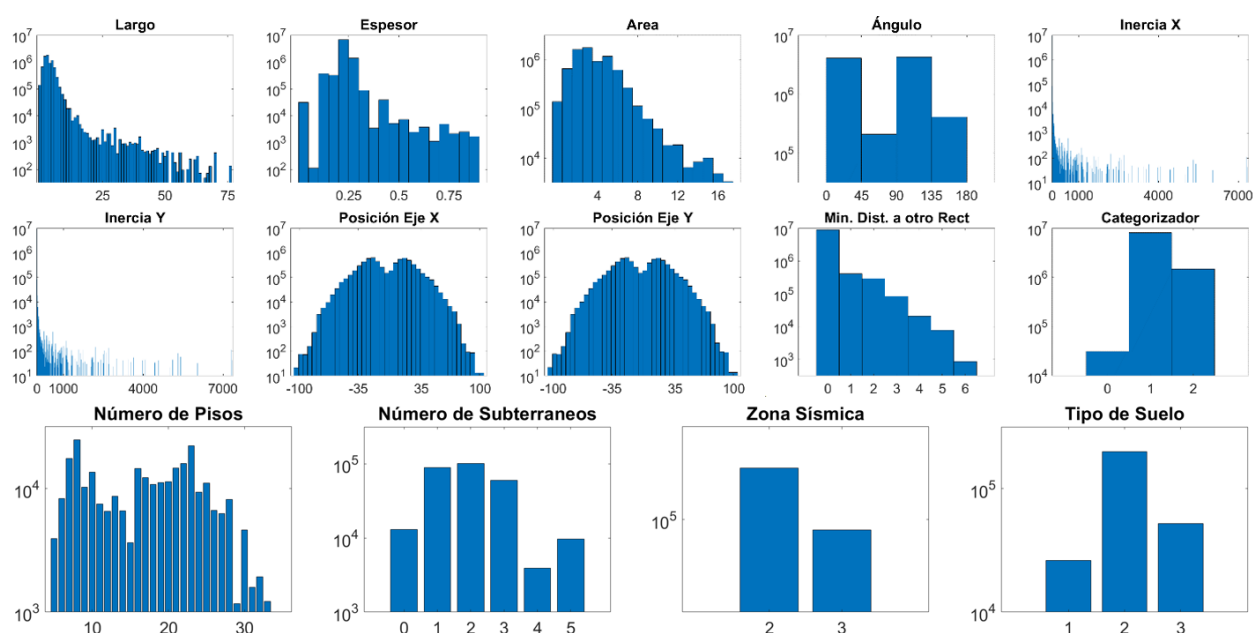


Figura 3.10: Histograma de las características del vector de entrada usando el Set de Datos C.

La Figura 3.11 muestra la comparación entre el vector de entrada usado en el modelo final y otras 3 variantes. Se calculó la relación que existe entre la unión de las áreas de todas las vecindades de un mismo piso con 22 y 33 rectángulos de entrada para radios de mapeo de 15 y 30 [m], y el área total del mismo piso. Con 22 rectángulos de entrada, para el mapeo 15 [m] radiales, el 94.36 % de los pisos tiene un índice de relación entre 0.9 y 1, el otro 5.74 % de los pisos logran una relación entre el 0.8 y 0.9. En cambio, para 30 [m], el 21.6 % de los pisos tiene relación de áreas entre 0.9 y 1, 23.31 % relación entre 0.8 y 0.9, 26.91 % entre 0.7 y 0.8, 21.61 % entre 0.6 y 0.7 y por ultimo un 6.57 % de los pisos, una relación entre 0.5 y 0.6. Luego para 33 rectángulos de entrada y radio de 15 [m], existe una relación entre 0.9 y 1 en el 100 % de los pisos. Mientras que para 30 [m] radiales, el 54.3 % de los planos tiene relación entre 0.9 y 1, 26.7 % entre 0.8 y 0.9, 16.29 % entre 0.7 y 0.8, por ultimo un 2.71 % entre 0.6 y 0.7.

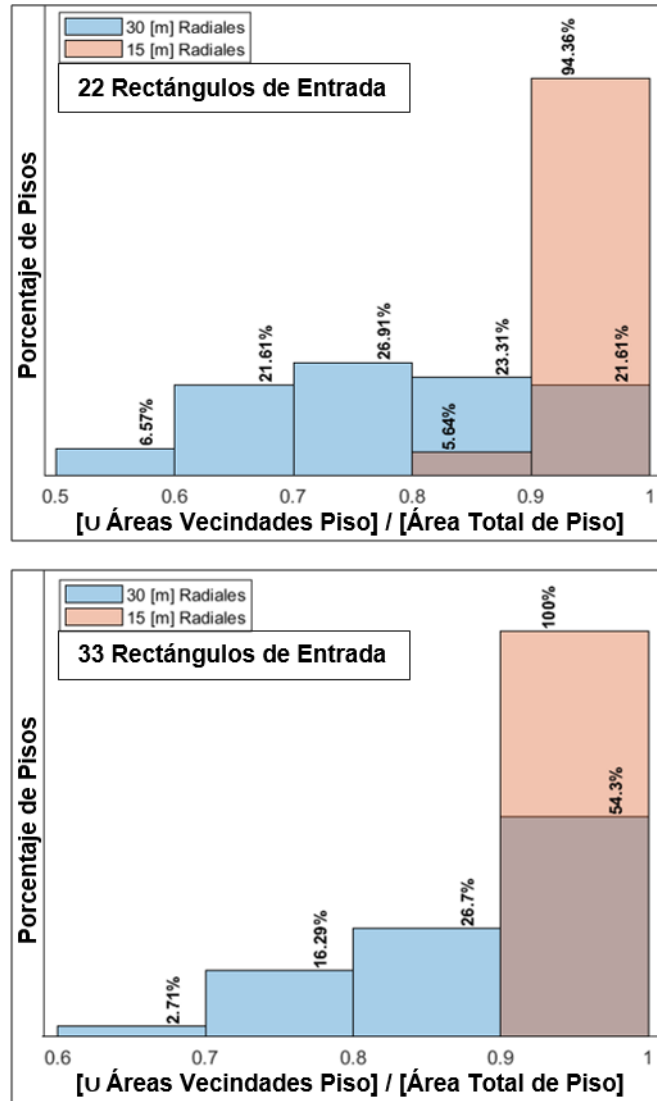


Figura 3.11: Comparación del área de los rectángulos en arquitectura capturados por mapeos de 15 y 30 [m] de radios.

En el vector de salida se usaron 6 rectángulos como $N_{rectsNoAsociados}$ para vecindades de 30 [m] radiales dentro del modelo final. Para los mismos radios de mapeo de arquitectura, se calcula la relación que existe entre la unión de las áreas de los rectángulos No Asociados de todas las vecindades de un mismo piso para 4 y 6 rectángulos No Asociados de salida, y el área total de rectángulos No Asociados del mismo piso, lo que se muestra en la Figura 3.12.

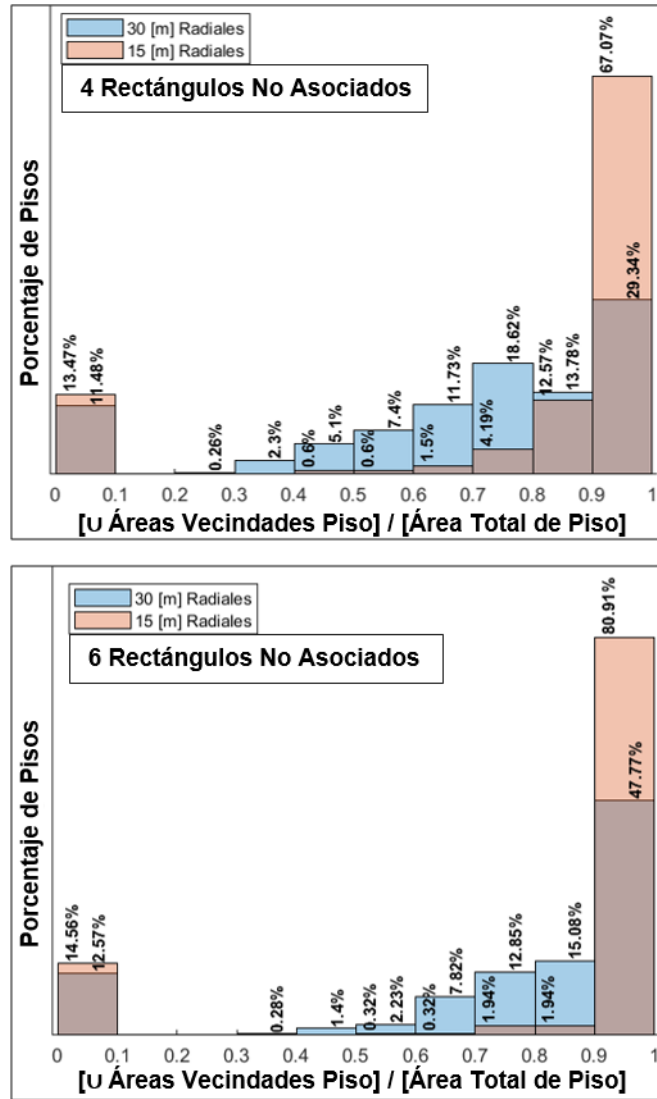


Figura 3.12: Comparación del área de los rectángulos No Asociados en ingeniería capturados por mapeos de 15 y 30 [m] de radios.

