

ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE INGENIERÍA DE SISTEMAS

MODELOS BASADOS EN INTELIGENCIA ARTIFICIAL PARA EL
DISEÑO DE ESTRUCTURAS NO CONVENCIONALES DE
HORMIGÓN ARMADO

PROYECTO PREVIO A LA OBTENCIÓN DEL TÍTULO DE
INGENIERO EN SISTEMAS INFORMÁTICOS Y DE
COMPUTACIÓN

CARLOS FABIÁN ÁVILA VEGA
cavila67@caltech.edu

Director: CARLOS ESTALISMET MONTENEGRO ARMAS
carlos.montenegro@epn.edu.ec

QUITO, 26 DE AGOSTO DE 2013

DECLARACIÓN

Yo CARLOS FABIÁN ÁVILA VEGA, declaro bajo juramento que el trabajo aquí escrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional en el país; y que he consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración cedo mis derechos de propiedad intelectual, correspondientes a este trabajo, a la Escuela Politécnica Nacional, según lo establecido por la Ley de Propiedad Intelectual, por su reglamento y por la normatividad institucional vigente.

CARLOS FABIÁN ÁVILA VEGA

CERTIFICACIÓN

Certifico que el presente trabajo fue desarrollado por CARLOS FABIÁN ÁVILA VEGA, bajo mi supervisión

CARLOS ESTALISNET MONTENEGRO ARMAS
Director del Proyecto

AGRADECIMIENTOS

A todas las personas que generosamente revisaron y aportaron en este trabajo.

DEDICATORIA

A Santiago, y Cecilia.

Carlos

Índice de contenido

| | |
|--|----------|
| Índice de figuras | vi |
| Índice de cuadros | vii |
| Resumen | viii |
| Abstract | xii |
| 1 INTRODUCCIÓN | 1 |
| 1.1 JUSTIFICACIÓN | 1 |
| 1.2 OBJETIVOS | 4 |
| 1.2.1 Objetivo General | 4 |
| 1.2.2 Objetivos Específicos | 4 |
| 1.3 ALCANCES | 5 |
| 1.4 METODOLOGÍA | 5 |
| 1.4.1 Actividad 1: Recolección de datos experimentales | 5 |
| 1.4.2 Actividad 2: Clasificación estadística de datos experimentales . . | 5 |
| 1.4.3 Actividad 3: Identificar parámetros físicos relevantes para mode- lar el problema | 5 |
| 1.4.4 Actividad 4: Indentificar un modelo de red neuronal | 6 |
| 1.4.5 Actividad 5: Validar y verificar resultados | 6 |
| 2 HORMIGÓN REFORZADO | 7 |
| 2.1 INTRODUCCIÓN | 7 |
| 2.2 MARCO TEORICO | 8 |
| 2.2.1 Generalidades | 8 |
| 2.3 VIGAS CONVENCIONALES | 9 |
| 2.3.1 Descripción | 9 |
| 2.3.2 Diseño Basado en Resistencia | 9 |
| 2.3.3 Diseño a Flexión | 10 |
| 2.3.4 Control de agrietamiento | 12 |

| | | |
|----------|--|-----------|
| 2.4 | VIGAS NO CONVENCIONALES | 15 |
| 2.4.1 | Generalidades | 15 |
| 2.4.2 | Planteamiento del problema y motivación | 16 |
| 2.4.3 | Descripción de las vigas en estudio | 18 |
| 2.5 | PROGRAMA EXPERIMENTAL | 26 |
| 2.5.1 | Objetivos específicos del programa experimental | 26 |
| 2.5.2 | Variables experimentales | 26 |
| 2.5.3 | Adquisición de datos | 27 |
| 2.6 | PROPIEDADES DE LOS MATERIALES | 29 |
| 2.6.1 | Concreto | 29 |
| 2.6.2 | Refuerzo principal | 29 |
| 2.6.3 | Barras de anclaje | 30 |
| 2.6.4 | Conectores mecánicos y tuercas de fijación | 30 |
| 2.6.5 | El sistema de conexión | 31 |
| 2.7 | RESULTADOS EXPERIMENTALES | 32 |
| 3 | MODELAMIENTO DEL CASO CON REDES NEURONALES | 37 |
| 3.1 | GENERALIDADES | 37 |
| 3.1.1 | Introducción y Motivación | 37 |
| 3.1.2 | Redes neuronales artificiales | 39 |
| 3.1.3 | Procesos de aprendizaje | 42 |
| 3.1.4 | Algoritmos de aprendizaje | 42 |
| 3.1.5 | Objetivos específicos | 44 |
| 3.1.6 | Problemas en estudio | 44 |
| 3.1.7 | Estrategia de solución | 45 |
| 3.1.8 | Características de los modelos propuestos | 46 |
| 3.2 | MODELAMIENTO BASADO EN REDES NEURONALES | 46 |
| 3.2.1 | Metodología | 46 |
| 3.2.2 | Análisis estadístico de los datos experimentales | 47 |
| 3.2.3 | Diseño de vectores de entrada y salida | 47 |
| 3.2.4 | Resumen de datos experimentales | 50 |
| 3.2.5 | Vectores de entrada y salida | 50 |
| 4 | ANALISIS DE RESULTADOS | 57 |
| 4.1 | PROCESAMIENTO DE DATOS | 57 |
| 4.2 | AQUITECTURA DE RED NEURONAL | 57 |
| 4.3 | TOPOLOGIA DE LA RED | 59 |
| 4.4 | MODELOS NEURONALES PARA FLEXIÓN | 60 |
| 4.4.1 | Capacidad última | 60 |

| | | |
|----------|---|-----------|
| 4.4.2 | Diseño a flexión | 61 |
| 4.5 | MODELOS NEURONALES PARA EL ANCHO DE GRIETA | 63 |
| 4.5.1 | Ancho de grieta 200 MPa | 63 |
| 4.5.2 | Ancho de grieta 300 MPa | 64 |
| 4.6 | RESULTADOS | 66 |
| 4.6.1 | Capacidad última | 66 |
| 4.6.2 | Diseño a flexión | 68 |
| 4.6.3 | Ancho de grieta 200 MPa | 68 |
| 4.6.4 | Ancho de grieta 300 MPa | 68 |
| 4.6.5 | Discusión | 70 |
| 5 | CONCLUSIONES Y RECOMENDACIONES | 76 |
| 5.1 | CONCLUSIONES | 76 |
| 5.2 | RECOMENDACIONES | 82 |
| | BIBLIOGRAFÍA | 86 |
| | APÉNDICE | |
| | DESCRIPCIÓN DE LA HERRAMIENTA | 89 |
| A | Introducción | 89 |
| B | Construcción del modelo de red neuronal | 89 |
| B1 | Selección del modelo de red neuronal | 89 |
| B2 | Selección del grupo de datos para entrenamiento | 89 |
| B3 | Selección del grupo de datos para validación cruzada y prueba . | 91 |
| B4 | Configuración de la topología del PERCEPTRON | 92 |
| B5 | Definición del número de neuronas internas | 92 |
| B6 | Datos experimentales | 94 |
| B7 | Resultados del proceso de validación | 94 |

Índice de figuras

| | | |
|------|--|----|
| 1 | Comparación de resultados obtenidos para la predicción de ancho de grieta en el ciclo de 300 MPa en vigas con conexiones. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error. | xi |
| 2.1 | Distribución de esfuerzos y deformaciones para la carga última | 10 |
| 2.2 | Estructura construida en base a elementos pre-fabricados unidos con conectores mecánicos. | 17 |
| 2.3 | Vigas Pre-fabricada tipo: Vista 3D. | 19 |
| 2.4 | Vigas Pre-frabricada tipo: Sección Transversal. | 19 |
| 2.5 | Vigas Pre-frabricada tipo: Sección Transversal. | 19 |
| 2.6 | Vigas Pre-frabricada tipo: Detalle del Conector. | 19 |
| 2.7 | Vigas Pre-fabricadas: Distribución de Acero de refuerzo y Sistemas de Anclaje. | 27 |
| 2.8 | Vigas Pre-fabricadas: Puntos de carga, condiciones de soporte y medidores de deformaciones. | 28 |
| 2.9 | Esquema de una barra de anclaje tipo | 30 |
| 2.10 | Esquema del sistema de conexión. | 32 |
| 3.1 | Arquitectura y Topología típica de un modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error . . . | 40 |
| 3.2 | Esquema que muestra el funcionamiento de una neurona | 40 |
| 4.1 | Arquitectura y Topología típica de un modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error . . . | 58 |
| 4.2 | Determinación del número de neuronas óptimo en la capa interna de la red neuronal. El valor máximo del coeficiente de correlación está asociado con el número de neuronas requerido para alcanzar ese valor pico de rendimiento. | 60 |

| | | |
|------|--|----|
| 4.3 | Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para la predicción la capacidad última a flexión de vigas no convencionales. | 61 |
| 4.4 | Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para la predicción la capacidad última a flexión de vigas no convencionales. | 62 |
| 4.5 | Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para el diseño a flexión de vigas no convencionales. | 62 |
| 4.6 | Modelo de red neuronal con entrenamiento basado en algoritmos genéticos para el diseño a flexión de vigas no convencionales. | 63 |
| 4.7 | Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para la predicción del ancho máximo de grieta en el ciclo de 200 MPa. | 64 |
| 4.8 | Modelo de red neuronal con entrenamiento basado en el algoritmos genéticos para la predicción del ancho máximo de grieta en el ciclo de 200 MPa. | 65 |
| 4.9 | Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para la predicción del ancho máximo de grieta en el ciclo de 300 MPa. | 65 |
| 4.10 | Modelo de red neuronal con entrenamiento basado en el algoritmos genéticos para la predicción del ancho máximo de grieta en el ciclo de 300 MPa. | 66 |
| 4.11 | Comparación de resultados obtenidos para el momento último. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error. | 67 |
| 4.12 | Comparación de resultados obtenidos para el diseño de las vigas con conexiones. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error. . . | 69 |
| 4.13 | Comparación de resultados obtenidos para la predicción de ancho de grieta en el ciclo de 200 MPa en vigas con conexiones. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error. | 70 |

| | | |
|------|--|----|
| 4.14 | Comparación de resultados obtenidos para la predicción de ancho de grieta en el ciclo de 300 MPa en vigas con conexiones. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error. | 71 |
| A1 | Neurosolutions for Excel | 90 |
| B1 | Selección de datos de entrenamiento | 90 |
| B2 | Selección del Modelo de Red Neuronal | 91 |
| B3 | Selección de datos para prueba | 92 |
| B4 | Configuración de la topología de red | 93 |
| B5 | Selección de parámetros de aprendizaje | 93 |
| B6 | Datos experimentales aleatoriamente dispuestos y división entre el set de entrenamiento y validación | 95 |
| B7 | Resultados del proceso de validación | 96 |
| B8 | Resultados de la convergencia del proceso de entrenamiento | 97 |

Indice de tablas

| | | |
|------|---|----|
| 2.1 | Descripción de la geometría de las vigas | 20 |
| 2.2 | SERIE I y II : Profundidad efectiva de las barras de anclaje d y d' | 21 |
| 2.3 | SERIE I: Configuración de refuerzo en tensión y compresión | 22 |
| 2.4 | SERIE I: Configuración de anclajes en tensión y compresión | 23 |
| 2.5 | SERIE II: Configuración de refuerzo en tensión y compresión | 24 |
| 2.6 | SERIE II: Configuración de anclajes en tensión y compresión | 25 |
| 2.7 | Diseño del hormigón Proporciones de mezcla y propiedades | 29 |
| 2.8 | Dimensiones de las barras de anclaje | 31 |
| 2.9 | Propiedades mecánicas de las barras de anclaje y refuerzo | 31 |
| 2.10 | Propiedades mecánicas del sistema Anclajes-Conector Mecánico | 31 |
| 2.11 | RESULTADOS: SERIE 1 | 33 |
| 2.12 | RESULTADOS: SERIE 1 | 34 |
| 2.13 | RESULTADOS: SERIE II | 35 |
| 2.14 | RESULTADOS: SERIE II | 36 |
| 3.1 | Geometría y refuerzo en vigas de la SERIE-I | 51 |
| 3.2 | Geometría y refuerzo en vigas de la SERIE-II | 52 |
| 3.3 | SERIE - I Vectores de entrada y salida | 53 |
| 3.4 | SERIE - I Vectores de entrada y salida | 54 |
| 3.5 | Serie II - Vectores de Entrada y Salida - Flexión | 55 |
| 3.6 | Serie II - Vectores de entrada y salida - Agrietamiento | 56 |
| 4.1 | Número de neuronas por capa | 59 |
| 4.2 | Predicción del Momento Último | 67 |
| 4.3 | Diseño de vigas | 68 |
| 4.4 | Predicción ancho de grieta 200 MPa | 69 |
| 4.5 | Predicción ancho de grieta 300 MPa | 69 |

Resumen

En este proyecto de titulación se proponen modelos basados en una combinación de: (1) ecuaciones usadas en el análisis y diseño de vigas convencionales de hormigón armado y (2) redes neuronales artificiales, para la predicción de parámetros estructurales que permiten diseñar y analizar vigas cuya geometría, configuración de refuerzo, y condiciones de contorno no son aquellas para las cuales las ecuaciones disponibles en códigos de construcción fueron diseñadas.

Este nuevo esquema de diseño ofrece al ingeniero estructural las siguientes ventajas:

- 1 Elementos de hormigón reforzado no considerados en los códigos de construcción pueden ser analizados y diseñados.
- 2 Elementos de hormigón reforzado bajo condiciones de borde diferentes a las impuestas en la fase experimental en base a la cual se derivan ecuaciones de diseño disponibles en textos y códigos de construcción pueden ser estudiados.
- 3 Las características no lineales de la respuesta constitutiva del hormigón pueden ser consideradas implícitamente durante el proceso de entrenamiento de la red.

Estudios previos muestran aplicaciones de RNA en el campo de la ingeniería civil, por ejemplo: Adeli (1995), Goh (1995), Kunieda (1996), Arahaki (1998), Takeda (1998), Basma (1999) y Oh (1999). Sin embargo, la literatura disponible no muestra aplicaciones de redes neuronales artificiales en la predicción del agrietamiento en estructuras de hormigón reforzado, y menos aún aplicaciones orientadas al análisis y diseño de estructuras no-convencionales. Este hecho motiva y justifica plenamente la propuesta de esta investigación, y se prevee un impacto en la comunidad de ingenieros estructurales que trabajan en el desarrollo de nuevos tipos de elementos estructurales y en especial en el estudio de la durabilidad de este tipo de elementos en ambientes agresivos.

Por simplicidad y por su capacidad predictiva [12], la arquitectura de red neuronal adoptada en este estudio es la denominada como PERCEPTRON . La topología de esta red consiste de una capa de entrada, una capa oculta o intermedia, y una capa

de salida. El número de neuronas en la capa intermedia fue determinado en base a un proceso simple, en el que se evaluó el coeficiente de correlación que mide la distancia, norma, entre la salida deseada y la obtenida por el modelo cuando se varía el número de neuronas de la capa interna.

El diseño de los vectores de entrada y salida de la red se enriquece de ecuaciones disponibles en los códigos de diseño de estructuras de hormigón armado y toma en cuenta parámetros físicos que caracterizan la respuesta estructural de las nuevas vigas.

Durante el proceso de aprendizaje de las redes planteadas para cada uno de los casos en estudio, se proponen dos tipos diferentes de algoritmos, el primero es el método de retro-propagación y el segundo está basado en algoritmos genéticos. Estos algoritmos tienen en común el hecho de plantear estrategias de búsqueda en el espacio multi-dimensional de la función de error. La diferencia radica en que el algoritmo genético, en base a una estrategia de búsqueda-optimización aleatoria, evita una respuesta que refleje mínimos locales. El algoritmo de retro-propagación, basado en gradientes, puede incurrir en errores al reflejar un mínimo local de la función de error.

Los resultados obtenidos de los 4 modelos propuestos en este estudio muestran coeficientes de correlación, con respecto a las respuestas experimentales, que varían entre 0.98 y 0.998. Estos resultados destacan el potencial predictivo de la propuesta, en especial si se toma en cuenta el alto nivel de no-linealidad del fenómeno físico en estudio. La estrategia de modelamiento propuesta en este estudio, ha decir por los resultados obtenidos, tiene el potencial de constituirse en una alternativa de solución a problemas altamente no-lineales relacionados con el análisis y diseño de estructuras de hormigón armado - pre-fabricadas, pre y post tensadas, fabricadas in-situ, etc. - con configuraciones y geometría diferentes a aquellas establecidas en los códigos de construcción.

CASOS DE ESTUDIO

CASO I: Predicción de la capacidad última

La red neuronal en la que se implementa un algoritmo de retro-propagación de error, como estrategia de aprendizaje, requiere de 12 neuronas en la capa oculta. Este valor se determina de acuerdo al procedimiento descrito anteriormente y permite obtener un coeficiente de correlación máximo de 0.991. La contraparte, esto es, el modelo entrenado en base a algoritmos genéticos, requiere de 84 neuronas en la capa interna para alcanzar un coeficiente de correlación de 0.998.

CASO II: Diseño a flexión

Igual número de neuronas en la capa interna son requeridos para alcanzar el mayor coeficiente de correlación en los modelos de redes neuronales planteados para el diseño a flexión de las vigas con conexiones. Con 12 neuronas en la capa interna, el modelo entrenado en base al algoritmo de retro-propagación produce resultados, que evaluados en comparación a la respuesta experimental esperada, muestran una correlación de 0.994. El modelo entrenado con algoritmos genéticos genera un coeficiente de correlación de 0.997 en base a 12 neuronas en la capa interna.

Se usaron 30000 iteraciones en cada uno de los modelos como criterio de extensión del proceso de aprendizaje. En el caso del entrenamiento basado en retro-propagación de error se emplearon 12 segundos, mientras que su contraparte, el entrenamiento basado en algoritmos genéticos empleo 16 segundos en un procesador Core 2 Duo, 2.66 MHz.

CASO III: Ancho de grieta

El proceso de agrietamiento del hormigón es altamente no-lineal. Su predicción por métodos tradicionales es una tarea compleja, y las ecuaciones disponibles actualmente se basan en la experimentación. Este empirismo limita la aplicabilidad de las ecuaciones así generadas a ciertos criterios, configuraciones y condiciones de borde. Las ecuaciones disponibles en la literatura no son aplicables en el caso de las vigas con conexiones que se estudian en este trabajo, pues su geometría, configuración y características especiales de refuerzo no son aquellas bajo las cuales dichas ecuaciones fueron generadas.

Ciclo de 200 MPa.

El ciclo de 200 MPa corresponde a un estado de esfuerzos en el que el acero en su totalidad trabaja en el rango elástico. De cierto modo esto se ve reflejado en el hecho de que el número de neuronas requerido, en el modelo que usa retro-propagación del error como estrategia de aprendizaje de la red, es menor que en el siguiente caso de estudio, esto es el ciclo de 300 MPa en donde la respuesta de la estructura es enteramente no-lineal. El número de neuronas en la capa interna del modelo que implementa retro-propagación es 12 en contraparte del modelo entrenado con algoritmos genéticos que requiere de 80 neuronas para alcanzar su máximo rendimiento en términos de la aproximación cuantificada como función del coeficiente de correlación entre respuesta del modelo y respuesta esperada.

Usando un computador con procesador Core 2 Duo, 2.66 MHz se ejecutaron 30000 iteraciones en 14 segundos para entrenar la red en base al algoritmo de retro-propagación de error.