Como resultados, para con 4 rectángulos No Asociados de salida, para el mapeo de 15 [m], el 67.07% de los pisos tienen una relación de área no asociada entre 0.9 y 1, un 12.57% entre 0.8 y 0.9. Luego, para 30 [m] radiales 29.34% entre 0.9 y 1, un 18.62% entre 0.7 y 0.8 y un 13.76% entre 0.8 y 0.9. Usando 6 rectángulos No Asociados de salida, para el mapeo de 15 [m], el 80.91% de los pisos tienen una relación entre 0.9 y 1, un 3.88% entre 0.7 y 0.9 y para el radio de 30 [m], el 47.47% tienen una relación entre 0.9 y 1, un 15.08% entre 0.8 y 0.9. Cabe mencionar que existen 45 pisos que no poseen rectángulos No Asociados por lo que para los 4 vectores de salida al menos 9% de los pisos poseen una relación de 0.

En resumen, el modelo ANN final utilizó para el vector de entrada y de salida los arreglos formados por 30 [m] de radio de mapeo, 33 rectángulos de N_{rects} y 6 rectángulos $N_{rectsNoAsociados}$ respectivamente. Las Figuras 3.11 y 3.12 muestran que el radio de 15 [m] posee mejores resultados capturar información de los planos, dado que tiene más plantas con relación de áreas cercanas a 1, sin embargo, el nivel de predicción una vez ocupado el modelo no era lo suficientemente bueno, esto se explicará mejor próximo capítulo.

Capítulo 4

Modelo ANN

Una Red Neuronal Artificial (ANN) es método de la inteligencia artificial que consiste en un modelo computacional matemático que intenta imitar el procesamiento de información de la misma manera que una red de neuronas biológicas. Su funcionamiento se describe como interconexiones entre nodos o neuronas, cada nodo realiza un cálculo simple actualizando los pesos de las conexiones en la fase de entrenamiento con el fin de minimizar el error en la predicción.

Este capítulo explica cómo se usaron las bases de datos que crearon el modelo de predicción para rectángulos No Asociados en los planos de ingeniería, la arquitectura de la red utilizada y los resultados del modelo. Usando algunos ejemplos de la configuración de muros de los planos de arquitectura y los muros nuevos de los planos de ingeniería, el modelo debe ser capaz de predecir para un proyecto de arquitectura: largo, espesor, ángulo y posición (x, y) con respecto al centro de masa de la planta de muros estructurales no considerados al inicio del proyecto.

4.1. Formulación del Modelo

El modelo ANN (ver Figura 4.1) que se ocupó es de tipo secuencial, cuenta con una capa de entrada de 334 características que corresponden a 4 características topológicas únicas por proyecto y 10 características geométricas para los 33 rectángulos más grandes dentro de una vecindad, 5 capas ocultas completamente conectadas con 1000 neuronas cada una, y una capa de salida de 42 datos que pertenecen a 7 características por 6 rectángulos No Asociados. Es así que con este modelo, la cantidad de datos necesaria para poder predecir nuevos rectángulos en ingeniería es apenas un 8% en comparación al modelo que usa CNN, dado que pasamos de un vector entrada de 4126 datos por imagen (modelo UNET-XY), a solo 334 datos por imagen. Es un modelo que permite moldear su arquitectura con mayor facilidad y posee herramientas para manipular los hiperparámetros de forma fiable. La arquitectura interna que usó en este modelo es igual al que usó Pizarro para su modelo ANN [8]. Entre las características más importantes tenemos: los datos de entrada y de salida fueron normalizados entre 0 y 1 utilizando la transformación de escala Min-Max, se aplicaron 3 capas de normalización por lotes (BN), la función de activación de la capa corresponde a ReLU, la función de pérdida se establece como el Error Cuadrático Medio MSE, y el optimizador fue Adam con una tasa de aprendizaje de 10^{-3} , $\beta_1 = 0.9$, $\beta_2 = 0.999$, y $\epsilon = 10^{-7}$.




Figura 4.1: Esquema del Modelo ANN que predice rectángulos para planos de ingeniería.

El entrenamiento del modelo se llevó a cabo con minilotes de tamaño 115 y un máximo de 200 épocas. Al final de cada época, los datos del lote se reordenaron aleatoriamente para reducir la varianza. Igual que en el modelo ANN de Pizarro, se utilizó una regularización de parada temprana para evitar el sobreajuste, con una tolerancia de 40 épocas; para acelerar la convergencia, se utilizó el monitor Keras ReduceLROnPlateau para reducir la tasa de aprendizaje del optimizador del modelo si la métrica de pérdida no mejora en un margen de 15 épocas, con un factor de disminución de 10^{-1} y un delta mínimo de 10^{-4} para el valor monitorizado. La partición del conjunto de datos en entrenamiento y prueba fue del 70 % y el 30 % en orden aleatorio, respectivamente; por otra parte, del conjunto de datos de entrenamiento, el 20 % de los datos se utilizó para la validación, y el 80 % para entrenar el modelo.

Dado que el número de neuronas, capas ocultas y de regulación modifican la capacidad de predicción del modelo, se probaron manualmente diferentes combinaciones para encontrar de forma heurística la mejor configuración en términos del coeficiente de correlación del modelo. No se utilizaron algoritmos de optimización para determinar estos hiperparámetros que maximizan la respuesta del modelo debido al gran tamaño del conjunto de datos [27].

4.2. Resultados

Los resultados del modelo secuencial se analizaron en términos del coeficiente de correlación (R^2), de una matriz de confusión para la variable de salida que funciona como identi-

ficador y la representación gráfica de los resultados en los planos. La Figura 4.2 muestra la variación de pérdida de entrenamiento y la de validación del modelo para el set de datos C. El error para la curva de entrenamiento corresponde a 0.0011 mientras que para la validación es de un 0.0014.

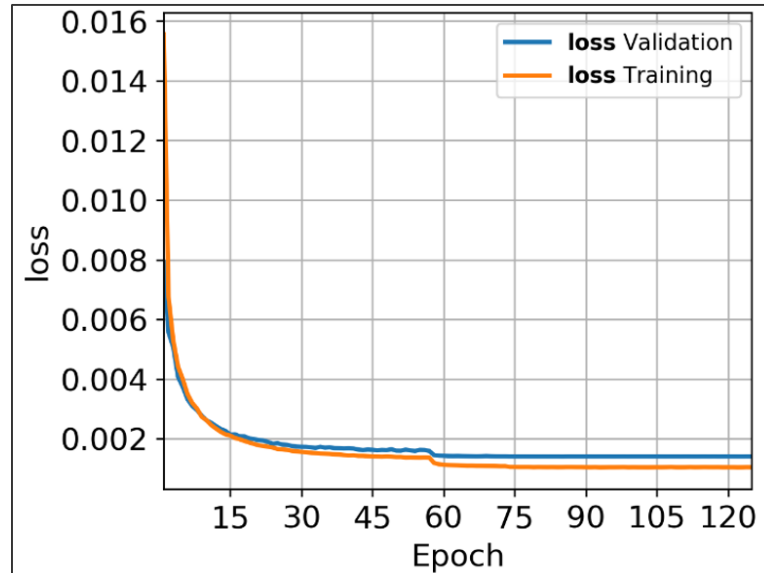


Figura 4.2: Curvas de pérdida del modelo (Entrenamiento y Validación).

El histograma de los valores reales de ingeniería del largo, espesor, área, ángulo, posiciones e identificador de todos los rectángulos predichos ocupando el set de datos C, se representa en la Figura 4.3.




Figura 4.3: Histograma de las características dentro del vector de salida.

La Figura 4.4 presentan los resultados de correlación de los valores predichos por el modelo “Predicción Ingeniería” frente a los valores reales en ingeniería “Real Ingeniería”. Para estos resultados se acomodaron todos los rectángulos predichos dentro de un arreglo que no

considera un orden específico puesto que más adelante se mostrarán los resultados de R^2 según el orden de predicción ya que originalmente estos se ubican de mayor a menor área. Se evidencia que todas las características poseen un R^2 mayor a 0.93 que se puede traducir como un buen nivel de predicción para los rectángulos nuevos.