En el caso de entrenamiento de la red con algoritmos genéticos se obtuvo la mejor población de pesos de conexiones (entrenamiento) en 29000 iteraciones. El tiempo de procesamiento fue de 41 segundos, lo cual como se puede ver excede al tiempo requerido

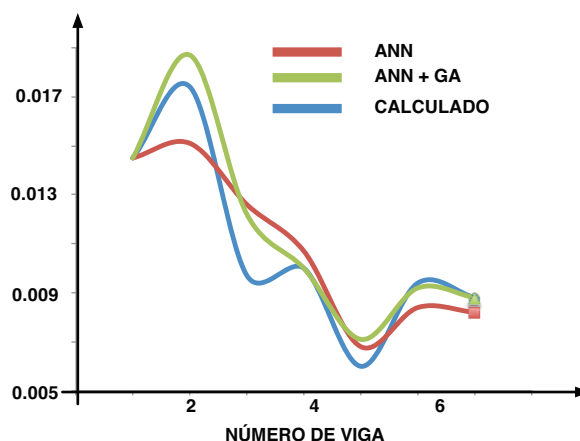


Figura 1: Comparación de resultados obtenidos para la predicción de ancho de grieta en el ciclo de 300 MPa en vigas con conexiones. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error.

por el algoritmo de retro-propagación, pero redundante en una mejor aproximación en los valores de ancho de grieta. Si tomamos en cuenta la no-linealidad involucrada en este fenómeno y los tiempos cortos de procesamiento podemos argumentar la efectividad de la metodología propuesta para la solución de este problema.

Ciclo de 300 MPa.

En el caso de entrenamiento basado en retro-propagación de error, se emplearon 30000 iteraciones para ajustar los pesos de las conexiones entre neuronas. El proceso de entrenamiento tomó 13 segundos en un procesador Core 2 Duo, 2.66 MHz.

La contraparte, esto es, el modelo de red neuronal entrenado en base a algoritmos genéticos requirió de 30000 iteraciones igualmente, con la diferencia de que el proceso de entrenamiento tomó 50 segundos.

El mayor número de neuronas requerido por los modelos planteados para la predicción de grietas, en un estado de esfuerzos en el que el acero se comporta plásticamente alcanzando los 300MPa en tensión, es a decir por los resultados, consecuencia de alto nivel de no-linealidad presente en el fenómeno en estudio.

El coeficiente de correlación en el caso del modelo entrenado en base a retro-propagación de error fue 0.948, mientras que en el caso en el que se usó algoritmos genéticos fue de 0.971. El incremento de tiempo de procesamiento en el segundo caso queda justificado por la mayor precisión obtenida en el modelo.

Abstract

The main contribution of this work is the proposal of Artificial Neural Networks (ANN) based models for:

- (1) The prediction of the maximum surface crack width,
- (2) The prediction of the ultimate bending moment capacity of the beams,
- (3) The flexural design of the new elements

of a new type of precast reinforced concrete beams joined by steel coupler connectors and anchor bars (jointed beams).

Available code equations do not allow to evaluate structural parameters when the geometry and configuration of new structural elements do not fit specific boundary conditions. This is the case of the new type of precast reinforced concrete beams targeted in this study.

In order to overcome those limitations, a simple one hidden layer perceptron architecture is combined with available equations to generate a ANN based model that allows, not only, to predict several parameters that characterize the mechanical response of the beams, but also to propose a design methodology for new type of reinforced concrete structures.

The number of neurons in the hidden layer of the ANN models was determined on the basis of a trial and error procedure that evaluated a correlation coefficient between expected response from the models and the actual output.

Two different training algorithms are used in this study and their performances are compared. The first approach used Back propagation (BP) and the second one includes Genetic Algorithms (GA) during the training process. Input and output vectors are designed on the basis of:

- (1) Empirical and theoretical equations available in the literature for the design of conventional reinforced concrete (RC) structures, and
- (2) Structural parameters that characterize the mechanical behavior of this new type of RC beams.

The surface crack width is predicted for two well-defined state of stresses. The first point corresponds to a quasi-linear state of stresses and the second point is in a highly nonlinear stage of the mechanical response of the beams.

Remarkable results were obtained, however, in all cases the combined Genetic Artificial Neural Network approach resulted in improved prediction performance over networks trained by error back propagation.

Capítulo 1

INTRODUCCIÓN

1.1 JUSTIFICACIÓN

Este trabajo propone, como contribución fundamental, modelos basados en redes neuronales para:

- 1 la evaluación de la capacidad última a flexión,
- 2 el diseño a flexión, y
- 3 la predicción del ancho máximo de grietas superficiales

en vigas prefabricadas de hormigón reforzado unidas con conectores mecánicos.

La meta que se persigue con este trabajo es proveer, a la comunidad de diseñadores estructurales, una herramienta que permita, con cierto nivel de simplicidad, el análisis y diseño por resistencia y servicialidad de estructuras de hormigón reforzado. El hormigón, como la mayoría de geo-materiales, presenta respuestas constitutivas altamente no-lineales, lo cual se refleja en la dificultad por describir determinísticamente su comportamiento. Como consecuencia, la formulación de esquemas de análisis y diseño es una tarea compleja que ha tenido que manejarse en base a extensa experimentación y abstracción del fenómeno físico. Estas condiciones imponen un sinnúmero de restricciones a la aplicabilidad de estos esquemas de análisis y diseño, en especial, cuando las condiciones de contorno (cargas, geometría y/o configuración de refuerzo en los elementos estructurales) difieren de aquellas bajo las cuales se definió la fase experimental.

Las normativas de diseño y construcción en hormigón reforzado vigentes tanto en Ecuador [9] como internacionalmente [1], [16] ofrecen formulaciones y esquemas de análisis y diseño válidos únicamente para ciertos tipos de elementos estructurales que,

el en contexto de este trabajo, se denominarán como elementos o estructuras convencionales (EC).

Su contraparte, las estructuras no convencionales (ENC), no se ajustan a las condiciones de frontera bajo las cuales los códigos de construcción fueron propuestos, y por tanto, las hipótesis bajo las cuales los criterios de análisis y diseño son desarrollados no son aplicables.

El objetivo de este proyecto de titulación es proponer una metodología de trabajo basada en redes neuronales que supla esta deficiencia y brinde al ingeniero estructural una herramienta de diseño y desarrollo de nuevos tipos de elementos estructurales, o en otras palabras, estructuras que no se ajustan a los planteamientos en base a los cuales se establece la normativa existente para la construcción y diseño de estructuras de hormigón reforzado.

El alcanzar este objetivo tendrá un impacto positivo en la industria de la construcción en hormigón reforzado. La metodología propuesta permitirá aproximar a un fenómeno altamente no-lineal, en base a modelos simples basados en redes neuronales. Las ventajas de este nuevo esquema de diseño se pueden resumir como sigue:

- 1** Permite diseñar elementos de hormigón reforzado no considerados en los códigos de construcción
- 2** Permite diseñar elementos de hormigón reforzado bajo condiciones de borde diferentes a las impuestas en la fase experimental en base a la cual se derivan ecuaciones de diseño disponibles en textos y códigos de construcción.
- 3** Permite considerar implícitamente las características no lineales de la respuesta constitutiva del hormigón.

En el caso de las estructuras prefabricadas de hormigón que son parte de este estudio, se requiere adicionalmente al acero de refuerzo convencional, de conectores mecánicos (macho-hembra) para su ensamble y montaje en el sitio de construcción. En términos de diseño estas conexiones añaden complejidad al problema, pues dependen de elementos de anclaje cuyo comportamiento encierra mecanismos de respuesta no considerados en el diseño de vigas convencionales [15] . Por otro lado y pese a los esfuerzos de múltiples grupos de investigación, la respuesta constitutiva de geomateriales, como el hormigón, no es completamente entendida y menos lo es cuando a esa complejidad se incluye la interacción con el acero de refuerzo y barras de anclaje.

En el Ecuador existe un creciente interés por el desarrollo de productos y tecnologías alternativas de vivienda e infraestructura. Los resultados de este proyecto tienen el potencial de brindar una herramienta versátil para el diseño de estructuras no convencionales de hormigón reforzado, en la que implícitamente se considere el comportamiento no-lineal de: (1) el hormigón, (2) el acero y (3) la interface acero-hormigón.

Estudios previos muestran aplicaciones de RNA en el campo de la ingeniería civil, por ejemplo: Adeli (1995) [2], Goh (1995) [10], Kunieda (1996) [14], Arahaki (1998) [3], Takeda (1998) [20], Basma (1999) [5] y Oh (1999) [17]. Estos enfoques pueden estar agrupados en tres categorías.

Adeli y Goh adoptaron un modelo RNA basado en el perceptrón de una capa en aplicaciones estructurales.

Kunieda, Arahaki y Takeda usaron el modelo perceptrón RNA multi-capas para tratar con la durabilidad del concreto y concreto reforzado.

Basma y Oh usaron un modelo RNA entrenado con el algoritmo de retropropagación para estudiar las propiedades del cemento y la dosificación de las mezclas de concreto.

Sin embargo, es importante resaltar que la literatura disponible no muestra aplicaciones de redes neuronales artificiales en la predicción del agrietamiento en estructuras de hormigón reforzado, y menos aún aplicaciones orientadas al análisis y diseño de estructuras no-convencionales. Este hecho motiva y justifica plenamente la propuesta de esta investigación, y se prevee un impacto en la comunidad de ingenieros estructurales que trabajan en el desarrollo de nuevos tipos de elementos estructurales.

Esta herramienta de diseño basada en redes neuronales tiene la capacidad de aprender y reforzar ese conocimiento en procesos de entrenamiento [2], usando datos de la respuesta global obtenida de experimentos físicos o numéricos basados, por ejemplo, en tecnología de elementos finitos.

En este proyecto se utiliza información experimental obtenida de ensayos de carga y durabilidad (a flexión) realizados a un grupo de 24 vigas prefabricadas unidas en la mitad del vano conectadas mecánicamente por conectores macho-hembra de acero anclados a las vigas por barras embebidas en el hormigón y que desarrollan esfuerzos por adherencia. Los anclajes están distribuidos bajo distintos esquemas y cuantías. Adicionalmente, se cuenta con la información experimental de 5 vigas monolíticas usadas como testigos y contrapartes para la comparación de resultados.

La idea central en base a la cual se estructuran los modelos basados en redes neuronales, es alimentar al modelo de red neuronal con un vector de entrada diseñado en base a las ecuaciones propuestas para vigas convencionales, que en resumen recogen las variables físicas que gobiernan el comportamiento de estos elementos, y establecer un mapeo con un vector de salida que no es más que la variable requerida para el diseño de las vigas objeto de este estudio. El mapeo entre vector de entrada y vector de salida recoge, en base a un entrenamiento con datos experimentales, las particularidades del comportamiento de las nuevas estructuras, sus nuevas condiciones geométricas y de frontera, además del comportamiento no lineal real de los materiales. Este es justamente el potencial de la propuesta de este trabajo.

Los resultados de este trabajo pueden servir como base para el desarrollo de modelos basados en redes neuronales que pueden ser aplicados en el desarrollo, análisis y diseño estructural de elementos de hormigón reforzado y otros materiales no concebidos en la normativa de diseño.

1.2 OBJETIVOS

1.2.1 Objetivo General

Probar modelos de redes neuronales para el análisis, diseño y predicción del ancho máximo de grietas superficiales en vigas prefabricadas de hormigón reforzado unidas por conectores mecánicos.

1.2.2 Objetivos Específicos

- 1 Revisar conceptos de diseño de estructuras de hormigón reforzado.
- 2 Determinar grupos de datos para entrenamiento y prueba de los modelos de redes neuronales en base a conceptos estadísticos.
- 3 Probar un modelo de red neuronal para el diseño a flexión de las vigas en estudio.
- 4 Probar un modelo de red neuronal para la predicción de anchos máximos de grietas.

1.3 ALCANCES

- 1 El estudio se limita a una propuesta de modelos basados en redes neuronales para: (a) el análisis de la capacidad última a flexión, (b) diseño a flexión y (c) predicción de ancho máximo de grieta superficial en vigas prefabricadas de hormigón reforzado unidas por conectores mecánicos y sometidas a acciones de flexión sin cortante,
- 2 Se cuenta con una base de datos experimental que corresponde a un estudio de resistencia y durabilidad de 27 vigas con diferente configuración y cantidad de acero de refuerzo y conectores mecánicos,
- 3 Se usará software comercial de redes neuronales,

1.4 METODOLOGÍA

Para alcanzar los objetivos planteados en este proyecto se desarrollan las siguientes actividades:

1.4.1 Actividad 1: Recolección de datos experimentales

Se usan datos experimentales de carga última a flexión de las vigas en estudio, ancho de grieta superficial máximo, y datos de geometría y caracterización mecánica de los materiales empleados.

1.4.2 Actividad 2: Clasificación estadística de datos experimentales

Los datos experimentales son clasificados y divididos en grupos para entrenamiento y validación de los modelos planteados. La clasificación se realiza en base a propuestas estadísticas disponibles en la literatura revisada y que están disponibles en el software de redes neuronales seleccionado para este proyecto.

1.4.3 Actividad 3: Identificar parámetros físicos relevantes para modelar el problema

En base a una revisión de las ecuaciones empíricas y analíticas disponibles en la literatura para evaluar y diseñar estructuras de hormigón reforzado convencionales, se

diseñan los vectores que servirán como entradas de los modelos basados en redes neuronales que constituyen la propuesta del presente trabajo. En adición a los parámetros estructurales involucrados en estas ecuaciones, se incluye en los vectores de entrada variables estructurales específicas de las nuevas vigas, en un intento por abstraer en el vector de entrada la física del fenómeno en estudio.

1.4.4 Actividad 4: Identificar un modelo de red neuronal

Se usa el modelo mas simple de red neuronal (perceptrón con una capa de neuronas interna). La configuración de la red neuronal se establece en base a un proceso iterativo en el que se tiene como variable al número de neuronas en la capa interna de la red y se evalúa el nivel de aproximación de los resultados experimentales con esos presentados por el modelo.

En cuanto al proceso de entrenamiento se proponen dos alternativas, que al final sirven para establecer comparaciones cuantitativas del rendimiento de la red. El primer método de entrenamiento de la red, es decir el proceso por el cual se fijan los valores del peso de las conexiones (en un proceso de minimización de error) corresponde al método de retro-propagación del error, y la segunda alternativa utilizada en este estudio es un entrenamiento basado en algoritmos genéticos.

1.4.5 Actividad 5: Validar y verificar resultados

Los datos experimentales se dividen, en base a un análisis estadístico de los mismos, en: (1) Grupo de entrenamiento de la red y (2) Grupo de validación del modelo neuronal. Una vez la red a sido entrenada, es decir pesos de conexiones ajustados, con los datos del grupo de entrenamiento, la fase de validación consiste en ingresar en los vectores de entrada de la red datos del grupo de validación, es decir datos que no fueron usados en la etapa de entrenamiento y obtener predicciones del modelo que pueden ser comparados con los datos experimentales disponibles para validación.

Capítulo 2

HORMIGÓN REFORZADO

2.1 INTRODUCCIÓN

En este capítulo se presenta una síntesis de la teoría del análisis y diseño de estructuras de hormigón reforzado. Se inicia con definiciones generales sobre el material, luego se describen ventajas y desventajas de la construcción con elementos pre-fabricados de hormigón. En las siguientes secciones se describen aspectos sobre la teoría existente para el análisis a flexión de vigas de hormigón reforzado convencionales, definidas como convencionales por ajustarse a las especificaciones de estándares de construcción disponibles. Se hace énfasis en las ecuaciones tanto de diseño a flexión basado en resistencia, como en las diferentes ecuaciones empíricas usadas para control de agrietamiento en estructuras convencionales de hormigón reforzado. La sección 2.3 de este capítulo inicia con una descripción detallada de las vigas objeto de este estudio, esto es, vigas de hormigón reforzado pre-fabricadas unidas con conectores mecánicos. Se describe la geometría, la configuración del refuerzo, la distribución de anclajes, propiedades de los materiales, etc. Se brinda información sobre el diseño de la fase experimental que llevó a obtener los datos que se utilizarán en el modelamiento basado en redes neuronales. Las ecuaciones planteadas en esta sección servirán como base para el diseño de los vectores de entrada y salida del modelo neuronal, y los datos experimentales serán la fuente de información para los procesos de entrenamiento de las redes y validación de los modelos propuestos.

2.2 MARCO TEORICO

2.2.1 Generalidades

Hormigón Reforzado

El objetivo fundamental de la teoría de hormigón reforzado es dimensionar un elemento estructural para satisfacer criterios de estabilidad, serviciabilidad, funcionalidad, seguridad y economía a nivel de estructura [18]. El hormigón reforzado, es un material de dos componentes, (1) hormigón, y (2) acero de refuerzo que trabajan conjuntamente para formar elementos estructurales con capacidad de resistir acciones externas para las cuales fueron diseñados. La clave del comportamiento de este material esta en la resistencia complementaria de sus componentes: (1) Hormigón que resiste esfuerzos de compresión, y (2) el acero que resiste tensión y proporciona ductilidad.

Hormigón Reforzado Pre-fabricado

Los elementos estructurales de hormigón reforzado pueden elaborarse en una planta bajo condiciones controladas. En estas circunstancias, los elementos obtenidos se conocen como pre-fabricados de hormigón. Los productos obtenidos son de alta calidad y pueden erigirse rápidamente. En consecuencia, las estructuras de hormigón pre-fabricadas son una alternativa económica a construcciones fabricadas, en su totalidad, in-situ. El proceso constructivo se simplifica considerablemente si el diseño de las conexiones, para unir los elementos pre-fabricados, responde a criterios no solo de resistencia sino también prácticos. El éxito económico y funcional de una estructura de hormigón pre-fabricada, depende en gran medida de la configuración y propiedades de las conexiones entre elementos [11].

Ventajas y Desventajas del Hormigón Reforzado Prefabricado

Ventajas

- 1 Calidad de los materiales
- 2 Mano de obra calificada
- 3 Reducción de tiempos de construcción
- 4 Economía

Desventajas

- 1 Complejidad adicional en el modelamiento,
- 2 Experimentación adicional requerida,

2.3 VIGAS CONVENCIONALES

2.3.1 Descripción

En el contexto de este estudio se denominan como vigas convencionales a vigas de hormigón reforzado monolíticas, con secciones transversales regulares. En general se describen con este término a todas las configuraciones estructurales de vigas que se enmarcan dentro de los parámetros de diseño establecidos en códigos de construcción para hormigón reforzado [4].

2.3.2 Diseño Basado en Resistencia

La filosofía de diseño de estructuras de hormigón reforzado basado en resistencia determina las dimensiones y la cantidad de acero de refuerzo requerido por una sección para resistir cargas de diseño. Las cargas últimas son determinadas multiplicando las cargas de trabajo por factores de carga impuestos por los códigos y que en términos generales son el resultado de análisis estadísticos y probablisticos. Por cargas de trabajo se entienden, entre otras, a: (1) cargas de peso propio, (2) cargas vivas impuestas por los códigos, (3) cargas sísmicas, (4) cargas de viento, etc. La capacidad última de una sección se alcanza ya sea por fluencia del acero de refuerzo, o por el aplastamiento del hormigón en compresión.

En el dimensionamiento de elementos estructurales se busca garantizar su respuesta mecánica en base a cuatro criterios estructurales [18]:

Resistencia

La cual es mantenida si se provee una adecuada capacidad interna última en el elemento.

Ductilidad

Refleja la capacidad de desarrollar deformaciones plásticas y disipación de energía.




Figura 2.1: Distribución de esfuerzos y deformaciones para la carga última

Serviciabilidad

El diseño debe controlar la flexibilidad del elemento restringiendo los desplazamientos máximos de la estructura en base a la geometría de la sección.

Durabilidad

Grietas visibles deterioran la apariencia del elemento, y permiten el ingreso de fluidos. Estos ocasionan corrosión en el acero de refuerzo y por tanto reducen la capacidad última del elemento de hormigón reforzado.

2.3.3 Diseño a Flexión

Asumiendo que la distribución de esfuerzos y deformaciones cerca de la falla en la sección de hormigón reforzado es la que se esquematiza en la figura 2.1, se pueden plantear ecuaciones basadas en el equilibrio estático de la sección para calcular el momento último nominal M_n en el cual la viga fallará dentro de uno de los siguiente modos de falla [18], [13]:

- (1) Por fluencia del acero sometido a tensión, o
- (2) Por aplastamiento del concreto en la fibra extrema a compresión.

Para el primer modo de falla, el criterio estipula que un elemento de hormigón reforzado fallará si el esfuerzo en el acero es igual al punto de fluencia de este material, esto es $f_s = f_y$.

En el caso del hormigón, el criterio de falla no es tan claro por la no-linealidad que muestra el material en su respuesta constitutiva. Sin embargo, estudios experimentales muestran que **en el caso de vigas de sección rectangular** las deformaciones

unitarias del hormigón, inmediatamente antes de la falla, varían entre 0.003 y 0.004 [mm/mm]. Si se supone conservadoramente que el concreto está próximo al aplastamiento cuando la máxima deformación unitaria alcanza $\epsilon_u = 0,003$, una vez mas en base a extensos programas experimentales, bajo estas condiciones de carga (i.e. flexión pura) se puede predecir la resistencia última en vigas de sección rectangular.

A continuación, en base a condiciones de equilibrio estático, se sintetizan las ecuaciones en las que se basan los esquemas de diseño de vigas de hormigón armado. Al plantear el equilibrio de la sección, no es necesario conocer la distribución de esfuerzos en el hormigón, basta con determinar la fuerza total del bloque de compresión para poder conocer la distancia c al eje neutro, es decir, la distancia vertical de la fibra extrema en compresión al plano de cero deformaciones de la sección de hormigón.

Para una viga rectangular, el área en compresión es bc , siendo b el ancho de la viga y c , como se dijo, la distancia vertical de la fibra extrema en compresión al eje neutro. La fuerza total de compresión C que actúa en esta área se puede expresar como [18]:

$$C = f_{avg}.b.c \quad (2.1)$$

donde: f_{avg} es el esfuerzo promedio a compresión sobre el área $b.c$. Evidentemente, el esfuerzo promedio a compresión que puede desarrollarse antes de que ocurra la falla resulta mayor si la resistencia del cilindro estándar para ensayos a compresión, f'_c , es mayor. Entonces,

$$\alpha = \frac{f_{avg}}{f'_c} \quad (2.2)$$

$$C = \alpha.f'_c.b.c \quad (2.3)$$

Para cierta distancia c hasta el eje neutro, la localización de C puede definirse como una fracción β de c . Entonces, como se muestra en la figura 2.1, para un hormigón con determinada resistencia f'_c , es necesario conocer unicamente α y β con el fin de definir completamente el efecto de los esfuerzos de compresión del hormigón. La determinación de estos coeficientes requiere de extensos programas experimentales.

Los valores recomendados se ajustan al siguiente esquema [18]:

α es igual a 0.72 para $f'_c < 280$ [kg/cm²]

α disminuye en 0.04 cada 70 [kg/cm²] sobre 280 [kg/cm²] y hasta 560 [kg/cm²]

α es igual a 0.56 para $f'_c > 560$ [kg/cm²]

β es igual a 0.425 para $f'_c < 280$ [kg/cm²]

β disminuye en 0.025 oir cada 70 [kg/cm²] sobre 280 [kg/cm²] y hasta 560 [kg/cm²]

β es igual a 0.325 para $f'_c > 560$ [kg/cm^2]

Si se acepta esta información experimental, la resistencia última puede calcularse planteando las leyes de equilibrio y el supuesto de que las secciones planas permanecen planas durante la flexión.

El equilibrio exige que la fuerza total de compresión \mathbf{C} y la fuerza resultante en el bloque de tensión \mathbf{T} satisfagan:

$$\mathbf{C} = \mathbf{T} \quad (2.4)$$

$$\alpha \cdot f'_c \cdot b \cdot c = A_s \cdot f_s \quad (2.5)$$

El momento flector equivalente al par formado por las fuerzas \mathbf{C} y \mathbf{T} puede escribirse como:

$$M = \mathbf{T} \cdot z = A_s \cdot f_s (d - \beta c) \quad (2.6)$$

$$M = \mathbf{C} \cdot z = \alpha \cdot f'_c \cdot b \cdot c \quad (2.7)$$

Si el criterio de falla corresponde a la fluencia del acero de refuerzo en tensión, entonces $f_s = f_y$. Con la sustitución de este valor en la ecuación 2.5, se obtiene la distancia al eje neutro.

$$c = \frac{A_s \cdot f_y}{\alpha \cdot f'_c \cdot b} \quad (2.8)$$

Si definimos $A_s = \rho \cdot b \cdot d$, la distancia al eje neutro puede evaluarse con la siguiente expresión:

$$c = \frac{\rho \cdot f_y \cdot d}{\alpha \cdot f'_c} \quad (2.9)$$

Esta ecuación proporciona la distancia hasta el eje neutro cuando ocurre la falla a tensión. El momento último M_n se obtiene, entonces, a partir de la ecuación 2.6, con el valor de c determinado con la ecuación 2.9 y con un valor de esfuerzo del acero igual al de fluencia, es decir, $f_s = f_y$. La ecuación del momento nominal M_n es:

$$M_n = \rho \cdot f_y \cdot b \cdot d^2 \cdot \left(1 - 0,59 \frac{\rho \cdot f_y}{f'_c}\right) \quad (2.10)$$

2.3.4 Control de agrietamiento

El control del agrietamiento en una estructura de hormigón reforzado es de importancia para: (1) Conservar la apariencia de la estructura, y (2) Controlar la durabilidad de la estructura. El minimizar el agrietamiento en el hormigón consigue prevenir el ingreso de humedad y oxígeno hasta la zona de ubicación del acero de refuerzo. La humedad y

el oxígeno ocasionan corrosión en el refuerzo y por tanto reducción de su área efectiva, con la consiguiente disminución de la capacidad de carga de la estructura.

Varias expresiones empíricas son propuestas por los códigos de construcción [1], [16] para evaluar el ancho máximo de grieta en vigas de sección rectangular sometidas a flexión.

Grietas en miembros a flexión

En elementos sometidos a flexión, el agrietamiento de la sección de hormigón se produce bajo cargas de trabajo por la baja capacidad a tensión de este material. Para prevenir este fenómeno, que puede tener consecuencias negativas en la estructura, se ubica acero de refuerzo en las zonas en tensión. El acero de refuerzo, como se dijo anteriormente, es el material encargado de resistir esfuerzos de tensión generados por la cargas externas. Un grieta se forma en el hormigón cuando una avertura muy delgada, de dimensión indefinida, se desarrolla en el elemento estructural como resultado de esfuerzos de tensión que sobrepasan el módulo de rotura del hormigón. Estos esfuerzos internos de tensión pueden deberse a una de las siguientes causas:

- (1) Fuerzas externas como tensión directa, cortante, flexión o torsión.
- (2) Creep,
- (3) Shrinkage.
- (4) Expansión producida por cambios en la estructura interna del material

Grietas principales

Se originan por las diferencias de deformación entre el acero de refuerzo y el hormigón en la sección analizada. El comportamiento de este tipo de grietas cambia en dos fases bien definidas [18]:

- (1) A bajos esfuerzos de tensión en las barras de acero, el número de grietas se incrementa, mientras el ancho de las mismas permanece en valores muy pequeños. En tanto el esfuerzo de tensión se incrementa, se alcanza un estado de equilibrio.
- (2) La segunda fase de agrietamiento se desarrolla cuando los esfuerzos de tensión alcanzan valores mas altos. Como consecuencia, el ancho de las grietas se incrementa, y no se observa un incremento significativo de el número de grietas. Generalmente el ancho de una o dos grietas empieza a incrementarse formando lo que se conoce como grieta principal crítica.

Ancho de grieta

Como resultado de extensos programas de investigación se ha llegado a determinar los factores de los cuales depende el ancho de grieta principal en una sección de hormigón:

- (1) Porcentaje o cuantía de refuerzo,
- (2) Distribución del refuerzo en la sección de hormigón,
- (3) Esfuerzo en el acero en condiciones de carga de servicio,
- (4) Propiedades constitutivas del hormigón,
- (5) Recubrimiento.

Diversas ecuaciones de carácter empírico han sido propuestas para predecir el ancho de grieta en elementos de hormigón reforzado. Los códigos de construcción son los que se han encargado de adoptar ecuaciones y sugerirlas como una medida para controlar la durabilidad de estructuras de hormigón reforzado.

Recomendaciones del Instituto Americano del Concreto ACI - Comité 224

De acuerdo a las recomendaciones del ACI [1], el ancho máximo de grieta permitido en el diseño de estructuras de hormigón reforzado se puede determinar con la siguiente ecuación:

$$w = 0,000076 \cdot \beta \cdot f_s \cdot (d_c \cdot A)^{1/3} \quad (2.11)$$

donde:

w: Ancho de grieta [in]; d_c : Recubrimiento [in]; A: Área de hormigón [in²]; β : 1.20 [in] para vigas; f_s : Esfuerzo en el acero de refuerzo;

Recomendaciones Europeas fijadas por el CEB

EL CEB [7] propone una ecuación simplificada para el cálculo del ancho de grieta en vigas con refuerzo corrugado:

$$w_m = 0,7 \cdot \frac{f_s}{E_s} \left(3c + 0,05 \frac{d_b}{\rho_r} \right) \quad (2.12)$$

donde:

w: Ancho medio de grieta [in]; f_s : Esfuerzo en el refuerzo en la zona de agrietamiento; f_c : Recubrimiento de concreto; d_b : diámetro del refuerzo; ρ_r : A_s/A_t ; A_t : Area efectiva en tensión

Recomendaciones Japonesas establecidas por la JSCE

La sociedad de ingenieros civiles del Japón (JSCE) [16] en el código de construcción Japonés , establece como ancho máximo de grieta el valor dado por la siguiente ecuación:

$$w = k.(4.c + 0,7.(c_s - \phi))\left(\frac{\sigma_s}{E_s} + \epsilon'_{cs}\right) \quad (2.13)$$

donde:

w: Ancho máximo de grieta; f_s : Esfuerzo en el refuerzo en la zona de agrietamiento $< 0,60f_y$; k : 1.0 para barras deformadas; c : recubrimiento de hormigón; c_s : Espaciamiento del refuerzo; ϕ : diámetro del refuerzo; ϵ_s : deformación en el concreto por creep.

2.4 VIGAS NO CONVENCIONALES

2.4.1 Generalidades

Dentro del contexto de este estudio, se definen como vigas no convencionales a aquellas cuya geometría y/o configuración del acero de refuerzo no se ajustan a los requerimientos establecidos en códigos de construcción y por tanto requieren consideraciones especiales o quizá únicas para su análisis y diseño estructural. Este es el caso de las vigas de hormigón reforzado pre-fabricadas estudiadas en este proyecto.

Una de las ventajas mas importantes de las estructuras de hormigón reforzado pre-fabricadas es la posibilidad de producir las en una planta bajo condiciones de fábrica controladas. Esto permite el uso de materiales, en especial el hormigón, de alta calidad. Este es un factor clave para reducir la incertidumbre intrínseca de los modelos numéricos usados en el análisis y diseño de estos elementos en lo referente a la respuesta constitutiva de los materiales utilizados.

En el aspecto constructivo los pre-fabricados consiguen ahorros importantes tanto de mano de obra como de tiempos de montaje de las estructuras. [15]

En consecuencia, estructuras de hormigón prefabricadas son una alternativa económica a las construcciones in-situ tradicionales, en especial si las conexiones entre elementos pre-fabricados son simples y garantizan el desarrollo de la capacidad mecánica total de cada elemento estructural.

Como puede verse, el éxito económico y funcional de una estructura de hormigón pre-fabricada depende en gran medida de la configuración y propiedades de las conexiones entre sus elementos.

Debido a las dificultades para proveer tales detalles de conexión, el desarrollo de con-

xiones momento resistentes, económicas y funcionales,. para estructuras de hormigón prefabricadas toma especial importancia. La gran cantidad de publicaciones, que han aparecido en años recientes, claramente indica el interés de la industria e ingenieros en este campo de investigación.

La mayor parte de la investigación esta concentrada en el estudio de cuatro parámetros estructurales fundamentales que necesitan ser considerados en el desarrollo de nuevos tipos de conexiones, éstos son [15]:

Configuración de las conexiones: Afecta la velocidad del proceso de montaje de la estructura, la estabilidad de la estructura durante el proceso de construcción. Determina también la cantidad de refuerzo requerida para alcanzar una resistencia nominal objetivo.

Flexibilidad de las conexiones: Determina la distribución de la fluencia, tensiones térmicas y contracciones. Determina el desempeño de las juntas en el tiempo.

Resistencia de las conexiones: Después de que las demandas de cambio de volumen, cargas de gravedad y correcciones dimensionales han quedado satisfechas.

Ductilidad de las conexiones: Determina si las deformaciones permanentes tendrán lugar mediante una redistribución segura de la carga y energía de disipación o por fallo en la conexión frágil.

Durabilidad de las conexiones: Prevenir procesos corrosivos, prevenir deflecciones excesivas.

2.4.2 Planteamiento del problema y motivación

En este estudio se utilizan datos experimentales relacionados con la resistencia a flexión y el agrietamiento de un tipo de vigas de hormigón reforzado pre-fabricadas en las que se usa una nueva configuración de los elementos usados como mecanismo de conexión [21].

El sistema de conexión formado por barras de acero de anclaje y conectores tipo macho-hembra, conecta mecánicamente dos elementos de hormigón pre-fabricados que pueden formar parte de vigas simples, estructuras para sistemas de alcantarillado, muros de contención, etc., como se muestra en la figura 2.2. La figura muestra la calidad del producto final, perfecta geometría de las secciones, entre otras propiedades que hacen de la construcción en hormigón pre-fabricado una alternativa a los métodos actuales de construcción.

Este trabajo trata de estudiar el comportamiento de vigas pre-fabricadas sometidas a flexión y validar normas de diseño para este tipo de elementos estructurales. De acuerdo a normas existentes, el diseño de estructuras pre-fabricadas conectadas con el sistema mecánico descrito anteriormente deben satisfacer las siguiente recomendacio-



Figura 2.2: Estructura construida en base a elementos pre-fabricados unidos con conectores mecánicos.

nes de configuración de refuerzo y sistema de conexión [8].

- 1 La estructura final debería contener al menos tres barras de refuerzo principal por cada barra de anclaje (3:1), y
- 2 El espacio entre conectores debe ser menor a 300mm.

El costo de producción y construcción de elementos pre-fabricados, que usan conectores mecánicos en las uniones de miembros, está directamente relacionado a la configuración de las conexiones, en otras palabras, por el número de conectores distribuidos a través de la sección de los elementos que están siendo conectados.

El establecer un nuevo esquema de conexión, que no responde a los requerimientos ya establecidos, demanda la generación de herramientas de diseño que tomen en cuenta las nuevas condiciones estructurales del elemento en estudio.

Este problema fundamental que surge a raíz del desarrollo de un nuevo tipo de conexiones para elementos pre-fabricados de hormigón, motiva la propuesta hecha en este proyecto.

Se persigue, como principal objetivo, el plantamiento de modelos basados en modelos de redes neuronales, para el análisis y diseño de vigas no convencionales, en los que se tomen en cuenta variables físicas que no pueden ser representadas en un modelo determinístico, o que su representación demanda de un elevado grado de abstracción y complejidad.

Paralelamente, se concentran esfuerzos en el estudio de la durabilidad de la estructura final. El agrietamiento en las estructuras de hormigón armado es un problema

latente y que demanda continua investigación. En el caso particular de las vigas en estudio, el problema del agrietamiento - y por tanto de durabilidad de estos elementos estructurales- demanda mayor atención debido a la grieta pre-existente en la sección de conexión.

El contar con una herramienta de predicción, como la que se propone en este estudio, del ancho máximo de grieta permitirá en tiempo de diseño hacer los ajustes necesarios para evitar daños ocasionados por el ambiente en la respuesta estructural de las vigas estudiadas.

En general, se puede decir que herramientas de diseño versátiles como las que se desarrollan en este proyecto, reducen la necesidad de extensos y costosos programas experimentales orientados a evaluar la respuesta de nuevos elementos y/o configuraciones estructurales.

2.4.3 Descripción de las vigas en estudio

Veintinueve vigas con geometría y configuración descritas en las tablas: 2.1, 2.2, 2.3, 2.4, 2.5 y 2.6, fueron ensayadas durante el programa experimental. Todas las vigas son simplemente apoyadas, y la distancia del vano libre es 0,50m mas corta que la longitud total especificada en la tabla 2.2. De estas veintinueve (29) vigas, veinticuatro (24) son con conexiones, y cinco (5) son monolíticas y usadas como testigos de comparación en este estudio.

Las vigas estan constituidas por dos elementos, de sección transversal rectangular pre-fabricados, unidos mediante conectores mecánicos en la mitad del vano.

Dos mecanismos de empalme son usados para lograr la conexión:

- (1) El primer mecanismo sirve para conectar las barras de anclaje embebidas en cada elemento pre-fabricado por medio de conectores de acoplamiento (macho-embra).
- (2) Con el segundo mecanismo de conexión, las barras de acero embebidas en los elementos prefabricadas transfieren esfuerzos al hormigón por adherencia.

Las vigas convencionales, de aquí en adelante llamadas vigas de control (i.e. vigas continuas sin conexiones), sirven como una contraparte de las vigas unidas mediante conectores mecánicos para comparar su desempeño estructural.

Un vista 3D de una viga tipo, unida mediante conectores mecánicos, se muestra en la figura 2.3. La figura 2.4 ilustra una vista lateral de una viga unida por conectores mecánicos y la figura 2.5 muestra una sección transversal típica de las vigas con conexiones. Finalmente, los detalles de los mecanismos de conexión usados en este experimento son gráficamente mostrados en la figura 2.6.




Figura 2.3: Vigas Pre-fabricada tipo: Vista 3D.




Figura 2.4: Vigas Pre-fabricada tipo: Sección Transversal.




Figura 2.5: Vigas Pre-fabricada tipo: Sección Transversal.

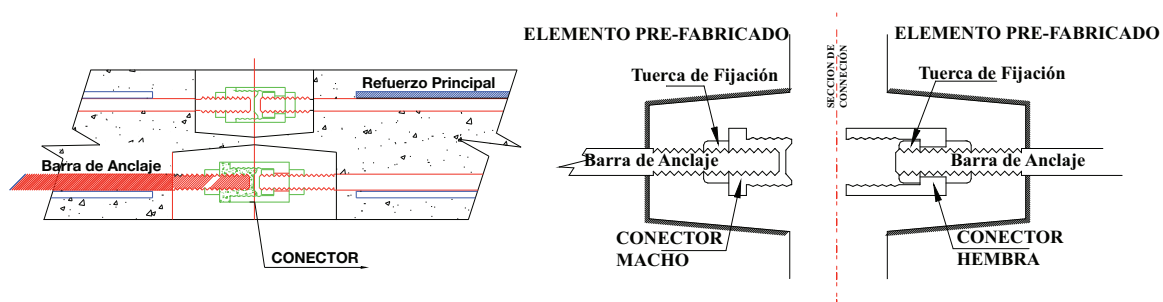


Figura 2.6: Vigas Pre-fabricada tipo: Detalle del Conector.

Dimensiones y Geometría

La tabla 2.1 presenta datos sobre longitud **L**, ancho **b**, espesor **h** y vano libre **s** de las vigas utilizadas en el programa experimental. Los datos hacen referencia a los esquema de las vigas presentados en las figuras 2.3, 2.4.

En la tabla 2.2 se detalla información sobre la profundidad efectiva de la vigas de la SERIE I y de la SERIE II.

Tabla 2.1: Descripción de la geometría de las vigas

| GEOMETRIA | L | h | b | s | Descripción |
|------------------|----------|----------|----------|----------|--------------------|
| TIPO | [mm] | [mm] | [mm] | [mm] | |
| 1 | 4500 | 300 | 1000 | 1500 | Conexión |
| 2 | 6500 | 300 | 2000 | 2000 | Conexión |
| 3 | 6500 | 250 | 2000 | 2000 | Conexión |
| 0_1 | 4500 | 300 | 1000 | 1500 | Monolítica |
| 0_2 | 6500 | 300 | 2000 | 2000 | Monolítica |

Configuración del refuerzo

Tres tipos de barras de acero de refuerzo son usadas en las vigas. El refuerzo longitudinal consiste de barras de anclaje y refuerzo principal. Las barras de anclaje se conectan en la mitad del vano y se extienden hacia los dos extremos de las vigas, una distancia equivalente a 35 diámetros de la varilla, para garantizar el desarrollo de esfuerzos por adherencia.