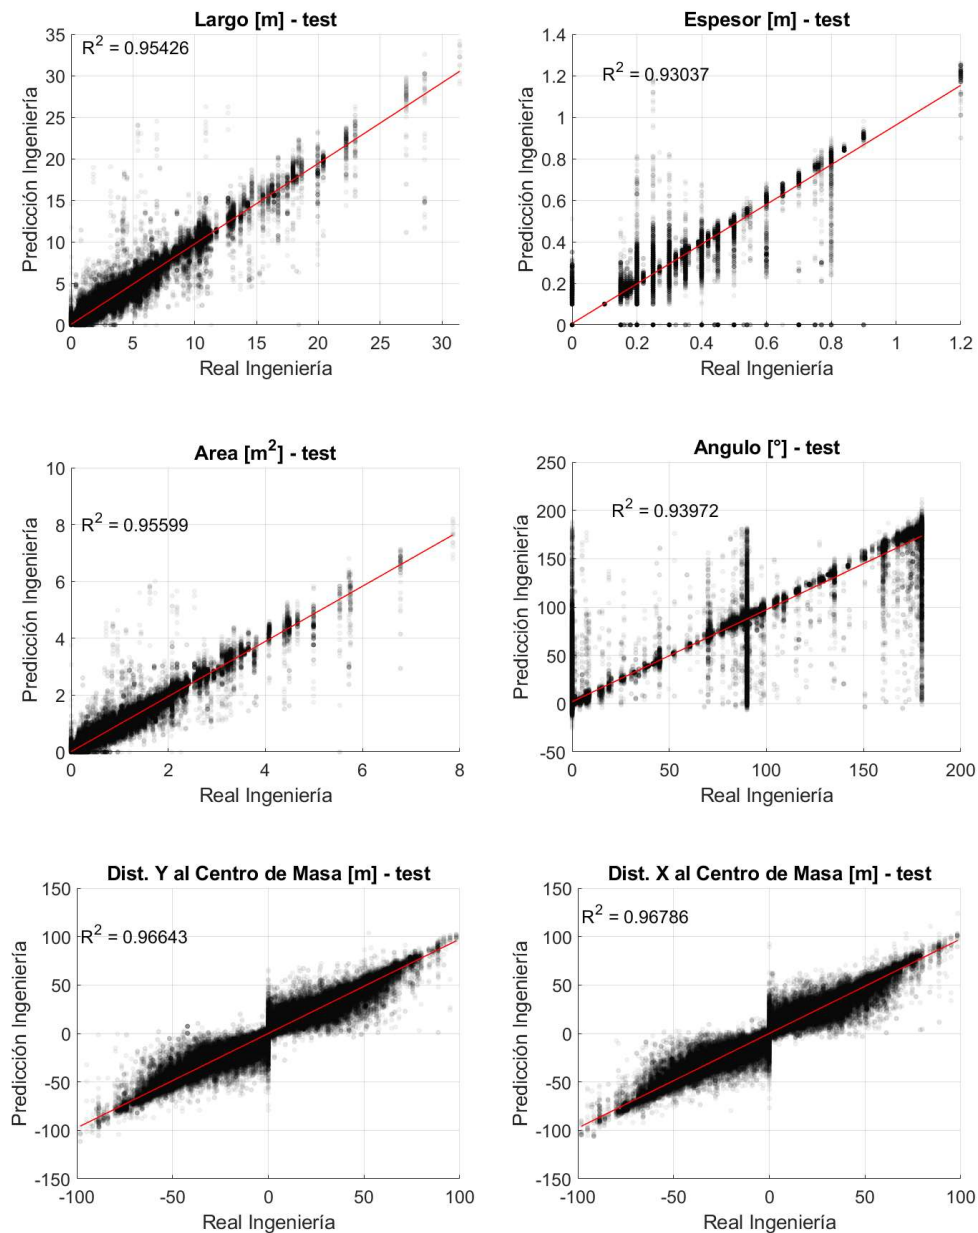


Figura 4.4: Correlación del modelo para el set de datos C.

La matriz de confusión se utilizó para mostrar los resultados del identificador. La Figura 4.5 nos permite para valorar el buen nivel de precisión que tiene el modelo mostrando los resultados de la definición correcta de los rectángulos predichos que corresponden a ser parte de otro muro o del tipo gravitacional. Se nota además que los valores entre 0 y 0.86 corresponden a elementos vacíos, es decir, no existen muros y la predicción tampoco los considera.




Figura 4.5: Matriz de confusión del Identificador para el set de datos C.

Otra manera de medir la precisión del modelo es calcular la media y la desviación estándar ($\frac{\text{Predicción Ingeniería}}{\text{Real Ingeniería}}$) entre los valores predichos y los reales. Para el largo, espesor y área se tienen relaciones cercanas a 1 y desviaciones menores a 0.35. Los valores para el ángulo son representados por lo que presenta resultados en la media y la desviación más grande al resto. La distancia x e y al centro de masa de la planta, o posiciones dentro del plano, poseen relaciones aproximadas de 1.1 y desviaciones de 1.14 y 1.01 respectivamente. La Tabla 4.1 muestra resultados para R^2 , media y desviación estándar para los resultados del modelo sin considerar su orden por área.

Tabla 4.1: Resultados del modelo de regresión para los datos considerando el vector de salida para el set de datos C.

	R^2	$\frac{\text{Predicción Ingeniería}}{\text{Real Ingeniería}}$
Largo	0.954	1.037 \pm 0.332
Espesor	0.930	0.996 \pm 0.117
Área	0.956	1.023 \pm 0.292
Ángulo	0.939	4.521 \pm 150.038
Dist. X	0.967	1.103 \pm 1.14
Dist. Y	0.967	1.095 \pm 1.01

4.2.1. Resultados Paramétricos

Los resultados de R^2 de las predicciones mejoran variando algunos de los hiperparámetros en la fase de entrenamiento, tal como lo explica la Figura 4.6. Se muestra la comparación entre 3 de los modelos más representativos, con 6 y 8 metros radiales de mapeo, ocupando 33 como N_{rects} y 1 como $N_{rectsNoAsociados}$ y modificando los siguientes hiperparámetros: Tamaño de Bache (TB), número de Neurona (N) y cantidad de Capas de Ocultas (CO), verificando que el valor del R^2 aumenta a medida que la arquitectura de los modelos se vuelve más compleja.




Figura 4.6: Resultados de R^2 usando distintos hiperparametros para mapeos de 6 y 8 [m] radiales.

Además, el R^2 mejora a medida que el radio de mapeo aumenta. La Figura 4.7 muestra los resultados de modelos que usan 33 como N_{rects} y 1 como $N_{rectsNoAsociados}$ y comparten los mismo hiperparametros (TB:115, N:1000, CO:5), pero el radio de mapeo varía entre los modelos. En el capítulo 3, se realizó un análisis de la cantidad de información que se puede capturar con un radio de mapeo de 15 [m], lo obtenido del modelo que usa ese radio, demuestra que los resultados del R^2 empiezan a acercarse a 0.9 traduciéndose como un buen nivel de predicción, sin embargo, esos resultados no son mejores que usando modelos que usan radios de mapeo mayores. No se probaron radios mayores a 30 [m] por la cantidad de información que se pierde de los planos a medida que se aumenta el radio de mapeo.




Figura 4.7: Resultados de R^2 usando distintos radios de mapeos.

El modelo final usa: 33 como N_{rects} , 6 como $N_{rectsNoAsociados}$, TB:115, N:100 y CO:5. El modelo ordena las predicciones por área, es decir, el primer rectángulo dentro de un vector de predicción corresponde al rectángulo que posee mayor área dentro del vector y el sexto rectángulo corresponde al de menor área. La Figura 4.8 muestra la variación del R^2 para las características de un rectángulo y la diferencia del mismo cuando cambia $N_{rectsNoAsociados}$. A medida que aumentan los rectángulos No Asociados dentro del vector de salida, el R^2 disminuye, entendiéndose a que el modelo es más preciso cuando predice el rectángulo No

Asociado más grande dentro de una vecindad, no obstante, los resultados para 6 rectángulos No Asociados a predecir, también muestran un alto nivel de precisión. En la Figura 4.8 notamos que fueron ejecutados 6 modelos diferentes para obtener estos resultados, las líneas indican la cantidad de rectángulos dentro del vector de salida del modelo por eso a medida que la salida aumenta, esta línea es más grande. La línea roja son los resultados para la salida de 1 $N_{rectsNoAsociados}$ y la línea morada para 6 $N_{rectsNoAsociados}$.




Figura 4.8: Resultados de R^2 según el número de rectángulos No Asociados dentro del vector de salida y radio de mapeo de 30 [m].

La Figura 4.9 muestra solo los resultados de los R^2 para la distancia (x,y) con respecto al centro de masa de la planta. A medida que aumentamos la cantidad de $N_{rectsNoAsociados}$ la precisión de la posición disminuye, de esta manera, se determina que ocupar más de 6 rectángulos empeora la exactitud del modelo. De la misma manera que la Figura 4.8, la línea es más grande para el modelo que usa 6 de $N_{rectsNoAsociados}$.

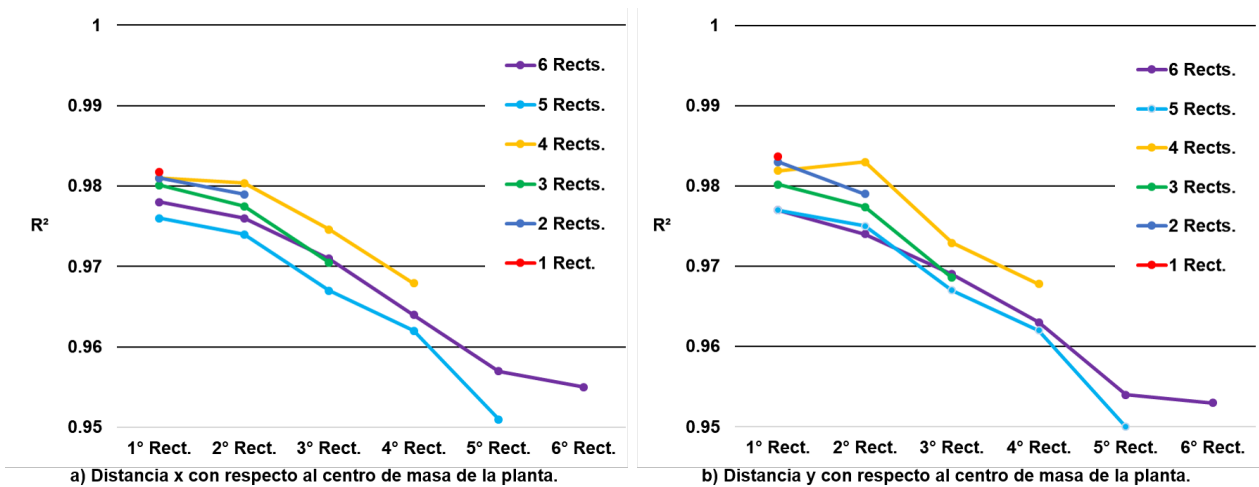


Figura 4.9: Variación del R^2 de las posiciones x e y según el número de rectángulos No Asociados dentro del vector de salida.