El refuerzo de acero se complementa con estribos distribuidos a lo largo de las vigas, cada 150mm, para prevenir fallas por cortante.

La configuración del acero de refuerzo y de las barras de anclaje se detalla en los cuadros 2.3, 2.4, 2.5, 2.6. La información contenida en los cuadros responde a la siguiente descripción.

- (1) Grupo: Configuraciones de refuerzo y geometrías similares
- (2) Número de viga: Identifica a una viga
- (3) Tipo de viga: Monolítica o Conectada
- (4) Área de refuerzo o anclaje en tensión y compresión
- (5) Número de varillas
- (6) Espaciamiento del refuerzo

El sistema estructural final obtiene su estabilidad como resultado de la continuidad dada por la conexión y las condiciones de soporte.

Tabla 2.2: SERIE I y II : Profundidad efectiva de las barras de anclaje **d** y **d'**

| | | SERIE 1 | | | | | | | | | | | | | | | | | | | |
|-----------------|--|----------------|----------|----------|----------|----------|----------|----------|----------|----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| VIGA No. | | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 |
| d [mm] | | 230 | 225 | 230 | 230 | 225 | 235 | 225 | 225 | 225 | 230 | 225 | 225 | 220 | 220 | 230 | 230 | 225 | 250 | 250 | 250 |
| d' [mm] | | 65 | 70 | 65 | 65 | 70 | 65 | 70 | 70 | 70 | 65 | 70 | 70 | 70 | 70 | 65 | 65 | 65 | 50 | 50 | 50 |

| | | SERIE - 2 | | | | | | | | |
|-----------------|--|------------------|----------|----------|----------|----------|----------|----------|----------|----------|
| VIGA No. | | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
| d [mm] | | 225 | 225 | 225 | 220 | 225 | 175 | 175 | 250 | 250 |
| d' [mm] | | 70 | 70 | 70 | 70 | 70 | 70 | 70 | 50 | 50 |

Tabla 2.3: SERIE I: Configuración de refuerzo en tensión y compresión

| GRUPO | VIGA | TIPO | REFUERZO EN TENSION | | | REFUERZO EN COMPRESION | | |
|-------|-------|------|------------------------|------------|--------------|------------------------|-----------------|--------------|
| | | | AsT [mm ²] | RB.T[mm] | Bars/Space | AsC[mm ²] | RB.C[mm] | Bars/Space |
| G1 | No.5 | 2 | 21.539 | 17D13 | 14/125+2/75 | 14.506 | 14D10+2D13+1D16 | 14/125+2/75 |
| | No.7 | 2 | 23.799 | 12D13+3D19 | 12/135+2/140 | 14.518 | 12D10+3D16 | 12/135+2/140 |
| | No.8 | 2 | 23.832 | 12D16 | 9/172+2/176 | 15.204 | 12D13 | 9/172+2/176 |
| | No.9 | 2 | 23.832 | 12D16 | 9/172+2/176 | 15.204 | 12D13 | 9/172+2/176 |
| | No.11 | 2 | 21.468 | 11D16 | 8/200+2/150 | 13.937 | 11D13 | 8/200+2/150 |
| G2 | No.19 | 0_2 | 23.832 | 12D16 | 9/172+2/176 | 15.204 | 12D13 | 9/172+2/176 |
| | No.13 | 2 | 21.618 | 8D16+2D19 | 7/210+2/215 | 9.678 | 8D16+2D16 | 7/210+2/215 |
| | No.14 | 2 | 21.618 | 8D16+2D19 | 6/250+2/200 | 9.742 | 3D10+6D13 | 6/250+2/200 |
| | No.20 | 0_2 | 22.92 | 8D19 | 5/270+2/275 | 10.136 | 8D13 | 5/270+2/275 |
| | No.1 | 2 | 25.5 | 2D10+19D13 | 18/100+2/50 | 14.186 | 2D6+19D10 | 18/100+2/50 |
| G3 | No.3 | 2 | 22.258 | 16D13+1D16 | 14/125+2/75 | 12.68 | 16D10+1D13 | 14/125+2/75 |
| | No.4 | 2 | 21.539 | 17D13 | 14/125+2/75 | 11.333 | 2D6+15D10 | 14/125+2/75 |
| G4 | No.10 | 2 | 20.408 | 2D13+9D16 | 8/200+2/150 | 8.4 | 10D10+1D13 | 8/200+2/150 |
| | No.12 | 2 | 15.375 | 9D13+2D16 | 8/200+2/150 | 10.061 | 7D10+4D13 | 8/200+2/150 |
| G5 | No.17 | 2 | 15.888 | 8D16 | 5/270+2/275 | 5.706 | 8D10 | 5/270+2/275 |
| | No.15 | 2 | 17.646 | 6D16+2D19 | 5/270 | 10.136 | 8D13 | 5/270 |
| G6 | No.16 | 2 | 17.646 | 6D16+2D19 | 5/270 | 10.136 | 8D13 | 5/270 |
| | No.6 | 2 | 13.468 | 10D10+5D13 | 12/135+2/140 | 13.468 | 10D10+5D13 | 12/135+2/140 |
| G7 | No.18 | 0_2 | 14.266 | 20D10 | 19/100 | 14.266 | 20D10 | 19/100 |
| | No.2 | 2 | 27.326 | 20D13+1D16 | 18/100+2/50 | 17.748 | 16D10+5D13 | 18/100+2/50 |

Tabla 2.4: SERIE I: Configuración de anclajes en tensión y compresión

| GRP | VIGA | TIPO | ANCLAJE EN TENSION | | | ANCLAJE EN COMPRESION | | |
|-----|-------|------|--------------------|-----------|-------------|-----------------------|-----------|-------------|
| | | | AnC[mm2] | AnT[mm] | Bars/Space | AnC[mm2] | AnC[mm] | Bars/Space |
| G1 | No.5 | 2 | 23.826 | 3D32 | 2/625 | 15.201 | 3D25 | 2/625 |
| | No.7 | 2 | 23.826 | 3D32 | 2/675 | 15.201 | 3D25 | 2/675 |
| | No.8 | 2 | 23.826 | 3D32 | 1/688+1/860 | 15.201 | 3D25 | 1/688+1/860 |
| | No.9 | 2 | 23.826 | 3D32 | 2/688 | 15.201 | 3D25 | 2/688 |
| | No.11 | 2 | 23.826 | 3D32 | 2/800 | 15.201 | 3D25 | 2/800 |
| G2 | No.19 | 0_2 | - | - | - | - | - | - |
| | No.13 | 2 | 22.8 | 2D38 | 1/1050 | 10.134 | 2D25 | 1/1050 |
| | No.14 | 2 | 22.8 | 2D38 | 1/1000 | 10.134 | 2D25 | 1/1000 |
| | No.20 | 0_2 | - | - | - | - | - | - |
| G3 | No.1 | 2 | 25.335 | 5D25 | 4/400 | 14.325 | 5D19 | 4/400 |
| | No.3 | 2 | 25.335 | 5D25 | 4/375 | 14.325 | 5D19 | 4/375 |
| G4 | No.4 | 2 | 20.268 | 4D25 | 2/500+1/300 | 11.46 | 4D19 | 2/500+1/300 |
| | No.10 | 2 | 20.268 | 4D25 | 2/600+1/400 | 7.944 | 4D16 | 2/600+1/400 |
| G5 | No.12 | 2 | 15.884 | 2D32 | 1/1000 | 10.134 | 2D25 | 1/1000 |
| | No.17 | 2 | 15.884 | 2D32 | 1/1350 | 5.73 | 2D19 | 1/1350 |
| G6 | No.15 | 2 | 18.076 | 2D25+1D32 | 2/675 | 10.797 | 2D19+1D25 | 2/675 |
| | No.16 | 2 | 21.534 | 2D25+1D38 | 2/675 | 10.797 | 2D19+1D25 | 2/675 |
| G7 | No.6 | 2 | 14.325 | 5D19 | 4/405 | 14.325 | 5D19 | 4/405 |
| | No.18 | 0_2 | - | - | - | - | - | - |
| G8 | No.2 | 2 | 31.768 | 4D32 | 2/500+1/600 | 20.268 | 4D25 | 2/500+1/600 |

Tabla 2.5: SERIE II: Configuración de refuerzo en tensión y compresión

| GRUPO | VIGA | TIPO | REFUERZO EN TENSION | | | REFUERZO EN COMPRESION | | |
|-------|------|------|------------------------|------------|------------|------------------------|------------|------------|
| | | | AsT [mm ²] | R.B.T[mm] | Bars/Space | AsC[mm ²] | R.B.C[mm] | Bars/Space |
| G9 | No.1 | 1 | 15.888 | 8D16 | 8/125 | 10.136 | 8D13 | 8/125 |
| | No.2 | 1 | 15.666 | 2D19+5D16 | 7/145 | 10.307 | 2D16+5D13 | 7/145 |
| | No.3 | 1 | 15.432 | 4D19+2D16 | 6/170 | 10.478 | 4D16+2D13 | 6/170 |
| G10 | No.8 | 0_1 | 15.666 | 2D19+5D16 | 7/150 | 10.307 | 2D16+5D13 | 7/150 |
| | No.6 | 3 | 23.148 | 4D16+12D13 | 16/125 | 14.735 | 6D13+10D10 | 16/125 |
| | No.7 | 3 | 23.49 | 8D16+6D13 | 14/145 | 15.523 | 10D13+4D10 | 14/145 |
| G11 | No.5 | 2 | 31.32 | 4D19+10D16 | 14/145 | 20.614 | 4D16+10D13 | 14/145 |
| | No.9 | 0_2 | 31.32 | 4D19+10D16 | 14/150 | 20.614 | 4D16+10D13 | 14/150 |
| G12 | No.4 | 1 | 23.073 | 3D22+4D19 | 7/145 | 10.307 | 2D16+5D13 | 7/145 |

Tabla 2.6: SERIE II: Configuración de anclajes en tensión y compresión

| GRUPO | VIGA | TIPO | ANCLAJE EN TENSION | | | ANCLAJE EN COMPRESION | | |
|-------|------|------|-----------------------|---------|------------|-----------------------|---------|------------|
| | | | AnC[mm ²] | AnT[mm] | Bars/Space | AnC[mm ²] | AnC[mm] | Bars/Space |
| G9 | No.1 | 1 | 15.884 | 2D32 | 2/500 | 10.134 | 2D25 | 2/500 |
| | No.2 | 1 | 15.884 | 2D32 | 2/500 | 10.134 | 2D25 | 2/500 |
| | No.3 | 1 | 15.884 | 2D32 | 2/500 | 10.134 | 2D25 | 2/500 |
| G10 | No.8 | 0_1 | - | - | - | - | - | - |
| | No.6 | 3 | 23.826 | 3D32 | 3/600 | 15.201 | 3D25 | 3/600 |
| | No.7 | 3 | 23.826 | 3D32 | 3/600 | 15.201 | 3D25 | 3/600 |
| G11 | No.5 | 2 | 31.768 | 4D32 | 4/500 | 20.268 | 4D25 | 4/500 |
| | No.9 | 0_2 | - | - | - | - | - | - |
| G12 | No.4 | 1 | 22.8 | 2D38 | 2/500 | 10.134 | 2D25 | 2/500 |

2.5 PROGRAMA EXPERIMENTAL

El programa experimental está diseñado para verificar en ensayos de flexión simple la respuesta estructural de:

- (1) **Vigas con conexiones** Vigas construidas en base a la unión de dos elementos de hormigón reforzado pre-fabricados por medio de un sistema de conexión como el representado en la figura 2.6. La distribución del sistema de conexión en la sección transversal de las vigas resultantes modifica criterios actualmente establecidos en códigos de construcción existentes y que requieren ser validados.
- (2) **Vigas monolíticas** Las vigas monolíticas son construidas en un solo cuerpo y responden a una configuración de refuerzo estándar contemplada por los códigos de construcción. Están simplemente apoyadas en sus extremos. Las vigas monolíticas se usan como testigos para comparar la respuesta estructural de sus contrapartes las vigas pre-fabricadas con conexiones mecánicas.

2.5.1 Objetivos específicos del programa experimental

El principal objetivo del programa experimental es evaluar la capacidad a flexión de la nueva configuración de conexión usada para unir elementos de hormigón reforzado pre-fabricados.

Este objetivo se alcanzó, mediante el ensayo de vigas construidas con una configuración de conectores y refuerzo convencional que difiere de las recomendaciones especificadas en códigos aplicables. Varias tareas específicas fueron ejecutadas para alcanzar este objetivo:

1. Verificación experimental de la respuesta estructural de vigas construidas con diferente configuración de conexión bajo cargas estáticas.
2. Ensayar vigas monolíticas convencionales con características geométricas similares, propiedades del material y condiciones de carga para usarlas como muestras de control.
3. Seleccionar y evaluar un conjunto de variables experimentales que permitan establecer recomendaciones de diseño y la verificación de la efectividad de la nueva configuración de conexión.

2.5.2 Variables experimentales

Teniendo como objetivo principal, de este programa experimental, la verificación de la resistencia y durabilidad de vigas pre-fabricadas unidas en base a una nueva configuración del sistema de conexión, el diseño del programa experimental considera algunas

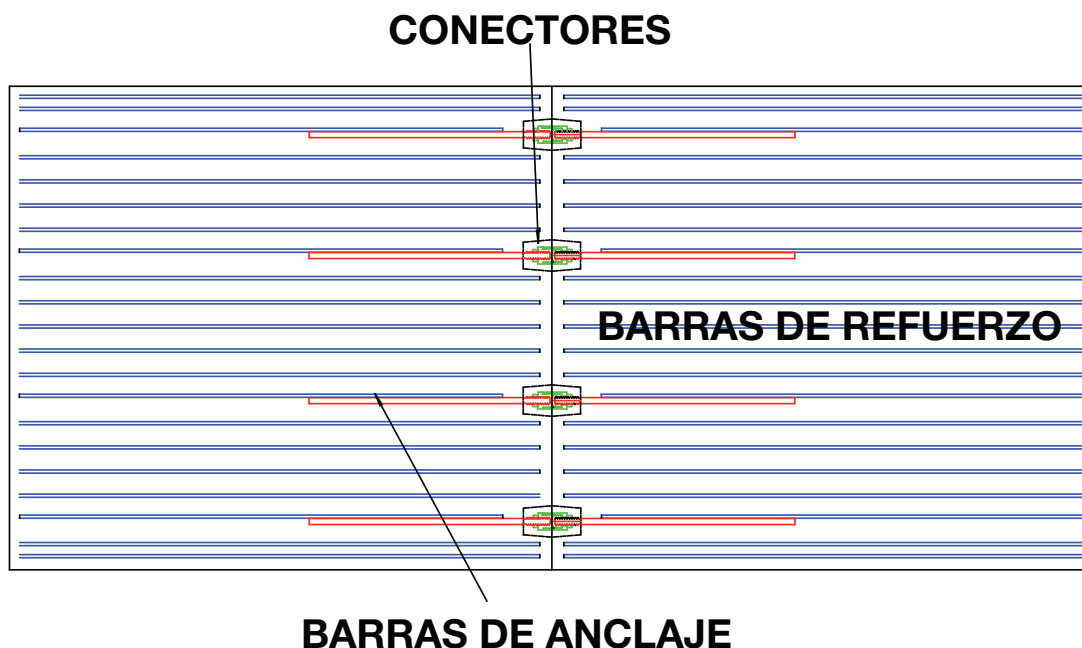


Figura 2.7: Vigas Pre-fabricadas: Distribución de Acero de refuerzo y Sistemas de Anclaje.

variables que pueden afectar el desempeño global de la nueva estructura. Las variables experimentales tomadas en cuenta son [21]:

Geometría de vigas: Longitud, Ancho, Profundidad

Barras de anclaje: Espaciamiento, Diámetro

Refuerzo convencional principal: Espaciamiento, Diámetro

Refuerzo convencional-anclajes: Relación entre el número de refuerzos convencionales y barras de anclaje

Dos grupos de vigas fueron ensayadas. El ancho de las vigas y su altura son constantes para el grupo 1, pero la profundidad efectiva es ligeramente modificada dependiendo del diámetro de las barras de anclaje. La figura 2.7 esquematiza la nueva propuesta de configuración de refuerzo y conexiones.

2.5.3 Adquisición de datos

Carga

La carga vertical estática aplicada en dos puntos ubicados en el tercio medio de las vigas, tal como se muestra en la figura 2.8, fue medida por una celda de carga conectada a un data-logger y controlada mediante un gato hidráulico.




Figura 2.8: Vigas Pre-fabricadas: Puntos de carga, condiciones de soporte y medidores de deformaciones.

Deformaciones en el acero y el hormigón

Medidores de deformaciones electrónicos fueron montados a diferentes distancias a partir de la mitad del vano. Las deformaciones en el hormigón y el acero, tanto de tracción como de compresión, fueron registradas para cada incremento de carga. Cada uno de los medidores de deformación, tipo strain-gauge, fueron conectados a un dispositivo electrónico de registro digital de datos.

Grietas

Medidores de ancho de grieta, tipo Omega, fueron instalados en la cara frontal y superior de las vigas de acuerdo a lo que se muestra en la figura 2.8. Se dió atención especial a la sección de conexión en donde hay una grieta pre-existente, originada por el proceso constructivo del elemento prefabricado.

El ancho de las grietas fue registrado y grabado, para cada incremento de carga, mediante un dispositivo electrónico tipo data-logger.

Deflexiones

Las deflexiones en la mitad del vano de las vigas y los desplazamientos de los extremos soportados fueron medidas mediante transductores de desplazamiento conectados a un dispositivo de registro de datos y grabadas para su posterior análisis.

Programa de carga

Un proceso quasi-estático incremental de carga y descarga fue aplicado a las vigas usando dos prensas hidráulicas en el tercio medio de las vigas.

Por otro lado, y como se describió anteriormente, la durabilidad de las vigas fue analizada bajo un estado de cargas de servicio. Para conseguir este objetivo, el programa

de carga consideró un total de cuatro ciclos de carga y descarga. La primera descarga fue aplicada cuando el esfuerzo máximo en la capa de refuerzo principal a tensión alcanzó 200 MPa (ciclo de 200 MPa). Los siguientes ciclos de carga-descarga quedan determinados cuando la capa de refuerzo principal a tensión alcanzó los 300 MPa (ciclo de 300 MPa).

2.6 PROPIEDADES DE LOS MATERIALES

2.6.1 Concreto

Todas las vigas fueron fabricadas usando la misma dosificación para la mezcla del concreto. Las proporciones de mezcla fueron 1:2.26:2 cemento: fino: agregado con una relación agua cemento de 0,46. Cemento tipo Portland fue usado para conseguir una resistencia a compresión del hormigón de 51.5 MPa. La tabla 2.7 muestra el detalle del diseño del hormigón.

Tabla 2.7: Diseño del hormigón Proporciones de mezcla y propiedades

| Gmax. [mm] | Slump [cm] | Air % | W/C % | s/a % | Unidades [Kg/m ³] | | | | | | |
|---------------|---------------|----------|----------|----------|-------------------------------|-----|-----|-----|-----|-------|-----|
| | | | | | W | C | C*2 | S | G | CSA*3 | AE |
| 20 | 65*1 | 4.5 | 46 | 46.9 | 175 | 380 | 120 | 759 | 859 | 30 | 6.4 |

2.6.2 Refuerzo principal

El refuerzo principal desarrolla esfuerzos de adherencia con el hormigón en base a las longitudes de empalme con las barras de anclaje. Dos funciones importantes cumple el refuerzo principal longitudinal. La primera es la transferencia de esfuerzos en el eje longitudinal y transversal de las vigas. La segunda es prevenir y controlar el agrietamiento de las vigas.

Las propiedades mecánicas del refuerzo principal fueron obtenidas experimentalmente. Diámetros y distribución diferentes del refuerzo principal fueron usados. El acero de las barras de refuerzo es del tipo SD-295A con un punto de fluencia a 295 MPa y un esfuerzo máximo de 440 MPa. Se usaron diámetros de barras de refuerzo de los siguientes diámetros: D6, D10, D13, D16, D19 y D22 [mm].




Figura 2.9: Esquema de una barra de anclaje tipo

2.6.3 Barras de anclaje

Cuatro diferentes diámetros son usados para las barras de anclaje en este programa experimental. Las barras de anclaje están embebidas a cada lado de la sección de conexión y conectadas mediante un sistema mecánico tipo macho-hembra como se describió anteriormente. Los esfuerzos son transferidos desde las barras de anclaje al concreto por adherencia y luego al refuerzo principal con longitudes de traslape diseñadas para el efecto. La longitud de las barras de anclaje es función de su diámetro y esta diseñada para evitar fallas de anclaje de tal modo que se pueda desarrollar toda la capacidad a flexión de las vigas. La figura 2.9 ilustra una barra de anclaje y la tabla 2.8 describe su geometría.

Adicionalmente, la tabla 2.9 presenta las propiedades mecánicas de las barras de anclaje y de refuerzo principal en función de su diámetro. Los datos están basados en las normas JISG3112 para acero SD295A. La tabla 2.10 presenta información sobre las propiedades mecánicas del sistema formado por las barras de anclaje y el conector mecánico.

2.6.4 Conectores mecánicos y tuercas de fijación

La función principal de los acopladores es proporcionar continuidad a las barras de anclaje. El acoplador se compone de un tornillo macho y un tornillo hembra soldados al anclaje. Los acopladores están situados en la mitad de vano de las vigas. Los conec-

Tabla 2.8: Dimensiones de las barras de anclaje

| Anclaje | D | M | H | L1 | L2 |
|---------|----|----|----|------|-----|
| Tipo | mm | mm | mm | mm | mm |
| D19 | 19 | 16 | 10 | 760 | 90 |
| D25 | 25 | 22 | 14 | 1000 | 115 |
| D32 | 32 | 36 | - | 1280 | - |
| D38 | 38 | 45 | - | 1520 | - |

Tabla 2.9: Propiedades mecánicas de las barras de anclaje y refuerzo

| | D10 | D13 | D16 | D19 | D25 | D32 | D38 |
|----------------|-----|-----|-----|-----|-----|-----|-----|
| fy MPa | 340 | 350 | 355 | 390 | 355 | 350 | 335 |
| fmaxMPa | 520 | 513 | 532 | 548 | 529 | 535 | 526 |
| Es GPa | 201 | 208 | 214 | 218 | 205 | 215 | 197 |

tores mecánicos fueron fabricados con acero JIS G 5502 - FCD600 [16], que tiene un esfuerzo de fluencia de 370 MPa y una resistencia máxima a la tensión de 600 MPa.

Tuercas de diámetros D19, D25, D32, y D39 [mm] fueron usadas para impedir el movimiento o deslizamiento de los conectores con respecto a las barras de anclaje.

2.6.5 El sistema de conexión

El sistema formado por el conector mecánico (Tornillos macho y hembra), las tuercas y dos barras de anclaje constituyen el mecanismo que se utiliza para conectar dos elementos prefabricados de hormigón reforzado para formar las vigas objeto de esta investigación. La figura 2.10 muestra esquemáticamente el sistema de anclaje utilizado en este estudio. La figura muestra el conector mecánico tipo macho-hembra, las barras de anclaje conectadas por medio del conector, y las barras de acero de refuerzo longitudinal traslapadas a las barras de anclaje para garantizar la transferencia de esfuerzos, a lo largo y ancho de las vigas.

El conjunto conector-barras de anclaje fue caracterizado mecánicamente y como resultado se obtuvieron las propiedades mecánicas que se muestran en la Tabla 2.9.

Tabla 2.10: Propiedades mecánicas del sistema Anclajes-Conector Mecánico

| Tipo | fy | f1 | fmax | Es1 | Es2 | Es3 |
|------|-----|-----|------|-----|------|-------|
| | MPa | MPa | MPa | GPa | MPa | MPa |
| D19 | 249 | 384 | 489 | 182 | 3303 | 3303 |
| D25 | 336 | 355 | 493 | 178 | 3465 | 13980 |
| D32 | 403 | 428 | 541 | 230 | 214 | 146 |
| D38 | 368 | 395 | 526 | 228 | 27 | 27 |



Figura 2.10: Esquema del sistema de conexión.

2.7 RESULTADOS EXPERIMENTALES

Las tablas 2.11, 2.12, 2.13, 2.14 presentan un resumen de los resultados experimentales obtenidos para las SERIE-I y SERIE-II. La tabla contiene la siguiente información [21]:

- 1 Identificación de la viga
- 2 Carga máxima evaluada teóricamente
- 3 Carga máxima evaluada experimentalmente
- 4 Momento máximo evaluado experimentalmente
- 5 Deflexión evaluada experimentalmente al 85 % de la carga máxima
- 6 Inercia a flexión en los ciclos de carga y descarga
- 7 Ancho máximo de grieta medido en la cara lateral de las vigas
- 8 Ancho máximo de grieta medido en la cara inferior de las vigas

Estos datos serán la base en el proceso de entrenamiento, y validación de los modelos basados en redes neuronales para el análisis y diseño de las vigas objeto de este estudio.

Tabla 2.11: RESULTADOS: SERIE I

| VIGA | SERIE I | | Max. Ancho de Grieta - LADO | | | Max. Ancho de Grieta - INFERIOR | | | | | |
|-------|---------------|---------------|-----------------------------|---------------------|--------|---------------------------------|--------|--------|--------|--------|--------|
| | Carga Teorica | Carga Experim | M Max | Defleccion 0.85Pmax | 200MPa | 300MPa | 300MPa | 200MPa | 300MPa | 300MPa | 300MPa |
| | (kN) | (kN) | (kN.m) | [mm] | [mm] | [mm] | [mm] | [mm] | [mm] | [mm] | [mm] |
| No.1 | 148 | 235 | 235 | 72 | 0.13 | 0.475 | 0.5 | 0.52 | 0.15 | 0.6 | 0.66 |
| No.2 | 164 | 326 | 326 | 64 | 0.33 | 0.872 | 0.93 | 0.96 | 0.28 | 0.72 | 0.76 |
| No.3 | 121 | 215 | 215 | 75 | 0.18 | 0.46 | 0.48 | 0.49 | 0.18 | 0.41 | 0.42 |
| No.4 | 115 | 197 | 197 | 68 | 0.24 | 0.834 | 0.96 | 1.03 | | | |
| No.5 | 115 | 231 | 231 | 70 | 0.13 | 0.432 | 0.47 | 0.48 | 0.16 | 0.56 | 0.61 |
| No.6 | 46 | 128 | 128 | 58 | 0.04 | 0.095 | 0.1 | 0.11 | 0.04 | 0.12 | 0.15 |
| No.7 | 134 | 219 | 219 | 75 | 0.31 | 0.847 | 0.9 | 0.91 | 0.35 | 1.05 | 1.16 |
| No.8 | 134 | 204 | 204 | 59 | 0.34 | 0.817 | 0.86 | 0.88 | 0.46 | 1.02 | 1.12 |
| No.9 | 134 | 230 | 230 | 66 | 0.38 | 0.833 | 0.87 | 0.9 | 0.48 | 1.05 | 1.15 |
| No.10 | 105 | 198 | 198 | 70 | 0.12 | 0.503 | 0.53 | 0.54 | 0.13 | 0.61 | 0.66 |
| No.11 | 117 | 212 | 212 | 71 | 0.23 | 0.609 | 0.63 | 0.65 | 0.27 | 0.74 | 0.81 |
| No.12 | 62 | 139 | 139 | 80 | 0.02 | 0.451 | 0.49 | 0.5 | 0.03 | 0.58 | 0.64 |
| No.13 | 115 | 179 | 179 | 71 | 0.38 | 1.041 | 1.1 | 1.13 | 0.46 | 1.27 | 1.4 |
| No.14 | 115 | 177 | 177 | 57 | 0.44 | 1.093 | 1.15 | 1.18 | 0.51 | 1.29 | 1.41 |
| No.15 | 82 | 168 | 168 | | 0.33 | 0.858 | 0.9 | 0.92 | 0.42 | 1.04 | 1.1 |
| No.16 | 82 | 187 | 188 | 67 | 0.13 | 0.455 | 0.48 | 0.5 | 0.14 | 0.57 | 0.63 |
| No.17 | 67 | 129 | 129 | 75 | 0.01 | 0.58 | 0.61 | 0.63 | 0.01 | 0.72 | 0.79 |
| No.18 | 53 | 170 | 170 | | | | | | | | |
| No.19 | 134 | 207 | 207 | 103 | 0.03 | 0.17 | 0.19 | 0.19 | 0.03 | 0.23 | 0.25 |
| No.20 | 126 | 210 | 210 | 175 | 0.05 | 0.272 | 0.29 | 0.3 | 0.05 | 0.36 | 0.4 |

Tabla 2.12: RESULTADOS: SERIE 1

| SERIE I VIGA | Inercia a Flexion E.I | | |
|-----------------|-----------------------|-----------------------|-----------------------|
| | 200 MPa | 300 MPa | Ultimate |
| | 3 | | |
| | [kN.mm ²] | [kN.mm ²] | [kN.mm ²] |
| No.1 | 62869 | 42776 | 13160 |
| No.2 | 60194 | 48404 | 19288 |
| No.3 | 58636 | 49304 | 11303 |
| No.4 | 54229 | 36621 | 11994 |
| No.5 | 65842 | 52062 | 12999 |
| No.6 | 71537 | 58045 | 9859 |
| No.7 | 53177 | 36285 | 11841 |
| No.8 | 47692 | 36926 | 14173 |
| No.9 | 48519 | 41878 | 14039 |
| No.10 | | | |
| No.11 | 53638 | 39864 | 12378 |
| No.12 | 72827 | 43909 | 7996 |
| No.13 | 45808 | 34029 | 10680 |
| No.14 | 43113 | 33716 | 12230 |
| No.15 | 40900 | 33544 | 8940 |
| No.16 | 57826 | 45813 | 11780 |
| No.17 | 74992 | 40199 | 8087 |
| No.18 | | | |
| No.19 | 70285 | 34806 | 8243 |
| No.20 | 77533 | 32529 | 5368 |

Tabla 2.13: RESULTADOS: SERIE II

| VIGA | SERIE II | | Max. Ancho de Grieta - LADO | | | Max. Ancho de Grieta - INFERIOR | | | | | | |
|------|---------------|---------------|-----------------------------|---------------------|--------|---------------------------------|--------|--------|--------|--------|--------|--------|
| | Carga Teorica | Carga Experim | M Max | Defleccion 0.85Pmax | 200MPa | 300MPa | 300MPa | 300MPa | 200MPa | 300MPa | 300MPa | 300MPa |
| | (kN) | (kN) | (kN.m) | [mm] | [mm] | 1 | 2 | 3 | [mm] | 1 | 2 | 3 |
| No.1 | 157 | 231 | 173 | 29.4 | 0.12 | 0.46 | 0.52 | 0.55 | 0.23 | 0.64 | 0.72 | 0.75 |
| No.2 | 154 | 239 | 179 | 33.6 | 0.07 | 0.36 | 0.39 | 0.4 | 0.13 | 0.5 | 0.53 | 0.54 |
| No.3 | 152 | 220 | 165 | 25.5 | 0.1 | 0.39 | 0.41 | 0.44 | 0.2 | 0.53 | 0.57 | 0.6 |
| No.4 | 236 | 306 | 229 | 34.7 | 0.28 | 0.91 | 0.98 | 1.03 | 0.32 | 1.01 | 1.09 | 1.15 |
| No.5 | 198 | 320 | 320 | 63.8 | 0.09 | 0.42 | 0.46 | 0.47 | 0.18 | 0.59 | 0.63 | 0.65 |
| No.6 | 99 | 180 | 180 | 89.7 | 0.02 | 0.43 | 0.48 | 0.5 | 0.19 | 0.71 | 0.78 | 0.81 |
| No.7 | 102 | 173 | 173 | 69.3 | 0.08 | 0.47 | 0.52 | 0.54 | 0.25 | 0.67 | 0.74 | 0.77 |
| No.8 | 154 | 231 | 173 | 49.4 | 0.01 | 0.79 | 0.81 | 0.81 | 0.02 | 0.28 | 0.3 | 0.31 |
| No.9 | 198 | 318 | 318 | 106.2 | 0.03 | 0.11 | 0.13 | 0.14 | 0.02 | 0.11 | 0.13 | 0.14 |

Tabla 2.14: RESULTADOS: SERIE II

| SERIE II VIGA | Inercia a Flexion E.I | | |
|------------------|-----------------------|-----------------------|-----------------------|
| | 200 MPa | 300 MPa | Ultimate |
| | 3 | | |
| | [kN.mm ²] | [kN.mm ²] | [kN.mm ²] |
| No.1 | 37338 | 24632 | 8674 |
| No.2 | 44130 | 27594 | 7954 |
| No.3 | 38819 | 26276 | 9780 |
| No.4 | 35912 | 22607 | 9605 |
| No.5 | 72053 | 50733 | 18675 |
| No.6 | 42805 | 31288 | 8140 |
| No.7 | 41047 | 31262 | 10037 |
| No.8 | 52279 | 26934 | 5168 |
| No.9 | 80578 | 64089 | 11235 |

Capítulo 3

MODELAMIENTO DEL CASO CON REDES NEURONALES

3.1 GENERALIDADES

3.1.1 Introducción y Motivación

El uso de elementos pre-fabricados da lugar a nuevas y mas complejas configuraciones estructurales [11]. Esta complejidad se refleja en dificultades implícitas para el diseño estructural de estos nuevos sistemas. Consecuencia directa de este proceso es la demanda por nuevos modelos matemáticos y métodos de solución que permitan analizar y diseñar estas estructuras.

Condiciones de pre-agrietamiento en la zona de conexión, a mas de un nuevo mecanismo de transferencia de esfuerzos, a lo largo y ancho de las vigas, generado por las barras de anclaje usadas como parte del mecanismo de conexión, contribuyen a la respuesta mecánica altamente no-lineal de los nuevos elementos estructurales.

Los métodos analíticos que emergen a raíz de esta demanda aún requieren de suposiciones que no permiten una solución exacta o de un nivel de precisión aceptable, en general, debido procesos no-lineales que caracterizan la respuesta estructural de estos nuevos elementos. Este es el caso de las vigas objeto de este estudio, la nueva configuración de las conexiones entre elementos pre-fabricados impone restricciones adicionales a los modelos matemáticos existentes, y por tanto es prioritario la propuesta de nuevos métodos que aproximen el fenómeno.

En las siguientes secciones se propone un esquema numérico que explota y combina las fortalezas de:

- (1) Un modelo basado en redes neuronales artificiales,
- (2) Una base de resultados experimentales que permite entrenar los modelos neurona-

les, y

(3) La mecánica clásica del hormigón reforzado, la cual es aplicable unicamente para analizar y diseñar vigas convencionales.

El resultado es una nueva metodología que permite analizar y diseñar las vigas no-convencionales objeto de este estudio. Si bien es cierto la metodología propuesta es validada para un caso específico, la propuesta es de caracter general, pues puede ser adaptada a otros sistemas estructurales.

Por otro lado, problemas de serviciabilidad y durabilidad estructural que se derivan del agrietamiento del concreto[18] son de gran preocupación por el interés de preservar la vida útil de cada elemento y por tanto del conjunto estructural.

La evaluación del ancho máximo de grieta superficial provee un importante parámetro de referencia para valorar la serviciabilidad y estado límite de estructuras de concreto que trabajan bajo severas condiciones ambientales (ej. regiones costeras).

Muchas investigaciones se han conducido para estudiar el mecanismo de crecimiento de las grietas que se desarrollan en estructuras de hormigón reforzado convencionales [18]. Sin embargo, la complejidad de la mecánica de fractura de estas estructuras no ha permitido hasta el momento generar modelos analíticos o numéricos que permitan predecir este fenómeno. En la actualidad se cuentan con varias ecuaciones empíricas, que se pueden encontrar en códigos de construcción en hormigón, para estimar el máximo ancho de grieta superficial. Estas ecuaciones empíricas son aplicables unicamente en estructuras que se ajustan a las condiciones de borde bajo las cuales fueron generadas. Adicionalmente, métodos numéricos como el de Elementos Finitos y Mecánica de la Fractura encierran complejidad y tiempos elevados para preparar la información requerida en el modelamiento del problema [6].

Ante estas dificultades, las redes neuronales artificiales (RNA) aparecen como un alternativa para generar modelos de análisis y diseño estructural que permitan, con cierto nivel de simplificación, resolver problemas con alto nivel de incertidumbre en las variables involucradas, y al mismo tiempo altos niveles de no-linealidad en la respuesta constitutiva de los materiales involucrados [2]. Como ventaja adicional está el reducido tiempo requerido, al menos en comparación con el tradicional método del elemento finito, para la implementación de procedimientos numéricos y la preparación de información requerida.

Estudios previos muestran aplicaciones de RNA en el campo de la ingeniería civil, por ejemplo: Adeli (1995) [2], Goh (1995) [10], Kunieda (1996) [14], Arahaki (1998) [14], Takeda (1998) [20], Basma (1999) [5] y Oh (1999) [17]. Estos enfoques pueden estar agrupados en tres categorías.

Adeli y Goh adoptaron un modelo RNA basado en el perceptrón de una capa en aplicaciones estructurales.

Kunieda, Arahaki y Takeda usaron el modelo perceptrón RNA multi-capa para tratar con la durabilidad del concreto y concreto reforzado.

Basma y Oh usaron un modelo RNA entrenado con el algoritmo de retropropagación para estudiar las propiedades del cemento y la dosificación de las mezclas de concreto.

Sin embargo, es importante resaltar que la literatura disponible no muestra aplicaciones de redes neuronales artificiales en la predicción del agrietamiento en estructuras de hormigón reforzado, y menos aún aplicaciones orientadas al análisis y diseño de estructuras no-convencionales. Este hecho motiva y justifica plenamente la propuesta de esta investigación, y se prevee un impacto en la comunidad de ingenieros estructurales que trabajan en el desarrollo de nuevos tipos de elementos estructurales.

3.1.2 Redes neuronales artificiales

La figura 3.1 esquematiza los principales componentes de un modelo de redes neuronales.

El diseño de una red neuronal es motivado por una analogía con el cerebro, el cual es una prueba viviente de que el procesamiento paralelo tolerante a fallas es no solo físicamente posible, sino que además es rápido y potente [12].

Una red neuronal es un procesador masivo distribuido, que tiene capacidad de almacenar conocimiento, y ponerlo en disponibilidad para ser usado. Este sistema ensambla dos aspectos del cerebro humano:

- (1) El conocimiento es adquirido por la red a través de un proceso de aprendizaje,
- (2) El peso de una conexión interna, conocido como pesos sinápticos, son usados para almacenar conocimiento.