Estos datos son los de mayor relevancia para nuestro modelo ya que corresponden a la ubicación de las predicciones, y a nivel de ingeniería, la mala ubicación de un muro puede poner en riesgo la estructura de un edificio. La Tabla 4.2 muestra los R^2 de todas las características predichas de los rectángulos No Asociados predichos, según la cantidad de rectángulos en el vector de salida.

Tabla 4.2: Resumen de los resultados de R^2 .

		$N_{rectsNoAsociados}$					
		1	2	3	4	5	6
1° Rect.	Largo	0.947	0.948	0.945	0.952	0.940	0.945
	Espesor	0.912	0.963	0.962	0.963	0.960	0.954
	Ángulo	0.962	0.961	0.961	0.972	0.960	0.972
	Distancia X	0.982	0.981	0.980	0.981	0.976	0.978
	Distancia Y	0.984	0.983	0.980	0.982	0.977	0.977
2° Rect.	Largo	-	0.956	0.952	0.955	0.940	0.938
	Espesor	-	0.941	0.942	0.941	0.892	0.910
	Ángulo	-	0.940	0.938	0.953	0.939	0.953
	Distancia X	-	0.979	0.978	0.980	0.974	0.976
	Distancia Y	-	0.979	0.977	0.983	0.975	0.974
3° Rect.	Largo	-	-	0.955	0.961	0.950	0.953
	Espesor	-	-	0.938	0.951	0.917	0.920
	Ángulo	-	-	0.916	0.938	0.920	0.938
	Distancia X	-	-	0.971	0.975	0.967	0.971
	Distancia Y	-	-	0.969	0.973	0.967	0.969
4° Rect.	Largo	-	-	-	0.957	0.941	0.946
	Espesor	-	-	-	0.941	0.926	0.930
	Ángulo	-	-	-	0.923	0.904	0.929
	Distancia X	-	-	-	0.968	0.962	0.964
	Distancia Y	-	-	-	0.968	0.962	0.963
5° Rect.	Largo	-	-	-	-	0.940	0.956
	Espesor	-	-	-	-	0.927	0.923
	Ángulo	-	-	-	-	0.898	0.923
	Distancia X	-	-	-	-	0.951	0.957
	Distancia Y	-	-	-	-	0.950	0.954
6° Rect.	Largo	-	-	-	-	-	0.947
	Espesor	-	-	-	-	-	0.926
	Ángulo	-	-	-	-	-	0.910
	Distancia X	-	-	-	-	-	0.955
	Distancia Y	-	-	-	-	-	0.953

4.2.2. Ejemplo de aplicación

Una vez que el modelo ha sido entrenado, se puede utilizar para proponer nuevos muros que no fueron considerados en el diseño arquitectónico inicial. La Figura 4.10 se muestra el plano ocupado como ejemplo para la aplicación del modelo. El procedimiento comienza con la digitalización del plano de arquitectura obteniendo un total de 112 rectángulos, luego usando *Mapeo* se divide el plano en vecindades radiales de 30 metros por cada rectángulo. Estas se analizan para identificar rectángulos de muros estructurales que no se hayan considerado en el diseño arquitectónico original.




Figura 4.10: Plano de arquitectura usado para el ejemplo de aplicación.

Se lograron identificar 8 de 10 rectángulos estructurales que no habían sido considerados en el diseño arquitectónico original. Estos rectángulos fueron detectados por el modelo al analizar las vecindades radiales y en base a la información del plano, se estima la longitud, el ancho y la orientación de cada rectángulo, así como su posición en el plano. Como se poseía el plano estructural que se utilizó para esta planta de arquitectura, una vez aplicado el modelo, se pudo hacer una comparación entre lo que propuso ingeniería y los resultados del modelo. La Figura 4.11 muestra el plano estructural del cual los rectángulos de color negro son los que arquitectura considero dentro de su diseño, los rectángulos rojos son los que no considero y por ultimo se muestran con color verde los rectángulos que propone el modelo. Es importante tener en cuenta que el modelo se basa en un conjunto limitado de datos de entrada y en suposiciones simplificadas sobre la distribución de los elementos estructurales en el edificio, lo que puede explicar la discrepancia en los resultados. Sin embargo, la combinación del modelo de redes neuronales y la división del plano en vecindades radiales mediante el uso de *Mapeo* permitió una identificación más eficiente de los muros estructurales, lo que puede ser de gran utilidad para el diseño y construcción de edificios observando que se han agregado nuevos muros en lugares donde no se había considerado inicialmente (pero necesario en el diseño estructural).




Figura 4.11: Plano de ingeniería usado para el ejemplo de aplicación con las predicciones correspondientes del modelo ANN.

En este caso, el modelo logró identificar correctamente la mayoría de los muros estructurales que no fueron considerados en el diseño original de arquitectura. Esto sugiere que el modelo podría ser utilizado en otros proyectos para mejorar la precisión en la identificación de muros estructurales y, por lo tanto, mejorar la seguridad y la estabilidad de los edificios. No obstante, es importante tener en cuenta que el modelo es una herramienta complementaria al conocimiento y experiencia de los profesionales de la construcción, y que su uso debe ser evaluado cuidadosamente en cada proyecto específico.

Capítulo 5

Análisis de Resultados

Al observar los resultados de R^2 que entrega el modelo para las características de los rectángulos predichos, podríamos asegurar que con un radio de mapeo de 15 [m] nuestras predicciones ya poseen un nivel de precisión aceptable, pero graficando las predicciones encima de los planos de ingeniería, los rectángulos predichos crean manchones sin ningún significado ingenieril. Lo que no ocurre para un radio de mapeo de 30 [m], la precisión de la posición de los nuevos rectángulos empieza a mejorar y lo que eran manchones, empieza a verse como la necesidad de tener uno o varios rectángulos nuevos no asociados en ingeniería. La Figura 5.1 muestra un ejemplo de los rectángulos predichos para una planta usando el modelo final con 15 y 30 [m].

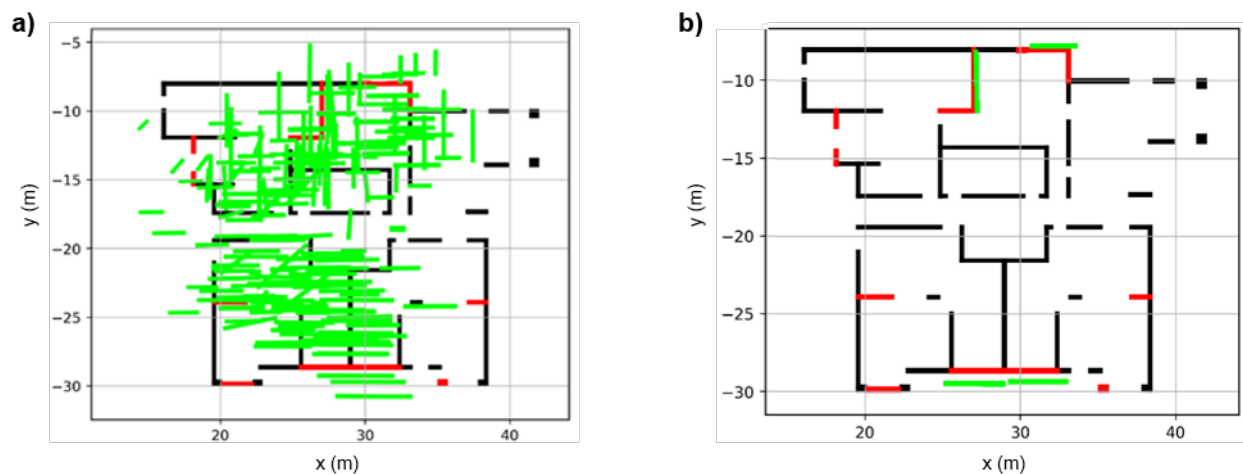


Figura 5.1: Esquema de un plano de ingeniería con los rectángulos No Asociados y sus predicciones: a) Modelo con radio de mapeo de 15 [m]. b) Modelo con radio de mapeo de 30 [m].

Debido a lo anterior, se crean 2 métricas para los resultados del modelo con el fin de tener una idea más clara del desempeño del modelo en proponer nuevos rectángulos. Para poder trabajar con las métricas, los rectángulos predichos fueron colocados en los planos de ingeniería correspondientes y se usó **Asociación** para poder emparejar las predicciones con rectángulos no asociados. La primera métrica realiza normalizaciones entre las características de las predicciones asociadas y los rectángulos No Asociados. La Figura 5.2 representa un

plano de ingeniería, los rectángulos negros son los que están asociados con arquitectura, los rojos son los No Asociados, los verdes son las predicciones del modelo y por último, los verdes dentro de las circunferencias, son asociaciones a los rectángulos rojos.




Figura 5.2: Esquema de un plano de ingeniería con los rectángulos No Asociados y las predicciones asociadas y no asociadas.