El procedimiento empleado para implementar el proceso de aprendizaje es llamado "The learning process". El objetivo fundamental de este proceso de aprendizaje es modificar los pesos sinápticos de la red de una manera ordenada y sistemática con un




Figura 3.1: Arquitectura y Topología típica de un modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error

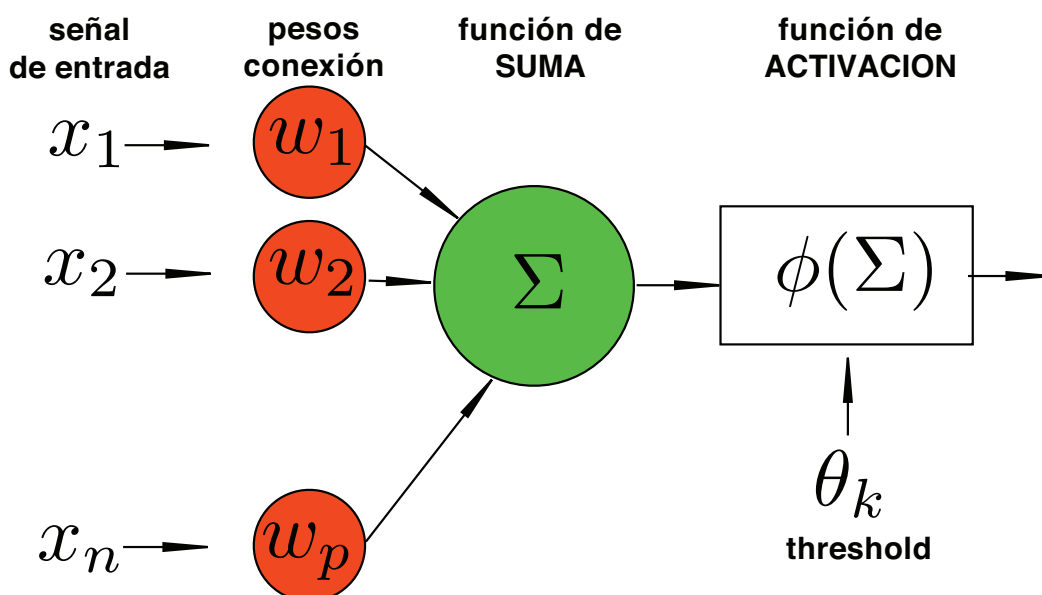


Figura 3.2: Esquema que muestra el funcionamiento de una neurona

adecuado algoritmo de entrenamiento.

Principales características de una red neuronal artificial

Una red neuronal artificial (RNA o ANN) deriva su poder computacional de: (1) su masiva estructura paralela distribuida, y (2) su habilidad de aprender y por tanto generalizar.

El proceso de generalización se refiere a la capacidad de la red para producir salidas razonables que se derivan de entradas que no fueron usadas en el proceso de entrenamiento, o definición de pesos de conexiones. Estas dos capacidades de procesamiento de información hacen posible que una red neuronal artificial pueda resolver problemas complejos, y que de otra manera no sería posible tratarlos.

En práctica, sin embargo, una red neuronal artificial no puede ofrecer una solución por si sola, por lo contrario, requieren ser integradas en un sistemático procesos ingenieril [12].

No linealidad: Una neurona es un dispositivo no lineal. Como consecuencia, una red neuronal artificial, construida en base a la interconexión de neuronas, es por si misma no lineal. La no-linealidad de una RNA es un propiedad importante, en particular, si el fenómeno a tratar es inherentemente no-lineal.

Mapeo entrada-salida: Un paradigma de aprendizaje, llamado supervisado, implica la modificación de pesos de conexiones por medio de un proceso en el que se alimenta a la red de un grupo de datos de entrenamiento. Cada elemento de este grupo de datos es un par único compuesto de una entrada y una salida deseada. Al alimentar la red con un par de datos, entrada-salida, los pesos de las conexiones se modifican para minimizar la diferencia entre la respuesta - salida - deseada y la respuesta dada por la red en un paso del proceso de entrenamiento. El proceso de aprendizaje es iterativo, este proceso termina cuando se consigue, en base a un criterio estadístico, que la salida de la red coincida con la deseada. Este proceso de entrenamiento se repite para muchos grupos de datos (entrada-salida), hasta que la red alcance un estado de equilibrio, en el cual no existen cambios importantes en el valor de los pesos asignados a las conexiones. De esta manera la red aprende en base a ejemplos y se construye un mapeo entrada-salida para cada problema de interés.

Adaptividad: Las redes neuronales artificiales tienen capacidades incorporadas para adaptar sus pesos sinápticos a cambios que se producen en su entorno. En particular, una red neuronal entrenada para operar en un ambiente específico, puede fácilmente ser re-entrenada para enfrentar cambios en las condiciones operativas del entorno. Los pesos de las conexiones en la red, pueden diseñarse para cambiar en tiempo real.

Tolerancia a la falla: Debido a la naturaleza distribuida de la información en una red neuronal, una falla producida en el entorno de la red tendría que ser muy extensa para que esta llegue a afectar el rendimiento global del sistema.

Uniformidad y Universalidad Una red neuronal artificial es un procesador universal de información. Esto es validado por el hecho de que la misma notación es usada para todos los dominios que requieren la aplicación de redes neuronales artificiales.

3.1.3 Procesos de aprendizaje

Entre todas las propiedades de interés en una red neuronal, una de mucha importancia es la habilidad de la red para aprender de su entorno, y de mejorar su rendimiento en base a un proceso de aprendizaje. Una red neuronal aprende de su entorno en base a un proceso iterativo en el cual se ajustan los pesos de las conexiones. Idealmente, una red neuronal conoce más acerca de su entorno luego de cada iteración.

En este contexto, el aprendizaje es un proceso por el cual los parámetros libres de una red se adaptan en base a un proceso continuo de estímulos del entorno. El tipo de aprendizaje queda determinado por la manera en la cual estos parámetros se actualizan [12].

3.1.4 Algoritmos de aprendizaje

Algoritmos de retro-propagación

El algoritmo de retro-propagación requiere de una arquitectura multi-capa en la red neuronal. El nombre de este algoritmo se deriva de el hecho de que los términos de error en el algoritmo son retro-propagados a través de la red de capa a capa de neuronas. Este algoritmo consiste de dos fases definidas como:

(1) **Paso adelante:** En el cual los pesos de las conexiones permanecen inalterados, y las funciones de la red son calculadas neurona por neurona. En la capa de salida,

el resultado obtenido es comparado con la respuesta deseada, de lo cual se obtiene el término de error. De esta manera, las operaciones hacia adelante comienzan al presentar el vector de entrada a la primera capa oculta de neuronas, y termina en la capa de salida con el cálculo de la señal de error para cada neurona de esta capa.

(2) Paso atrás: El paso hacia atrás se inicia en la capa de neuronas final al transmitir el error, capa por capa, en el sentido opuesto, y calculando recursivamente el gradiente para cada neurona. Este proceso recursivo permite que los pesos sinápticos de la red se ajusten de acuerdo a una regla determinada.

Algoritmos genéticos en el entrenamiento de una RNA

Un algoritmo genético (AG) es una técnica stocástica de búsqueda basada en las ideas de los mecanismos de selección natural. Inicia con una población inicial de soluciones aleatorias, llamadas cromosomas, que evolucionan en el tiempo o generan nuevos cromosomas. Luego de varias generaciones, el algoritmo converge hacia el mejor cromosoma, el cual representa una solución óptima al problema.

Esta técnica puede ser integrada en el proceso de aprendizaje de una red neuronal artificial. Esto es viable pues, tanto una RNA como un AG son técnicas de búsqueda. La regla de aprendizaje de una red neuronal ejecuta una búsqueda altamente restringida para optimizar su estructura. Un algoritmo genético ejecuta una búsqueda muy general en su población con el fin de encontrar un gen óptimo.

Si un algoritmo genético es usado como la regla de aprendizaje de una red neuronal, el código genético es una codificación directa de la red neuronal, con cada peso representado explícitamente. Para entrenar una red neuronal, en base a algoritmos genéticos, es necesario codificar los pesos de la red como cadenas de caracteres que representan los cromosomas ha ser modificados hasta encontrar una solución óptima.

Algoritmos genéticos vs. retro-propagación

La búsqueda de pesos óptimos de las conexiones, se reduce a un proceso de optimización, en el cual, se busca un mínimo de una función de error. Este proceso puede ser ejecutado, ya sea por: (1) Procesos heurísticos basados en gradientes, o (2) Procesos estocásticos como por ejemplo los algoritmos genéticos.

La principal diferencia entre estos dos métodos es la manera como cada uno de estos encuentra un nuevo vector de valores de pesos de las conexiones.

El algoritmo de retro-propagación es un proceso determinístico de búsqueda basado en el gradiente o en derivadas de orden superior para encontrar la siguiente solución. El principal problema de ese algoritmo es que el mínimo encontrado puede ser local.

Por otro lado, un algoritmo genético ejecuta una búsqueda multidireccional en base a un proceso aleatorio, con lo cual se evitan mínimos locales de la función multidimensional de error.

3.1.5 Objetivos específicos

Los objetivos de la aplicación de técnicas basadas en inteligencia artificial para el estudio de vigas pre-fabricadas de hormigón armado con conexiones son los siguientes.

- (1) El primer y principal objetivo es proponer una metodología que permita a la comunidad de diseñadores estructurales, la evaluación de la respuesta estructural de estructuras no convencionales en corto tiempo y de una forma relativamente simple.
- (2) El segundo es desarrollar procedimientos numéricos innovadores disponibles para problemas complejos de ingeniería y alcanzar soluciones prácticas.
- (3) El tercer objetivo es superar las limitaciones de las ecuaciones empíricas disponibles para la evaluación del ancho máximo de grieta superficial. Con esto se pretende extender su aplicabilidad a estructuras de hormigón reforzado que no satisfacen los requerimientos de códigos de diseño aplicables y vigentes.

3.1.6 Problemas en estudio

Se propone una metodología basada en redes neuronales artificiales para abordar y dar solución a tres problemas fundamentales del diseño en hormigón reforzado [18]:

- 1 Capacidad última a flexión:** El primer parámetro estructural evaluado, en base a un modelo de Red Neuronal Artificial, es la capacidad máxima a flexión de las vigas objeto de estudio.
- 2 Ancho máximo de grieta:** El segundo parámetro a ser evaluado es el valor del ancho máximo de grieta superficial en dos ciclos diferentes de carga y descarga. El primer punto de evaluación corresponde al ciclo denominado como de 200 MPa. En este ciclo la viga responde dentro del rango elástico. El segundo punto al cual se evalúa el ancho máximo de grieta corresponde al ciclo de 300 MPa en el cual la respuesta de la viga es puramente no lineal. En otras palabras, el modelo usado para predecir el ancho máximo de grieta a 200 MPa puede ser usado en la fase elástica del comportamiento de las vigas, y la arquitectura de Red Neuronal propuesta para el ciclo de 300 MPa podría ser usado en fases avanzadas, no lineales, de carga de la estructura.

3 Diseño a flexión: Finalmente, se propone un procedimiento basado en Redes Neuronales Artificiales para el diseño a flexión de las vigas con conexiones.

3.1.7 Estrategia de solución

La metodología propuesta en las siguientes secciones combina exitosamente:

- (1) Ecuaciones empíricas y deterministas propuestas por: Especificaciones Normalizadas para Concreto del Japón, y el Instituto Americano del Concreto, y
- (2) Un modelo basado en una combinación de técnicas de Inteligencia Artificial (Redes Neuronales Artificiales y Algoritmos Genéticos) para predecir la respuesta estructural de las vigas de hormigón pre-fabricado unidas en base a una nueva configuración de conexiones.

En lo que respecta al esquema de redes neuronales, estas son usadas y entrenadas para mapear la relación entre vectores de entrada y salida generados a partir de:

- (1) Parámetros físicos y geométricos que caracterizan la vigas en estudio,
- (2) Ecuaciones empíricas existentes que sirven de base para agrupar los parámetros mencionados anteriormente, y
- (3) Los datos experimentales disponibles para entrenar y validar los modelos propuestos.

Dos tipos diferentes de algoritmos de entrenamiento fueron empleados para establecer comparaciones y también intentar mejorar el desempeño del modelo neuronal. El primer método de entrenamiento emplea el algoritmo de retro-propagación de error y el segundo está basado en computación evolucionaria, que en el proceso de optimización de pesos de conexiones neuronales tiene el potencial de evitar mínimos locales en los cuales el algoritmo de retro-propagación puede incurrir.

Los modelos neuronales propuestos son probados en veinticuatro vigas pre-fabricadas unidas en la mitad del vano por el sistema mecánico de anclaje.

Los resultados obtenidos para el momento máximo y el ancho de grieta máximo muestran una excelente aproximación en relación a los valores experimentales.

Luego del proceso de entrenamiento de las redes neuronales, se usó un grupo de vigas para probar la efectividad del modelos en la predicción del comportamiento de vigas no previamente usadas en el entrenamiento.

3.1.8 Características de los modelos propuestos

Hay varias características significativas en los modelos basados en redes neuronales para estudiar la respuesta estructural de vigas pre-fabricadas.

- (1) Predicción, con un gran nivel de aproximación, del máximo ancho de grieta superficial que ocurre en estructuras RC no convencionales donde la aplicación directa de las ecuaciones de códigos de construcción disponibles no es posible.
- (2) Predicción, con un gran nivel de aproximación, de la resistencia máxima de las vigas en estudio pese al alto nivel de no linealidad que caracteriza la respuesta estructural de este tipo de elementos,
- (3) Un método simple pero confiable para el diseño de vigas no-convencionales, y
- (4) El modelo hace posible la predicción de varios parámetros estructurales como el máximo ancho superficial de grieta y máxima resistencia durante el tiempo de diseño. Esta característica importante da a los profesionales herramientas para evaluar parámetros requeridos para garantizar la resistencia y durabilidad de estructuras de concreto. Además, un alto grado de precisión es logrado con datos y procesamiento relativamente simples.

3.2 MODELAMIENTO BASADO EN REDES NEURONALES

3.2.1 Metodología

El desarrollo de un modelo RNA requiere una serie de decisiones antes de alcanzar la configuración de red mas adecuada para el problema a ser resuelto.

El arreglo de neuronas en capas, el número, forma y optimización del peso de cada una de las conexiones determinan la arquitectura de la Red Neuronal Artificial y su topología [12].

Se plantea el siguiente procedimiento para el modelado de problemas estructurales en base redes neuronales artificiales.

FASE I: ESTRUCTURA DE LA RED NEURONAL ARTIFICIAL

- (1) Decidir la arquitectura de la red neural y topología.
- (2) Decidir el proceso de aprendizaje.

FASE II: INTEGRACIÓN DEL PROBLEMA

- (1) División y pre-procesamiento de un conjunto de datos disponibles.
- (2) Diseño de vectores de entrada y salida.
- (3) Establecer relaciones de mapeo-entrenamiento.

FASE III: PRUEBAS Y PRODUCCIÓN

- (1) Validar el modelo ensayo criterio estadístico.
- (2) Producción

3.2.2 Análisis estadístico de los datos experimentales

Los datos experimentales disponibles para cada uno de los casos de estudio fueron sometidos a un análisis estadístico [19]. Este análisis se lo ejecutó con opciones disponibles en la herramienta computacional usada en este estudio. Como resultado de este análisis se dividió a estos datos en grupos de entrenamiento y grupos de producción o verificación.

3.2.3 Diseño de vectores de entrada y salida

CASO I: Predicción de la capacidad a flexión

La siguiente relación básica, derivada de la mecánica de estructuras de hormigón reforzado, se propone para ser integrada dentro de un esquema de red neuronal artificial para predecir la capacidad a flexión de las vigas pre-fabricadas objeto de este estudio.

El vector de entrada y salida de la red neuronal fue diseñado en base a la siguiente ecuación:

$$M_u = b.d^2.f'c.w.[1 - 0,59.w] \quad (3.1)$$

donde:

$$w = \frac{\rho.f_y}{f'c} \quad (3.2)$$

combinando estas ecuaciones podemos escribir:

$$\frac{1}{b.d^2.\rho.f_y.[1 - 0,59.\frac{\rho.f_y}{f'c}]} \Rightarrow \frac{1}{M_u} \quad (3.3)$$

donde:

M_u : Momento último

f'_c : Resistencia a la compresión del hormigón

f_y : Resistencia a la fluencia del sistema barras de anclaje + conectores

b : Ancho de la sección transversal de hormigón

d : Altura efectiva de la sección transversal

ρ : Cuantía de acero para las barras de anclaje

La estructura con la cual se plantea la expresión 3.3 nos permite visualizar tanto el vector de entrada (término del lado izquierdo) como el vector de salida (término del lado derecho) del modelo de red neuronal.

Se puede ver claramente que el término de entrada de la red considera propiedades geométricas y mecánicas de las vigas y materiales respectivamente para obtener como resultado la capacidad última de las vigas.

CASO II: Predicción del ancho de grieta

La relación entre vector de entrada y salida del modelo de red neuronal se establece en base a relaciones de mapeo apropiadas que son obtenidas de las ecuaciones descritas en secciones anteriores para la predicción del ancho máximo de grietas en vigas convencionales.

Tanto el vector de entrada como el de salida son diseñados para tener en cuenta parámetros estructurales relevantes que determinan el agrietamiento del hormigón.

El vector de salida de los modelos neuronales lo constituye el valor del ancho máximo de grieta superficial en las vigas en estudio, y el vector de entrada lo constituyen dos terminos:

- (1) El término izquierdo de la ecuación 3.7, el cual corresponde a la propuesta empírica de la Asociación de Ingenieros Civiles del Japón [16] en sus normativas de construcción, y
- (2) El término derecho de la ecuación 3.5 que representa la relación entre el espaciamiento del refuerzo y el de las barras de anclaje. Es bien conocido que el espaciamiento de refuerzo tiene relación directa con la respuesta al agrietamiento de estructuras de hormigón reforzado.

$$[4.c + 0,7 [c_s - \phi]] \Rightarrow w \quad (3.4)$$

$$S = \frac{C_s}{C_r} \quad (3.5)$$

Ciclo de 200 MPa El valor experimental del ancho máximo de grieta superficial, medido en las vigas con conexiones, fue utilizado como vector de salida del modelo de red neuronal. El ánimo es encontrar una relación de mapeo, entre el vector de entrada y el vector de salida deseado, durante la etapa de entrenamiento de la red. Este proceso de entrenamiento consigue establecer el peso de las conexiones entre las capas de neuronas que servirán posteriormente en la etapa de producción o predictiva.

Es importante recalcar que el ciclo de carga-descarga a 200 MPa se ubica dentro del rango de respuesta elástica de las vigas.

Ciclo de 300 MPa En el caso del ciclo de carga-descarga de 300 MPa la respuesta estructural de las vigas es puramente no-lineal. El diseño de los vectores de entrada y salida fue ajustado a esta condicionantes del problema. El vector de salida de la red neuronal considera en este caso el espesor de recubrimiento de hormigón como una variable determinante en el proceso de agrietamiento de este tipo de estructuras.

El nuevo esquema de vectores de entrada y salida de la red queda determinado por las siguiente ecuaciones:

$$[4.c + 0,7 [c_s - \phi]] \Rightarrow \frac{w}{c} \quad (3.6)$$

$$S = \frac{C_s}{C_r} \quad (3.7)$$

CASO III: Modelo de diseño a flexión

En esta sección se describe el modelo de red neuronal y la metodología propuesta para el diseño a flexión de vigas no convencionales.

Dados μ , b , d , f_y , f_c

Calcular cuantía de acero, $A_{s_{anchor}}$

Procedimiento de diseño propuesto:

Estimar Geometría de la sección: b , d

Definir el vector de entrada

$$ANN_{entrada} = \frac{M_u}{b.d^2.f'_c} \quad (3.8)$$

Calcular en base al modelo de red neuronal

$$ANN_{salida} = \frac{\rho \cdot fy}{f'c} \quad (3.9)$$

Calcular la cuantía de acero

$$\rho = ANN_{salida} \cdot \frac{f'c}{fy} \quad (3.10)$$

Calcular el área de acero requerida para las barras de anclaje

$$A_s = \rho \cdot b \cdot d \quad (3.11)$$

Diseño por durabilidad: estimar ancho de grieta máximo

$$ANN_{entrada} = 4 \cdot c + 0,7(C_s - \phi) \cdot \frac{f_s 200MPa}{E_s} \quad (3.12)$$

$$ANN_{salida} = W_{200MPa} \quad (3.13)$$

3.2.4 Resumen de datos experimentales

En esa sección se presenta una síntesis de los datos experimentales. Los datos presentados, en las tablas subsiguientes, se usan para el proceso de entrenamiento y producción de los modelos de redes neuronales planteados para dar solución a cada uno de los casos planteados en la sección previa.