El largo es la característica más difícil de predecir debido a que es la que posee mayor variabilidad. Cada largo de las predicciones asociadas se normaliza por medio de una relación entre el largo del rectángulo de ingeniería (No Asociado) correspondiente. La Figura 5.3 muestra una comparación de los resultados de la normalización del largo entre el modelo final y un modelo con 15 [m] radios e iguales entradas y salidas que el modelo final ($N_{rects} = 33$ y $N_{rectsNoAsociados} = 6$). Entre los resultados más importantes, con 30 [m] de radio, se tiene que un 47.35% de los rectángulos predichos poseen una relación de 1 ± 0.1 , es decir que aproximadamente la mitad de las predicciones poseen cerca del mismo largo que su asociación en ingeniería. En cambio, para el radio de 15 [m], los rectángulos predichos que están cerca de parecerse al su rectángulo asociado en ingeniería son apenas el 22.13%.

Otro detalle importante en el gráfico es el agrupamiento de todas las predicciones que poseen largos mayores al doble del de sus asociaciones, donde, con 15 [m] estos alcanzan 13.37% pero para 30 [m] son solo el 5.44%.




Figura 5.3: Resultados de la normalización del largo para modelos que usan 15 y 30 [m] radiales en el mapeo.

La característica que tiene más relevancia estructural es el espesor. El dimensionamiento de un muro o una columna radica principalmente en su espesor. De la misma manera que con el largo, su normalización se basa en la relación entre el espesor de las predicciones asociadas y el espesor del rectángulo de ingeniería (No Asociado). La Figura 5.4 muestra que con 30 [m] de radio, se tiene que un 88.61% de los rectángulos predichos poseen una relación de 1 ± 0.1 (espesores muy parecidos). Para 15 [m], este porcentaje desciende a un 63.11%. Finalmente, se observa que, para ambos radios, menos del 1% de las predicciones poseen relaciones menores al 0.5 y mayores a 1.5 con su rectángulo de ingeniería.




Figura 5.4: Resultados de la normalización del espesor para modelos que usan 15 y 30 [m] radiales en el mapeo.

El mejor resultado en las predicciones es el ángulo. Esto se debe, a la restricción que utiliza **Asociación** de no agrupar elementos con una diferencia angular de más de 45° . La normalización se basa en la razón de la diferencia angular de las predicciones con el rectángulo asociado entre un ángulo arbitrario que en este caso fue de 90° . La Figura 5.5 muestra que para ambos radios, más del 90 % de las predicciones comparten un ángulo cercano al rectángulo de ingeniería que tienen asociados pudiendo tener una variación de $\pm 9^\circ$.




Figura 5.5: Resultados de la normalización del ángulo para modelos que usan 15 y 30 [m] radiales en el mapeo.

Las posiciones x e y son las características más importantes a nivel de precisión, ya son las coordenadas donde estarán ubicados los centros de los rectángulos. Para la normalización de estas características calculó la relación entre, la diferencia de las coordenadas x e y de los centros de masa de las predicciones y los rectángulos de ingeniería a los que fueron asociados, y 50 [m] que es el promedio de la máxima dimensión de los planos. Los resultados obtenidos de las posiciones se muestran en las Figuras 5.6 y 5.7.




Figura 5.6: Resultados de la normalización de la posición x para modelos que usan 15 y 30 [m] radiales en el mapeo.




Figura 5.7: Resultados de la normalización de la posición y para modelos que usan 15 y 30 [m] radiales en el mapeo.

La segunda métrica realiza normalizaciones entre los promedios de las características de las predicciones asociadas y los rectángulos No Asociados. La Figura 5.8 representa un plano de ingeniería, los rectángulos negros son los que están asociados con arquitectura, los rojos son los No Asociados, los verdes son las predicciones del modelo, los verdes dentro de las circunferencias, son asociaciones a los rectángulos rojos y los morados son el promedio de los verdes asociados.




Figura 5.8: Esquema de un plano de ingeniería con los rectángulos No Asociados, las predicciones asociadas y no asociadas; y el promedio de las predicciones asociadas.

Una vez identificados los rectángulos predichos que son asociados a un rectángulo No Asociado, mediante el promedio de las características geométricas de estas asociaciones, se genera un rectángulo predicho promedio (ver Figura 5.9).




Figura 5.9: Ejemplo: Rectángulo Predicho Promedio.

Esta métrica relaciona los rectángulos predichos promedios con los rectángulos No Asociados correspondientes para verificar si la agrupación de las predicciones confirma la precisión

de las características de las mismas. Las normalizaciones de los rectángulos promedios predichos se realizan igual que la de los rectángulos predichos asociados. A continuación, las Figuras 5.10, 5.11, 5.12, 5.13 y 5.14, muestran los resultados de la normalización de los rectángulos predichos asociados para el largo, espesor, ángulo y distancia (x, y) al centro de masa del piso, respectivamente.




Figura 5.10: Resultados de la normalización del largo promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.




Figura 5.11: Resultados de la normalización del espesor promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.




Figura 5.12: Resultados de la normalización del ángulo promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.




Figura 5.13: Resultados de la normalización de la distancia x promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.




Figura 5.14: Resultados de la normalización de la posición y promedio para modelos que usan 15 y 30 [m] radiales en el mapeo.

Se determina para cada piso, la diferencia entre el área total del promedio de las predicciones y el área total de los rectángulos No Asociados, luego estos valores son normalizados para $4 m^2$, que es aproximadamente, el promedio de las áreas No Asociadas de todos los pisos, de esta manera, se clasifican los pisos en grupos que presentan diferencias por metro cuadrado. La Figura 5.15 muestra los resultados de la normalización de área y el porcentaje de pisos a los que están asociada para ambos modelos, entre los resultados más importantes, tenemos que para el modelo final, cerca de un 79% de los pisos, su normalización se encuentra en el rango de 0 a 0.25, es decir, poseen una diferencia \pm de $1 m^2$ entre el promedio del área predicha y el área total del piso No Asociado. Para los siguientes rangos de la normalización, hasta alcanzar una relación de 1, el porcentaje disminuye a 9.72%, 5.79%, 1.39%. Finalmente, se agruparon los pisos con una normalización mayores a 1 y se alcanzó un porcentaje a 4.17%.




Figura 5.15: Normalización de áreas para modelos de 15 y 30 [m] radiales.

Las Figuras 5.16, 5.17 y 5.18 son ejemplos aleatorios de planos de ingeniería reales donde se sobreponen los rectángulos predichos obtenidos del modelo. Se representan mediante color negro, los rectángulos de ingeniera asociados a algún rectángulo en arquitectura, con color rojo los rectángulos de ingeniería No Asociados y con color verdes los rectángulos predichos. La Figura 5.16 muestra las predicciones para 2 pisos que poseen una relación de la normalización de áreas entre 0 y 0.25. En ambos casos se nota que las predicciones, si bien no son exactamente iguales a los rectángulos No Asociados, su representación gráfica es bastante cercana a lo que debería ser.

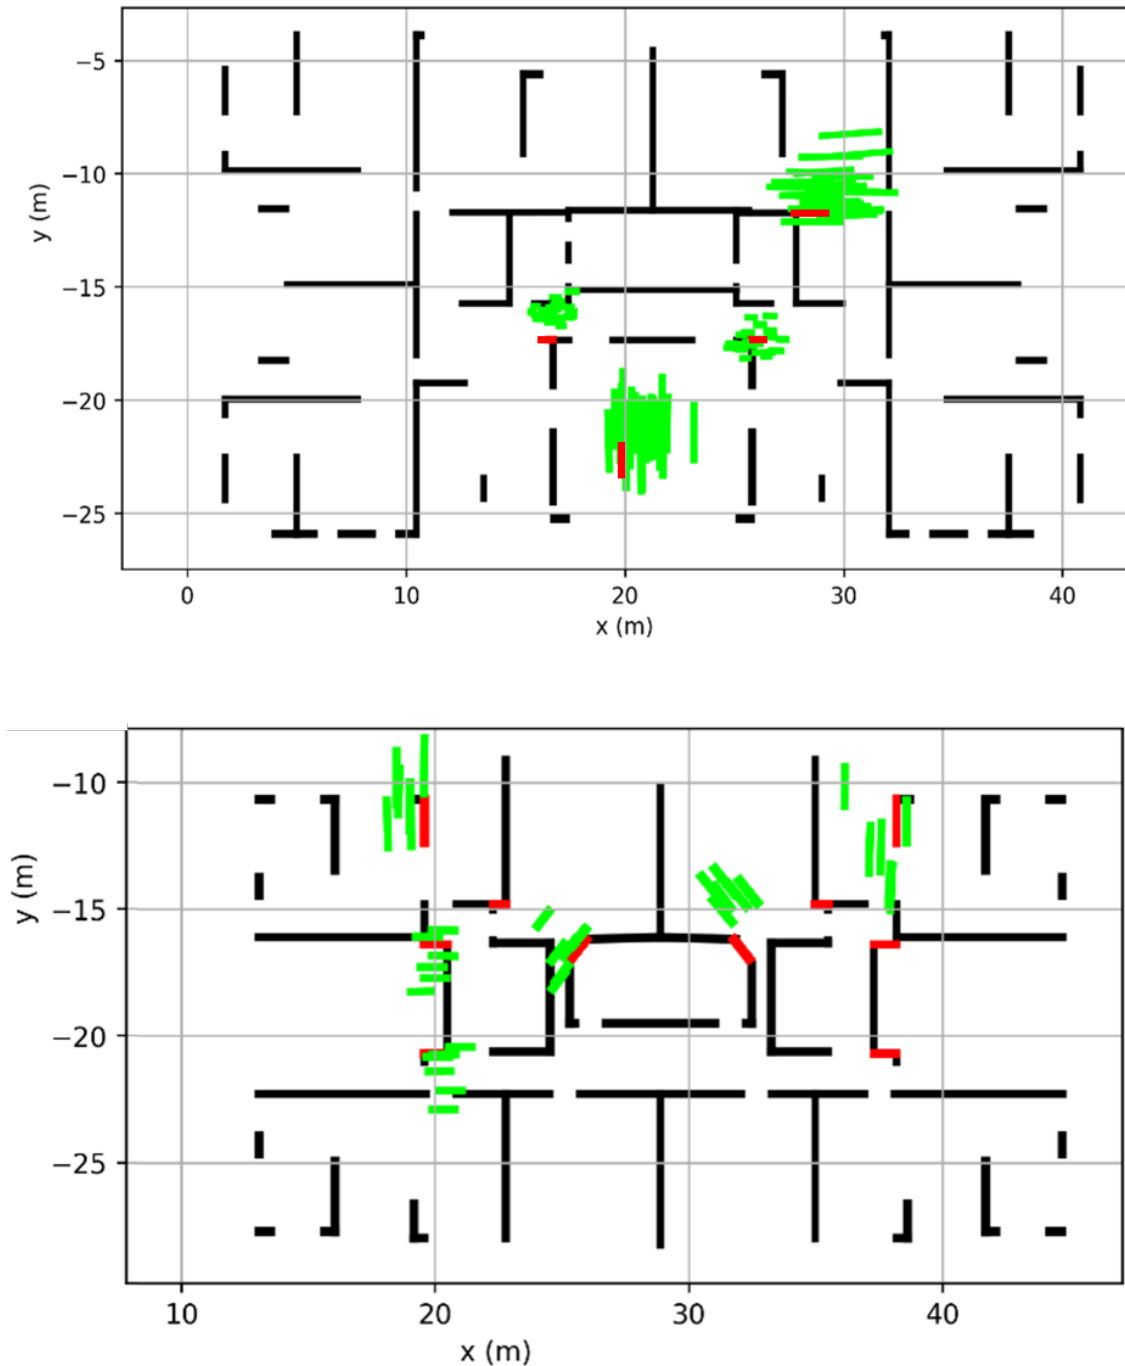


Figura 5.16: Ejemplo: Predicciones para pisos con normalización de área entre 0 y 0.25.

La Figura 5.17 muestra las predicciones para 2 pisos dentro de las normalizaciones de 0.25 y 0.75. Para estos casos notamos como la cantidad de rectángulos predichos no son lo suficiente para satisfacer el área de rectángulos No Asociados que requieren estas plantas, pero aun así, proponen soluciones ingenieriles aceptables.

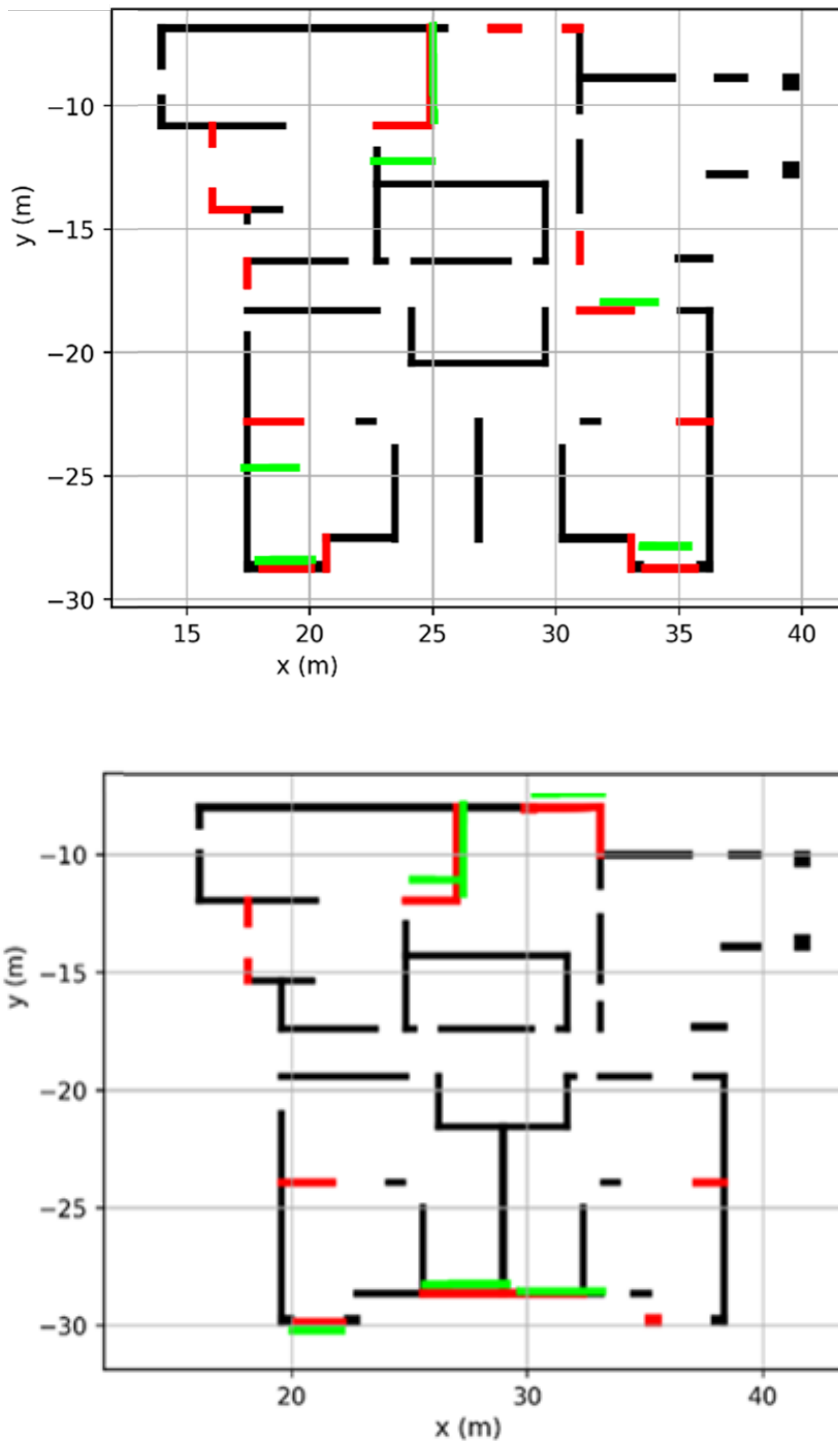


Figura 5.17: Ejemplo: Predicciones para pisos con normalización de área entre 0.25 y 0.75.

En la Figura 5.16 se muestran las predicciones de 2 pisos con normalizaciones mayores

a 0.75. Estos son los casos donde la cantidad de rectángulos predichos son extremadamente pocas en comparación con la demanda de rectángulos No Asociados (planta superior), o por el otro extremo, establece demasiados rectángulos a predecir (en forma de manchas muy grandes) (planta inferior), lo que hace difícil el tomar una decisión de colocar un rectángulo nuevo o carece de criterio para hacerlo.