Las tablas 3.1 y 3.2 presentan información sobre la geometría, configuración y área de refuerzo principal y de anclajes con las cuales se contruyeron las vigas.

3.2.5 Vectores de entrada y salida

A continuación se muestra varias tablas en las que resumen los valores obtenidos de ecuaciones anteriores con las cuales se definen los vectores de entrada y salida de las redes neuronales diseñadas para cada uno de los casos de estudio.

Tabla 3.1: Geometría y refuerzo en vigas de la SERIE-I

| Viga | L [m] | b [m] | d [mm] | c [mm] | Anclaje en Tension | | As [cm ²] | Refuerzo en Tension | | As [cm ²] | Refuerzo en Tension | |
|----------|-------|-------|--------|--------|-----------------------|-------------|-----------------------|-----------------------|-------------|-----------------------|---------------------|--------------|
| | | | | | Ref / Diam [-] / [mm] | Cs | | Ref / Diam [-] / [mm] | Cr | | | |
| No.01-S1 | 6.0 | 2.0 | 230 | 70 | 5D25 | 4/400 | 25.3 | 5D25 | 4/400 | 25.5 | 2D10+19D13 | 18/100+2/50 |
| No.02-S1 | 6.0 | 2.0 | 225 | 75 | 4D32 | 2/500+1/600 | 31.8 | 4D32 | 2/500+1/600 | 27.3 | 20D13+1D16 | 18/100+2/50 |
| No.03-S1 | 6.0 | 2.0 | 230 | 70 | 5D25 | 4/375 | 25.3 | 5D25 | 4/375 | 22.3 | 16D13+1D16 | 14/125+2/75 |
| No.04-S1 | 6.0 | 2.0 | 230 | 70 | 4D25 | 2/500+1/300 | 20.3 | 4D25 | 2/500+1/300 | 21.5 | 17D13 | 14/125+2/75 |
| No.05-S1 | 6.0 | 2.0 | 225 | 75 | 3D32 | 2/625 | 23.8 | 3D32 | 2/625 | 21.5 | 17D13 | 14/125+2/75 |
| No.06-S1 | 6.0 | 2.0 | 235 | 65 | 5D19 | 4/405 | 14.3 | 5D19 | 4/405 | 13.5 | 10D10+5D13 | 12/135+2/140 |
| No.07-S1 | 6.0 | 2.0 | 225 | 75 | 3D32 | 2/675 | 23.8 | 3D32 | 2/675 | 23.8 | 12D13+3D19 | 12/135+2/140 |
| No.08-S1 | 6.0 | 2.0 | 225 | 75 | 3D32 | 1/688+1/860 | 23.8 | 3D32 | 1/688+1/860 | 23.8 | 12D16 | 9/172+2/176 |
| No.09-S1 | 6.0 | 2.0 | 225 | 75 | 3D32 | 2/688 | 23.8 | 3D32 | 2/688 | 23.8 | 12D16 | 9/172+2/176 |
| No.10-S1 | 6.0 | 2.0 | 230 | 70 | 4D25 | 2/600+1/400 | 20.3 | 4D25 | 2/600+1/400 | 20.4 | 2D13+9D16 | 8/200+2/150 |
| No.11-S1 | 6.0 | 2.0 | 225 | 75 | 3D32 | 2/800 | 23.8 | 3D32 | 2/800 | 21.5 | 11D16 | 8/200+2/150 |
| No.12-S1 | 6.0 | 2.0 | 225 | 75 | 2D32 | 1/1000 | 15.9 | 2D32 | 1/1000 | 15.4 | 9D13+2D16 | 8/200+2/150 |
| No.13-S1 | 6.0 | 2.0 | 220 | 80 | 2D38 | 1/1050 | 22.8 | 2D38 | 1/1050 | 21.6 | 8D16+2D19 | 7/210+2/215 |
| No.14-S1 | 6.0 | 2.0 | 220 | 80 | 2D38 | 1/1000 | 22.8 | 2D38 | 1/1000 | 21.6 | 8D16+2D19 | 6/250+2/200 |
| No.15-S1 | 6.0 | 2.0 | 230 | 70 | 2D25+1D32 | 2/675 | 18.1 | 2D25+1D32 | 2/675 | 17.7 | 6D16+2D19 | 5/270 |
| No.16-S1 | 6.0 | 2.0 | 230 | 70 | 2D25+1D38 | 2/675 | 21.5 | 2D25+1D38 | 2/675 | 17.7 | 6D16+2D19 | 5/270 |
| No.17-S1 | 6.0 | 2.0 | 225 | 75 | 2D32 | 1/1350 | 15.9 | 2D32 | 1/1350 | 15.9 | 8D16 | 5/270+2/275 |

Tabla 3.2: Geometría y refuerzo en vigas de la SERIE-II

| Viga | L [m] | b [m] | d [mm] | c [mm] | Anclaje en Tension | | Refuerzo en Tension | | | |
|----------|----------|----------|-----------|-----------|--------------------------|--------------------------|--------------------------|--------------------------|------------|--------------|
| | | | | | As [cm ²] | Ref / Diam [-] / [mm] | As [cm ²] | Ref / Diam [-] / [mm] | Cr | |
| No.01-S2 | 4.5 | 1.0 | 225 | 75 | 15.9 | 2D32 | 1/500 | 15.9 | 8D13 | 5/128+2/130 |
| No.02-S2 | 4.5 | 1.0 | 225 | 75 | 15.9 | 2D32 | 1/500 | 15.7 | 5D13+2D16 | 6/150 |
| No.03-S2 | 4.5 | 1.0 | 225 | 75 | 15.9 | 2D32 | 1/500 | 15.4 | 4D16+2D13 | 3/200+2/150 |
| No.04-S2 | 4.5 | 1.0 | 220 | 80 | 22.8 | 2D38 | 1/500 | 23.1 | 5D13+2D16 | 6/150 |
| No.05-S2 | 6.0 | 2.0 | 225 | 75 | 31.77 | 4D32 | 3/500 | 31.3 | 10D16+4D19 | 12/150+1/100 |
| No.06-S2 | 6.0 | 2.0 | 175 | 75 | 23.83 | 3D32 | 2/600 | 23.15 | 12D13+4D16 | 13/126+2/131 |
| No.07-S2 | 6.0 | 2.0 | 175 | 75 | 23.83 | 3D32 | 2/600 | 23.5 | 6D13+8D10 | 11/146+2/141 |

Tabla 3.3: SERIE - I Vectores de entrada y salida

| Viga | RESULTADOS EXPERIMENTALES | | | | | | | | | | GRIETAS | | | | | |
|----------|---------------------------|-------|-------|---------|---------|---------|--------|-----------|-----------|-----------|------------------|-----------|-----------|------------------|--------|---------|
| | 200 MPa | | | | | 300 MPa | | | | | Ciclo de 200 MPa | | | Ciclo de 300 MPa | | |
| | Mu | w | [mm] | 200 MPa | 300 MPa | w | [mm] | ENTRADA | | SALIDA | | Eq. [3.6] | Eq. [3.7] | Cs/Cr | w | 300 MPa |
| | | | | | | | | Eq. [3.4] | Eq. [3.5] | Eq. [3.6] | Eq. [3.7] | | | | | |
| No.01-S1 | 235 | 0.151 | 0.600 | 0.1068 | 0.2375 | 0.151 | 0.4270 | 0.2375 | 0.0104 | 0.0104 | 0.2375 | 0.0104 | 0.0104 | 0.0104 | 0.0104 | 0.0104 |
| No.02-S1 | 326 | 0.279 | 0.717 | 0.1061 | 0.1782 | 0.279 | 0.3902 | 0.1782 | 0.0122 | 0.0122 | 0.3902 | 0.0122 | 0.0122 | 0.0122 | 0.0122 | 0.0122 |
| No.03-S1 | 215 | 0.181 | 0.414 | 0.1292 | 0.3166 | 0.181 | 0.4403 | 0.3166 | 0.0072 | 0.0072 | 0.4403 | 0.0072 | 0.0072 | 0.0072 | 0.0072 | 0.0072 |
| No.04-S1 | 197 | 0.236 | 0.834 | 0.1180 | 0.2500 | 0.236 | 0.9710 | 0.2500 | 0.0145 | 0.0145 | 0.9710 | 0.0145 | 0.0145 | 0.0145 | 0.0145 | 0.0145 |
| No.05-S1 | 231 | 0.161 | 0.546 | 0.0879 | 0.1900 | 0.161 | 0.3535 | 0.1900 | 0.0093 | 0.0093 | 0.3535 | 0.0093 | 0.0093 | 0.0093 | 0.0093 | 0.0093 |
| No.06-S1 | 128 | 0.038 | 0.120 | 0.0315 | 0.3350 | 0.038 | 0.1157 | 0.3351 | 0.0022 | 0.0022 | 0.1157 | 0.0022 | 0.0022 | 0.0022 | 0.0022 | 0.0022 |
| No.07-S1 | 219 | 0.354 | 1.051 | 0.2140 | 0.2010 | 0.354 | 0.7328 | 0.2011 | 0.0178 | 0.0178 | 0.7328 | 0.0178 | 0.0178 | 0.0178 | 0.0178 | 0.0178 |
| No.08-S1 | 204 | 0.456 | 1.024 | 0.3361 | 0.2231 | 0.456 | 0.8748 | 0.2232 | 0.0174 | 0.0174 | 0.8748 | 0.0174 | 0.0174 | 0.0174 | 0.0174 | 0.0174 |
| No.09-S1 | 230 | 0.483 | 1.045 | 0.2910 | 0.2510 | 0.483 | 0.7974 | 0.2510 | 0.0177 | 0.0177 | 0.7974 | 0.0177 | 0.0177 | 0.0177 | 0.0177 | 0.0177 |
| No.10-S1 | 198 | 0.132 | 0.608 | 0.1159 | 0.4068 | 0.132 | 0.4661 | 0.4069 | 0.0106 | 0.0106 | 0.4661 | 0.0106 | 0.0106 | 0.0106 | 0.0106 | 0.0106 |
| No.11-S1 | 212 | 0.274 | 0.744 | 0.1310 | 0.2380 | 0.274 | 0.5624 | 0.2375 | 0.0126 | 0.0126 | 0.5624 | 0.0126 | 0.0126 | 0.0126 | 0.0126 | 0.0126 |
| No.12-S1 | 139 | 0.031 | 0.575 | 0.0548 | 0.1900 | 0.031 | 0.5098 | 0.1900 | 0.0097 | 0.0097 | 0.5098 | 0.0097 | 0.0097 | 0.0097 | 0.0097 | 0.0097 |
| No.13-S1 | 179 | 0.458 | 1.273 | 0.2952 | 0.2010 | 0.458 | 0.9172 | 0.2011 | 0.0209 | 0.0209 | 0.9172 | 0.0209 | 0.0209 | 0.0209 | 0.0209 | 0.0209 |
| No.14-S1 | 177 | 0.512 | 1.292 | 0.3770 | 0.2375 | 0.512 | 0.9156 | 0.2375 | 0.0212 | 0.0212 | 0.9156 | 0.0212 | 0.0212 | 0.0212 | 0.0212 | 0.0212 |
| No.15-S1 | 168 | 0.421 | 1.035 | 0.2096 | 0.4021 | 0.421 | 0.6713 | 0.4021 | 0.0108 | 0.0108 | 0.6713 | 0.0108 | 0.0108 | 0.0108 | 0.0108 | 0.0108 |
| No.16-S1 | 188 | 0.142 | 0.574 | 0.1210 | 0.4020 | 0.142 | 0.4507 | 0.4021 | 0.0100 | 0.0100 | 0.4507 | 0.0100 | 0.0100 | 0.0100 | 0.0100 | 0.0100 |
| No.17-S1 | 129 | 0.013 | 0.723 | 0.0463 | 0.0201 | 0.013 | 0.8087 | 0.0201 | 0.0123 | 0.0123 | 0.8087 | 0.0123 | 0.0123 | 0.0123 | 0.0123 | 0.0123 |

Tabla 3.4: SERIE - I Vectores de entrada y salida

| Viga | RESULTADOS EXPERIMENTALES | | MOMENTO | | DISEÑO VIGAS | |
|----------|---------------------------|---------|---------|-----------|--------------|---------|
| | μ | w | RNA | SALIDA | RNA | SALIDA |
| | [kN.m] | 200 MPa | 300 MPa | Eq. [3.3] | Eq. [3.9] | |
| | | [mm] | [mm] | Izquierda | Izquierda | Derecha |
| No.01-S1 | 235 | 0.151 | 0.600 | 0.00521 | 0.04313 | 0.03517 |
| No.02-S1 | 326 | 0.279 | 0.717 | 0.00358 | 0.06252 | 0.05344 |
| No.03-S1 | 215 | 0.181 | 0.414 | 0.00521 | 0.03945 | 0.03527 |
| No.04-S1 | 197 | 0.236 | 0.834 | 0.00649 | 0.03616 | 0.02826 |
| No.05-S1 | 231 | 0.161 | 0.546 | 0.00474 | 0.04430 | 0.04075 |
| No.06-S1 | 128 | 0.038 | 0.120 | 0.00867 | 0.02250 | 0.02512 |
| No.07-S1 | 219 | 0.354 | 1.051 | 0.00474 | 0.04200 | 0.04042 |
| No.08-S1 | 204 | 0.456 | 1.024 | 0.00474 | 0.03912 | 0.04042 |
| No.09-S1 | 230 | 0.483 | 1.045 | 0.00474 | 0.04411 | 0.04042 |
| No.10-S1 | 198 | 0.132 | 0.608 | 0.00649 | 0.03634 | 0.02826 |
| No.11-S1 | 212 | 0.274 | 0.744 | 0.00474 | 0.04065 | 0.03660 |
| No.12-S1 | 139 | 0.031 | 0.575 | 0.00705 | 0.02668 | 0.02717 |
| No.13-S1 | 179 | 0.458 | 1.273 | 0.00553 | 0.03598 | 0.03177 |
| No.14-S1 | 177 | 0.512 | 1.292 | 0.00553 | 0.03559 | 0.03622 |
| No.15-S1 | 168 | 0.421 | 1.035 | 0.00726 | 0.03083 | 0.02525 |
| No.16-S1 | 188 | 0.142 | 0.574 | 0.00611 | 0.03445 | 0.02999 |
| No.17-S1 | 129 | 0.013 | 0.723 | 0.00705 | 0.02474 | 0.02717 |

Tabla 3.5: Serie II - Vectores de Entrada y Salida - Flexión

| Viga | RESULTADOS EXPERIMENTALES | | | | GRIETAS | | | | | |
|----------|---------------------------|--------|---------|--------|---------------------|--------------------|---------------------|--------------------|-------|-------|
| | 200 MPA | | 300 MPA | | Ciclo de 200 Mpa | | Ciclo de 300 Mpa | | | |
| | μ | w [mm] | μ | w [mm] | ENTRADA | SALIDA | ENTRADA | SALIDA | | |
| No.01-S2 | 231 | 0.227 | 0.641 | 0.113 | Eq. [3.3] w JSCE | Eq. [3.9] Cs/Cr | Eq. [3.6] w JSCE | Eq. [3.7] Cs/Cr | 0.258 | 0.277 |
| No.02-S2 | 239 | 0.132 | 0.496 | 0.110 | 0.300 | 0.300 | 0.235 | 0.300 | 0.300 | 0.132 |
| No.03-S2 | 220 | 0.196 | 0.533 | 0.112 | 0.360 | 0.360 | 0.297 | 0.360 | 0.360 | 0.196 |
| No.04-S2 | 306 | 0.315 | 1.008 | 0.224 | 0.300 | 0.300 | 0.256 | 0.300 | 0.300 | 0.315 |
| No.05-S2 | 320 | 0.180 | 0.588 | 0.110 | 0.292 | 0.292 | 0.287 | 0.292 | 0.292 | 0.180 |
| No.06-S2 | 179 | 0.194 | 0.709 | 0.103 | 0.212 | 0.212 | 0.267 | 0.212 | 0.212 | 0.194 |
| No.07-S2 | 173 | 0.249 | 0.667 | 0.126 | 0.243 | 0.243 | 0.281 | 0.234 | 0.234 | 0.249 |

Tabla 3.6: Serie II - Vectores de entrada y salida - Agrietamiento

| Viga | RESULTADOS EXPERIMENTALES | | MOMENTO | | DISEÑO VIGAS | | |
|----------|---------------------------|---------|---------|--------------|--------------|--------------|---------|
| | μ | w | RNA | VECTORES I/O | RNA | VECTORES I/O | |
| | [kN.m] | 200 MPA | 300 MPA | ENTRADA | SALIDA | ENTRADA | SALIDA |
| | | [mm] | [mm] | Eq. [3.3] | 1/ μ | Eq. [3.9] | |
| | | | | Izquierda | Exp. | Izquierda | Derecha |
| No.01-S2 | 231 | 0.227 | 0.641 | 0.00418 | 0.00433 | 0.0686 | 0.05521 |
| No.02-S2 | 239 | 0.132 | 0.496 | 0.00418 | 0.00418 | 0.06167 | 0.05521 |
| No.03-S2 | 220 | 0.196 | 0.533 | 0.00418 | 0.00455 | 0.06438 | 0.05521 |
| No.04-S2 | 306 | 0.315 | 1.008 | 0.00366 | 0.00327 | 0.12276 | 0.07399 |
| No.05-S2 | 320 | 0.180 | 0.588 | 0.00359 | 0.00313 | 0.06137 | 0.05521 |
| No.06-S2 | 179 | 0.194 | 0.709 | 0.00614 | 0.00559 | 0.05675 | 0.05324 |
| No.07-S2 | 173 | 0.249 | 0.667 | 0.00614 | 0.00578 | 0.05484 | 0.05324 |

Capítulo 4

ANÁLISIS DE RESULTADOS

4.1 PROCESAMIENTO DE DATOS

La división y el pre-procesamiento de los datos experimentales es un factor importante para mejorar el rendimiento de los modelos basados en redes neuronales. La primera fase es la división de datos, de acuerdo a lo propuesto por Shahin:2000, debe sujetarse al siguiente criterio: 70 % del total de datos disponibles debería ser usado en la fase de entrenamiento de la red, y el restante 30 % debería ser usado en el proceso de validación del modelo.

La aplicación de este criterio resulta en el uso de 17 vigas con conexiones en el entrenamiento de la red, y 7 vigas en la etapa de validación - producción.

Es importante anotar, que los vectores de entrada de los modelos de red propuestos en esta investigación han sido normalizados, es decir, los valores pertenecen al set cerrado $[0,1]$. Esta condición emerge por el uso de funciones sinusoidales como funciones de transferencia a nivel neuronal. Consecuencia de este hecho es tener únicamente salidas en el rango $[0,1]$.

4.2 AQUITECTURA DE RED NEURONAL

La determinación de la arquitectura y topología de una red neuronal artificial es una tarea compleja. Sin embargo puede intentar resumirse en base la siguiente secuencia de actividades [12]:

- 1 Arreglar neuronas en varias capas, capa de entrada, capas intermedias y capa de salida.
- 2 Decidir el tipo de conexiones entre neuronas




Figura 4.1: Arquitectura y Topología típica de un modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error

- 3 Decidir la manera en que una neurona recibe datos y produce la salida y tipo de datos
- 4 Decidir el peso inicial de las conexiones

El criterio de simplicidad prima en la determinación de la topología de los modelos neuronales a ser propuestos. La simplicidad se busca a la medida que se pretende difundir el uso de esta herramienta en una comunidad que no necesariamente está familiarizada con este tipo de esquemas de modelamiento, ni con sus fundamentos teóricos. Además, la simplicidad de los modelos propuestos redundará en períodos de tiempo cortos para su implementación y posterior uso en aplicaciones reales de diseño estructural.

En términos generales, los modelos de red neuronal artificial, con los que se trabajará en adelante, se basan en arquitecturas y topologías dadas por el modelo de PERCEPTRON DE UNA CAPA [12]. Este tipo de arquitectura se caracteriza por unidades neuronales enlazadas por capas de acuerdo al esquema mostrado por la figura 4.1. Los nodos de la capa de entrada representan a los nodos fuente de información, esto es, conforman el vector de entrada con información que caracteriza y es relevante al problema a ser solucionado. El diseño de los vectores de entrada que se utilizarán en este trabajo quedó definido en secciones anteriores.