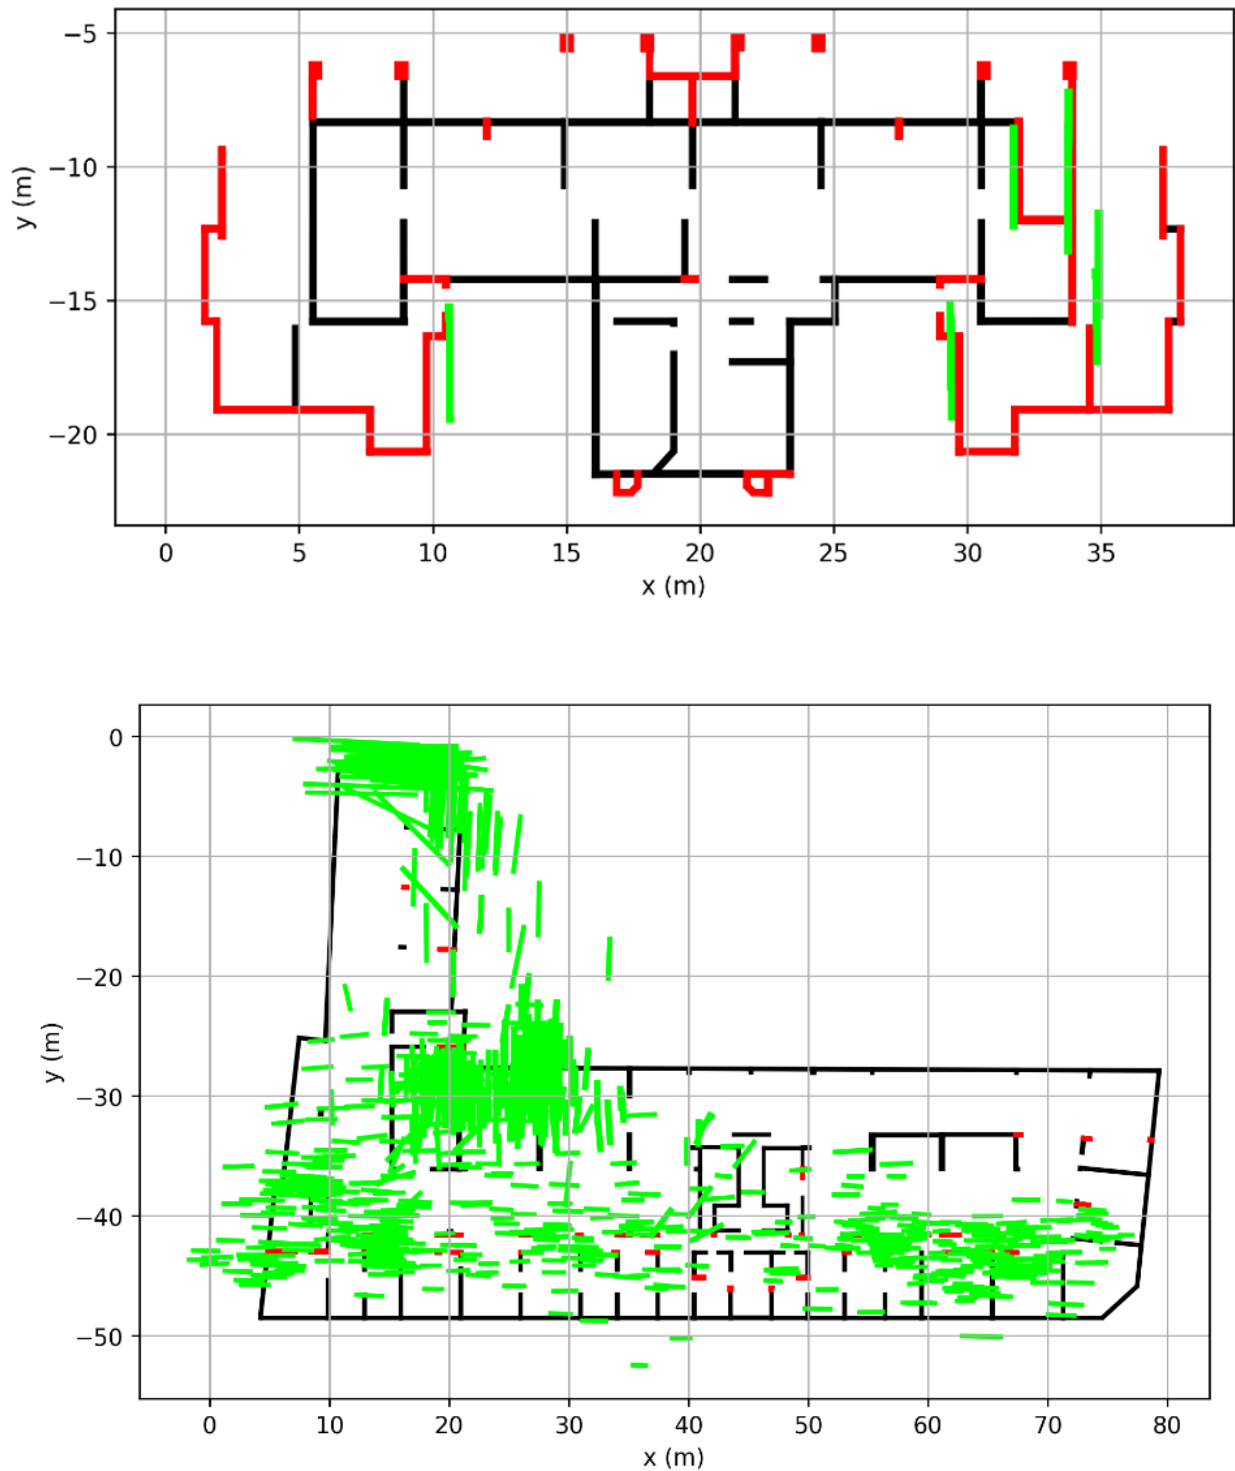


Figura 5.18: Ejemplo: Predicciones para pisos con normalización de área mayores a 0.75.

Finalmente, como las predicciones que entrega modelo pueden no estar siempre representadas como un solo rectángulos, sino también como un grupo disperso de rectángulos, se pueden emplear métodos de clusterizing para agrupar los rectángulos predichos y definir los rectángulos necesarios dentro de los planos de ingeniería final. Cuando se habla de clusterizar se hace una referencia a separar o categorizar a un grupo de objetos de acuerdo a características que tienen en común. La Figura 5.19, es el resultado de la clusterización de las predicciones de los pisos de la Figura 5.16. Aplicando un método de clusterización simple, se eliminan los grupos de predicciones (en caso de existir) permitiendo una mejor visualización mejorando la toma de decisión de colocar rectángulos o muros que no fue considerado en el diseño arquitectónico.

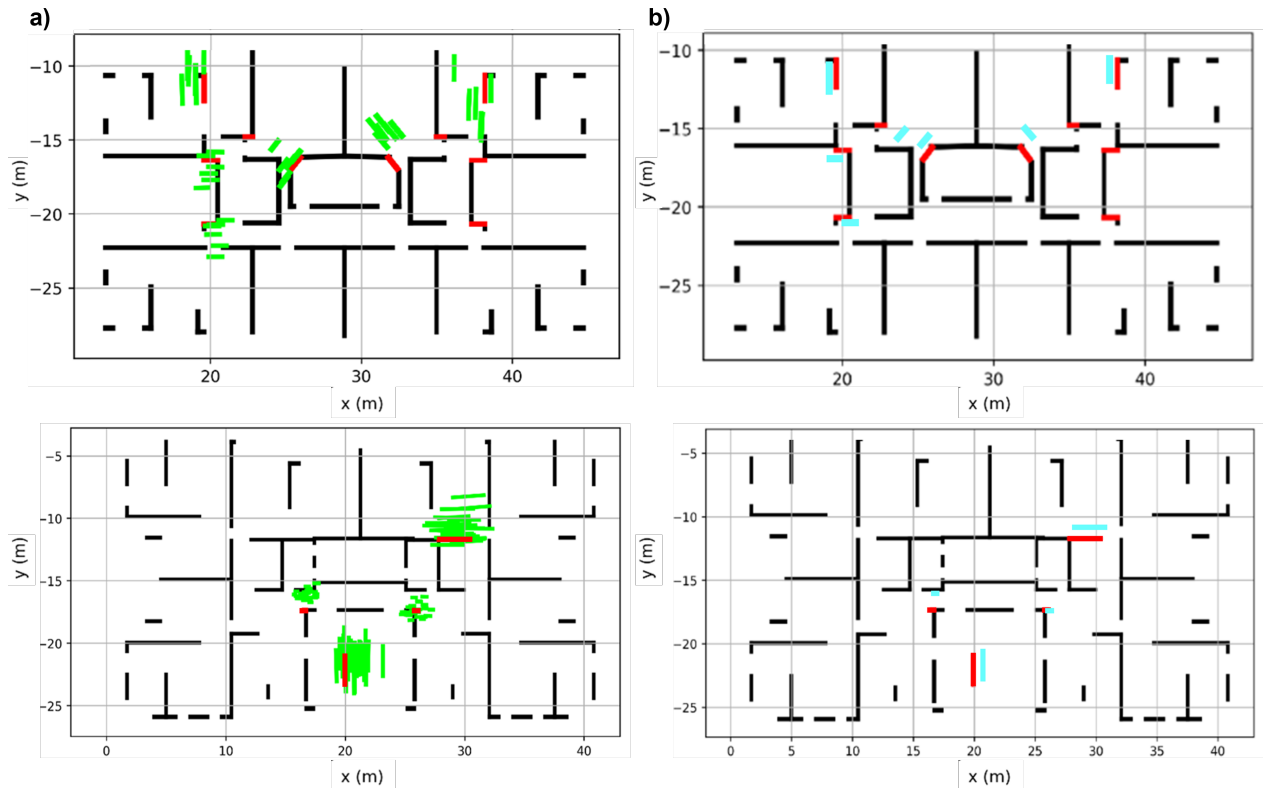


Figura 5.19: Ejemplo: a) Planos de ingeniería con las perdicciones superpuestas (rectángulos verdes). b) Planos de ingeniería con la clusterización de las perdicciones superpuestas (rectángulos turquesa).

Capítulo 6

Conclusiones

En la industria de la construcción chilena, los proyectos habitacionales requieren el conocimiento y la comprensión entre el diseño arquitectónico y el diseño estructural. La interacción entre ambas áreas genera una amplia cantidad de datos, que pueden ser usados en modelos de predicción y toma de decisiones. Es común que los planos arquitectónicos no consideren la ubicación de todos los muros estructurales necesarios para garantizar la estabilidad del edificio, por lo que, el modelo escogido permite relacionar de forma compleja vectores de entrada y la salida y proponer elementos nuevos de muros dentro de los planos estructurales.

Debido a los recientes estudios en el desarrollo de machine learning (ML) en el campo de la ingeniería estructural, se utilizó un algoritmo basado en redes neuronales artificiales (ANN). Se mejoró la función de asociación, agregando 1717 pares de rectángulos nuevos que son usados para la base de datos. Se creó la base de datos de 165 proyectos de edificios residenciales chileno que se enfocó en crear vecindades a partir de planos digitalizados de los proyectos, y para cada vecindad se calculó un total de 334 características numéricas, considerando propiedades geométricas y topológicas de los rectángulos dentro de estas. Las características alimentaron el modelo para predecir dimensión, orientación y ubicación de elementos de muros que no fueron considerado por arquitectura. Después de evaluar los resultados obtenidos por el modelo, se determinó que la mejor elección en términos de precisión para la predicción de los rectángulos de muros estructurales en las variables de entrada y salida fue de 33 y 6 rectángulos, respectivamente, junto con un radio de mapeo de 30 metros.

Con la metodología propuesta, la cantidad de datos utilizados para la predicción de nuevos rectángulos en ingeniería que usa el modelo ANN, es aproximadamente un 8% de los datos que usan el modelo CNN. La implementación del modelo obtuvo sobresalientes resultados en términos del coeficiente de determinación (R^2): 0.95 para el largo, 0.93 para el espesor, 0.94 para el ángulo y 0.96 para su posición (x,y). Además, cerca del 80% de los pisos posee una relación de área, calculada como la diferencia entre los rectángulos No Asociados y el promedio de las predicciones por piso sobre el área promedio de los rectángulos No Asociados para todos los pisos, entre 0 a 0.25. Lo que también quiere decir que para esos pisos las predicciones tienen un margen de error de $\pm 1 m^2$. Debido a que las predicciones del modelo generan grupos de rectángulos dentro de los planos, es posible aplicar técnicas de clusterización para agrupar dichos conjuntos. Esto permitirá al usuario una mejor identificación y selección de los muros estructurales nuevos.

Por último, aunque los resultados son satisfactorios, se puede mejorar el algoritmo. Se pueden agregar más datos o estudiar nuevos algoritmos para reducir los datos nulos y organizarlos mejor. Este modelo es aplicable a diferentes tipos de estructuras y no se limita a edificios chilenos. Investigaciones futuras permitirán crear herramientas que aceleren la interacción entre arquitectura e ingeniería, proporcionando soluciones de diseño en un tiempo más breve que los métodos actuales. Esto se convierte en una valiosa contribución al campo de la ingeniería y puede ser utilizada por profesionales competentes para mejorar la eficiencia de su trabajo.

Bibliografía

- [1] Shahin, M. A., “State-of-the-art review of some artificial intelligence applications in pile foundations,” *Annalen der Physik*, vol. 7, pp. 33–34, 2016, doi:<https://doi.org/10.1016/j.gsf.2014.10.002>.
- [2] Samuel, A. L., “Some studies in machine learning using the game of checkers,” *IBM Journal of Research and Development*, vol. 3, pp. 210–229, 1959, doi:<https://doi.org/10.1147/rd.441.0206>.
- [3] Siam, A., Ezzeldin, M., y El-Dakhakhni, W., “Machine learning algorithms for structural performance classifications and predictions: Application to reinforced masonry shear walls,” *Structures*, vol. 22, pp. 252–265, 2019, doi:<https://doi.org/10.1016/j.istruc.2019.06.017>.
- [4] Salehi, H. y Burgueño, R., “Emerging artificial intelligence methods in structural engineering,” *Engineering Structures*, vol. 171, pp. 170–189, 2018, doi:<https://doi.org/10.1016/j.engstruct.2018.05.084>.
- [5] National Institute of Standards and Technology (NIST), “Comparison of U.S. and Chilean Building Code Requirements and seismic design practice 1985–2010.” NIST GCR 12-917-18, 2012. <https://www.nasa.gov/nh/pluto-the-other-red-planet> (Visitado: 02-07-2021).
- [6] Massone, L. M., Bonelli, P., Lagos, R., Lüders, C., Moehle, J., y Wallace, J. W., “Seismic design and construction practices for r.c. structural wall buildings,” *Earthquake Spectra*, vol. 28, pp. 245–256, 2012, doi:<https://doi.org/10.1193/1.4000046>.
- [7] Yang, J., Jang, H., Kim, J., y Kim, J., “Semantic segmentation in architectural floor plans for detecting walls and doors,” en 2018 11th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), pp. 1–9, 2018, doi:[10.1109/CISP-BMEI.2018.8633243](https://doi.org/10.1109/CISP-BMEI.2018.8633243).
- [8] Pizarro, P. N. y Massone, L. M., “Structural design of reinforced concrete buildings based on deep neural networks,” *Engineering Structures*, vol. 241, 2021, doi:<https://doi.org/10.1016/j.engstruct.2021.112377>.
- [9] Pizarro, P. N., Massone, L. M., Rojas, F. R., y Ruiz, R. O., “Use of convolutional networks in the conceptual structural design of shear wall buildings layout,” *Engineering Structures*, vol. 239, 2021, doi:<https://doi.org/10.1016/j.engstruct.2021.112377>.
- [10] Alpaydin, E., *Introduction to Machine Learning*. 2014. <https://mitpress.mit.edu/books/introduction-machine-learning-third-edition> (Visitado: 02-07-2021).
- [11] Goodfellow, I., Bengio, Y., y Courville, A., *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org> (Visitado: 02-07-2021).

- [12] Liao, W., Lu, X., Huang, Y., Zheng, Z., y Lin, Y., “Automated structural design of shear wall residential buildings using generative adversarial networks,” *Automation in Construction*, vol. 132, p. 103931, 2021, doi:<https://doi.org/10.1016/j.autcon.2021.103931>.
- [13] Lu, X., Liao, W., Zhang, Y., y Huang, Y., “Intelligent structural design of shear wall residence using physics-enhanced generative adversarial networks,” *Earthquake Engineering Structural Dynamics*, vol. 51, pp. 1657–1676, 2022, doi:<https://doi.org/10.1002/eqe.3632>.
- [14] Málaga-Chuquitaype, C., “Machine learning in structural design: An opinionated review,” *Frontiers in Built Environment*, vol. 8, 2022, doi:[10.3389/fbuil.2022.815717](https://doi.org/10.3389/fbuil.2022.815717).
- [15] Amezquita-Sancheza, J., Valtierra-Rodriguez, M., y Adeli, H., “Machine learning in structural engineering,” *Scientia Iranica*, vol. 27, no. 6, pp. 2645–2656, 2020, doi:[10.24200/sci.2020.22091](https://doi.org/10.24200/sci.2020.22091).
- [16] Guozhong, C., Xuhong, Z., Jiepeng, L., y Lufeng, W., “Intelligent design method of high-rise shear wall structures based on deep reinforcement learning,” *Journal of Building Structures*, vol. 43, no. 9, p. 84, 2022, doi:[10.14006/j.jzjgxb.2022.0067](https://doi.org/10.14006/j.jzjgxb.2022.0067).
- [17] Fei, Y., Liao, W., Huang, Y., y Lu, X., “Knowledge-enhanced generative adversarial networks for schematic design of framed tube structures,” *Automation in Construction*, vol. 144, p. 104619, 2022, doi:<https://doi.org/10.1016/j.autcon.2022.104619>.
- [18] Zhao, P., Liao, W., Xue, H., y Lu, X., “Intelligent design method for beam and slab of shear wall structure based on deep learning,” *Journal of Building Engineering*, vol. 57, p. 104838, 2022, doi:<https://doi.org/10.1016/j.jobbe.2022.104838>.
- [19] Liao, W., Huang, Y., Zheng, Z., y Lu, X., “Intelligent generative structural design method for shear wall building based on “fused-text-image-to-image” generative adversarial networks,” *Expert Systems with Applications*, vol. 210, p. 118530, 2022, doi:<https://doi.org/10.1016/j.eswa.2022.118530>.
- [20] D’Amico, B., Myers, R., Sykes, J., Voss, E., Cousins-Jenvey, B., Fawcett, W., Richardson, S., Kermani, A., y Pomponi, F., “Machine learning for sustainable structures: A call for data,” *Structures*, vol. 19, pp. 1–4, 2019, doi:<https://doi.org/10.1016/j.istruc.2018.11.013>.
- [21] Kanyilmaz, A., Tichell, P. R. N., y Loiacono, D., “A genetic algorithm tool for conceptual structural design with cost and embodied carbon optimization,” *Engineering Applications of Artificial Intelligence*, vol. 112, p. 104711, 2022, doi:<https://doi.org/10.1016/j.engappai.2022.104711>.
- [22] Lukas, F., Vahid, M., Ole, O. P., y Pierluigi, D., “Data-driven design: Exploring new structural forms using machine learning and graphic statics,” 2018.
- [23] Danhaive, R. y Mueller, C. T., “Design subspace learning: Structural design space exploration using performance-conditioned generative modeling,” *Automation in Construction*, vol. 127, p. 103664, 2021, doi:<https://doi.org/10.1016/j.autcon.2021.103664>.
- [24] Zheng, H., Moosavi, V., y Akbarzadeh, M., “Machine learning assisted evaluations in structural design and construction,” *Automation in Construction*, vol. 119, p. 103346, 2020, doi:<https://doi.org/10.1016/j.autcon.2020.103346>.
- [25] Pizarro, P. N., “Conceptual structural design of shear wall buildings layout based on

artificial neural networks,” 2021.

- [26] He, Z., Xie, L., Chen, X., Zhang, Y., Wang, Y., y Tian, Q., “Data augmentation revisited: Rethinking the distribution gap between clean and augmented data,” CoRR, vol. abs/1909.09148, 2019, <http://arxiv.org/abs/1909.09148>.
- [27] Tran-Ngoc, H., Khatir, S., De Roeck, G., Bui-Tien, T., y Abdel Wahab, M., “An efficient artificial neural network for damage detection in bridges and beam-like structures by improving training parameters using cuckoo search algorithm,” Engineering Structures, vol. 199, p. 109637, 2019, [doi:https://doi.org/10.1016/j.engstruct.2019.109637](https://doi.org/10.1016/j.engstruct.2019.109637).