4.3 TOPOLOGIA DE LA RED

Una vez que la arquitectura de red neuronal ha sido decidida, es necesario diseñar la configuración de neuronas divididas en tres capas: (1) Capa de entrada, (2) Capa interna, y (3) Capa de salida.

Puesto que el diseño de vectores de entrada y salida fue definido ya en secciones anteriores, esta sección se centra en describir la metodología usada para determinar el número de neuronas requeridas en la capa interna de la red con las cuales se optimiza el rendimiento de la red en términos del coeficiente de correlación determinado en función de respuestas del modelo y de las respuestas esperadas que fueron obtenidas experimentalmente.

El proceso consiste en evaluar el rendimiento de la red, (en términos del coeficiente de correlación), cuando el número de neuronas en la capa interna de la red es modificado. La tabla 4.1 presenta los resultados obtenidos para la topología de red de cada uno de los casos de interés para este estudio.

Tabla 4.1: Número de neuronas por capa

| | Mu | Diseño | 200 Mpa | 300 Mpa |
|---------------|-----------|---------------|----------------|----------------|
| BP-ANN | 1/12/1 | 1/12/1 | 2/12/1 | 2/24/1 |
| GA-ANN | 1/84/1 | 1/12/1 | 2/60/1 | 2/72/1 |

Donde:

BP-ANN: representa el modelo de red entrenado en base al algoritmo de retro-propagación de error

GA-ANN: representa el modelo de red entrenado en base algoritmos genéticos.

1/12/1: 1 neurona en el vector de entrada, 12 neuronas en la capa intermedia, y 1 neurona en el vector de salida

La figura 4.2 muestra la relación entre rendimiento del modelo de red para el caso de predicción del ancho máximo de grieta (ciclo de 200 MPa) en función del número de neuronas de la capa interna. Como puede verse, el valor mas alto de coeficiente de correlación se obtiene cuando el número de neuronas de la capa interna de la red es igual a 12. La tabla 4.1 fue obtenida de procedimientos similares para cada uno de los casos en estudio.

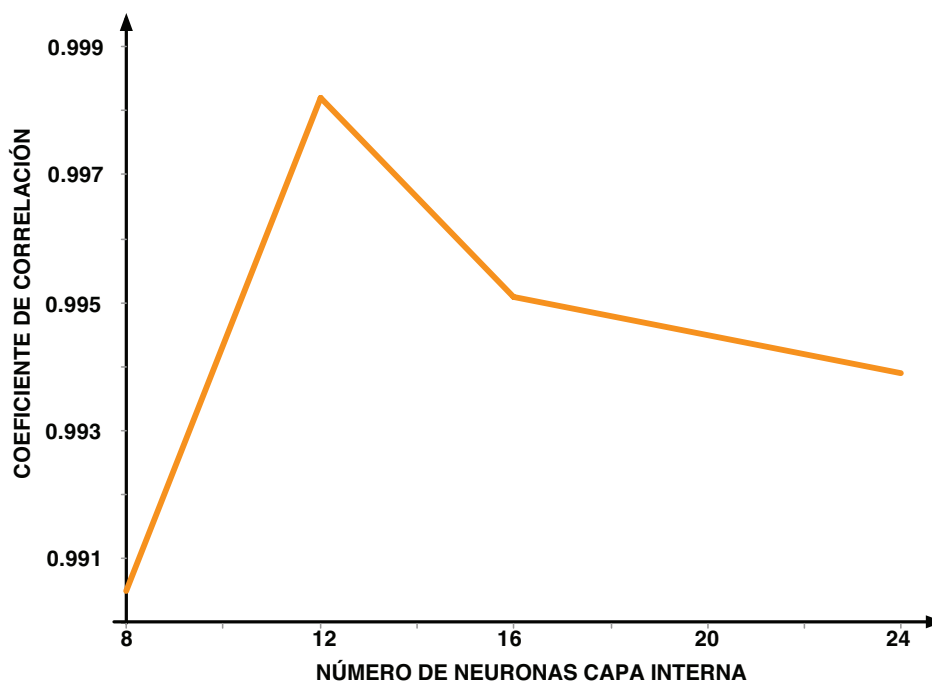


Figura 4.2: Determinación del número de neuronas óptimo en la capa interna de la red neuronal. El valor máximo del coeficiente de correlación está asociado con el número de neuronas requerido para alcanzar ese valor pico de rendimiento.

4.4 MODELOS NEURONALES PARA FLEXIÓN

4.4.1 Capacidad última

Modelo basado en retro-propagación

La figura 4.3 muestra esquemáticamente el modelo de red neuronal utilizado para predecir la capacidad última a flexión de vigas pre-fabricadas con conexiones mecánicas en la zona de momento máximo. El modelo mostrado en la figura corresponde a la red entrenada en base al algoritmo de retro-propagación del error para la determinación de pesos de conexiones entre capas de neuronas.

Por simplicidad, se decidió emplear una sola capa interna de neuronas en este estudio. Este acercamiento a la solución del problema permite además establecer un estudio paramétrico para establecer comparaciones con diferentes alternativas de entrenamiento de la red.

El procedimiento descrito en líneas superiores fue utilizado para determinar el número de neuronas en la capa interna, y se llegó a determinar, que para esta aplicación específica el número de neuronas requeridas en la capa interna es de 12.

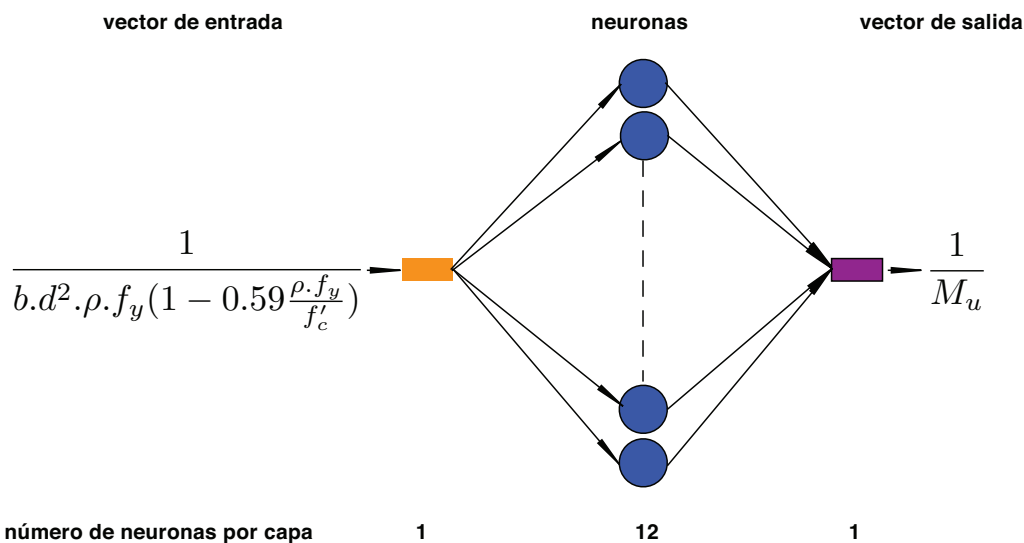


Figura 4.3: Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para la predicción la capacidad última a flexión de vigas no convencionales.

Modelo basado en algoritmos genéticos

La figura 4.4 muestra un modelo neuronal con una capa interna que consta de 84 neuronas y que fue entrenado en base a algoritmos genéticos. Como se verá mas adelante, los resultados muestran que el rendimiento de la red es superior para el modelo entrenado con algoritmos genéticos. La justificación puede estar dada por dos factores: (1) mayor número de neuronas internas, y (2) el proceso de optimización que se consigue en base a algoritmos genéticos tiene la capacidad de evitar mínimos locales en la función de error.

4.4.2 Diseño a flexión

Modelo basado en retro-propagación

La figura 4.5 muestra esquemáticamente el modelo de red neuronal adoptado para implementar un proceso de diseño a flexión de las vigas con conexión. La capa interna cuenta con 12 neuronas, este número fue determinado por el mismo procedimiento de evaluación del coeficiente de correlación descrito anteriormente.

Modelo basado en algoritmos genéticos

Siguiendo la misma secuencia de descripción de los modelos utilizados, la figura 4.6 presenta el modelo de red neuronal que implementa el procedimiento de diseño a flexión




Figura 4.4: Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para la predicción la capacidad última a flexión de vigas no convencionales.

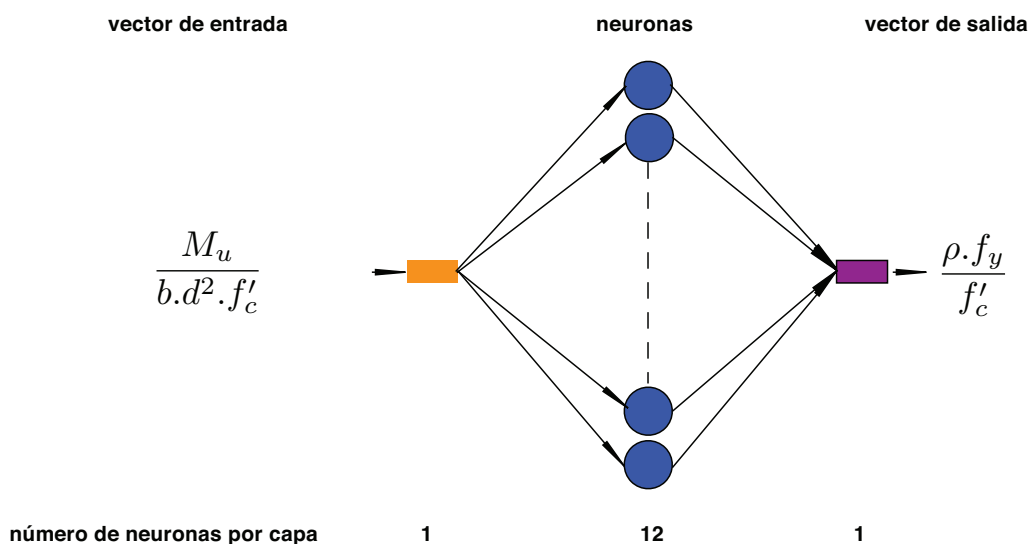


Figura 4.5: Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para el diseño a flexión de vigas no convencionales.

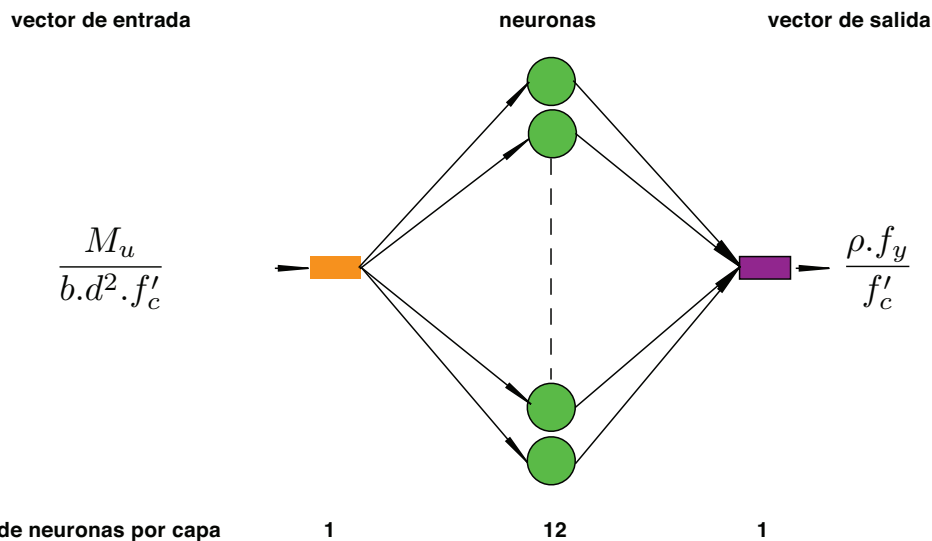


Figura 4.6: Modelo de red neuronal con entrenamiento basado en algoritmos genéticos para el diseño a flexión de vigas no convencionales.

de este nuevo tipo de vigas. A diferencia del modelo anterior, el peso de conexiones entre neuronas se establece en base un proceso de optimización basado en algoritmos genéticos. En este caso, el número de neuronas internas establecido, de acuerdo a procedimientos ya descritos, es igual al requerido en el caso de entrenamiento basado en retro-propagación del error, esto es 12 neuronas.

4.5 MODELOS NEURONALES PARA EL ANCHO DE GRIETA

4.5.1 Ancho de grieta 200 MPa

Modelo basado en retro-propagación

La figura 4.7 muestra esquemáticamente la topología propuesta para la red neuronal que permite la predicción del ancho máximo de grieta superficial en el ciclo de carga y descarga identificado como de 200 MPa. El proceso de entrenamiento de la red se base en un algoritmo de retro-propagación de error.

Modelo basado en algoritmos genéticos

La figura 4.8 muestra esquemáticamente la topología propuesta para la red neuronal que permite la predicción del ancho máximo de grieta superficial en el ciclo de carga




Figura 4.7: Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para la predicción del ancho máximo de grieta en el ciclo de 200 MPa.

y descarga identificado como de 200 MPa. A diferencia del esquema basado en retro-propagación del error, el modelo planteado fija los pesos de las conexiones de la red, en base a un proceso de optimización logrado en base a algoritmos genéticos.

4.5.2 Ancho de grieta 300 MPa

Modelo basado en retro-propagación

La figura 4.9 muestra esquemáticamente la topología propuesta para la red neuronal que permite la predicción del ancho máximo de grieta superficial en el ciclo de carga y descarga identificado como de 300 MPa. El proceso de entrenamiento de la red se base en un algoritmo de retro-propagación de error.

Modelo basado en algoritmos genéticos

La figura 4.10 muestra esquemáticamente la topología propuesta para la red neuronal que permite la predicción del ancho máximo de grieta superficial en el ciclo de carga y descarga identificado como de 300 MPa. A diferencia del esquema basado en retro-propagación del error, el modelo planteado fija los pesos de las conexiones de la red, en base a un proceso de optimización logrado en base a algoritmos genéticos.




Figura 4.8: Modelo de red neuronal con entrenamiento basado en el algoritmo genético para la predicción del ancho máximo de grieta en el ciclo de 200 MPa.

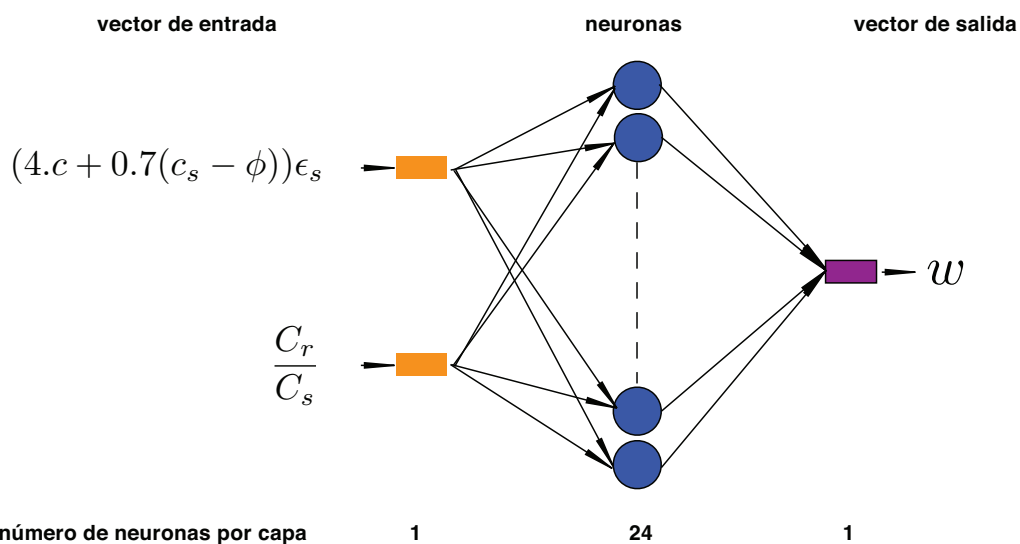


Figura 4.9: Modelo de red neuronal con entrenamiento basado en el algoritmo de retro-propagación del error para la predicción del ancho máximo de grieta en el ciclo de 300 MPa.




Figura 4.10: Modelo de red neuronal con entrenamiento basado en el algoritmos genéticos para la predicción del ancho máximo de grieta en el ciclo de 300 MPa.

4.6 RESULTADOS

En esta sección se presentan los resultados obtenidos, en la etapa de producción o predicción, para cada uno de los casos de estudio.

Las tablas presentadas a continuación, una por caso de estudio, muestra el grupo de vigas usadas en la etapa de validación del modelo unicamente. El resto de vigas fueron usadas para entrenar la red, es decir, para ajustar pesos de conexiones en base a un algoritmo de optimización.

4.6.1 Capacidad última

En esta sección se presentan los resultados obtenidos del modelo neuronal como predicción de la predicción de la capacidad última de un grupo de vigas. La tabla 4.2 presenta los resultados tanto experimentales, como los obtenidos en el modelo neuronal entrenado con retro-propagación (ANN), como del modelo entrenado con algoritmos genéticos. La figura 4.11 muestra un comparativo de datos experimentales, y de aquellos obtenidos como predicción de los modelos.

La figura 4.11 muestra, adicionalmente, un comparativo de los valores calculados en base a datos experimentales v.s. los valores obtenidos del modelo de red neuronal en la etapa de predicción, tanto por el modelo neuronal entrenado con algoritmos genéticos como con el modelo entrenado con retro-propagación.

Tabla 4.2: Predicción del Momento Último

| Viga | ENTRADA | calculado | 1/Mu PREDICCIÓN | |
|------------|---------|-----------|--------------------|---------|
| | | | ANN | ANN+GA |
| No.01 - S1 | 0.00521 | 0.00425 | 0.00424 | 0.00425 |
| No.05 - S1 | 0.00474 | 0.00433 | 0.00443 | 0.00443 |
| No.15 - S1 | 0.00726 | 0.00595 | 0.00683 | 0.00583 |
| No.16 - S1 | 0.00611 | 0.00533 | 0.00580 | 0.00580 |
| No.02 - S2 | 0.00418 | 0.00418 | 0.00399 | 0.00398 |
| No.05 - S2 | 0.00359 | 0.00313 | 0.00362 | 0.00362 |
| No.06 - S2 | 0.00614 | 0.00559 | 0.00582 | 0.00542 |




Figura 4.11: Comparación de resultados obtenidos para el momento último. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error.

4.6.2 Diseño a flexión

La tabla 4.3 presenta resultados obtenidos en la etapa de predicción del modelo neuronal en el que se obtiene como respuesta una función de la cuantía de acero requerida por las vigas para resistir el momento flexionante de diseño. La figura 4.12 muestra, adicionalmente, un comparativo de los valores calculados en base a datos experimentales y los valores obtenidos de la predicción, tanto por el modelo neuronal entrenado con algoritmos genéticos como con el modelo entrenado con retro-propagación.

Tabla 4.3: Diseño de vigas

| Viga | ENTRADA 1 | calculado | EQ. DERECHA PREDICCIÓN | |
|------------|-----------|-----------|---------------------------|---------|
| | | | ANN | ANN+GA |
| No.03 - S1 | 0.03945 | 0.03530 | 0.03510 | 0.03520 |
| No.05 - S1 | 0.04430 | 0.04080 | 0.03950 | 0.03990 |
| No.08 - S1 | 0.03912 | 0.04040 | 0.03470 | 0.04000 |
| No.10 - S1 | 0.03634 | 0.02830 | 0.03250 | 0.03250 |
| No.13 - S2 | 0.03598 | 0.03180 | 0.03220 | 0.03200 |
| No.01 - S2 | 0.06860 | 0.05520 | 0.06010 | 0.05530 |
| No.05 - S2 | 0.06137 | 0.05520 | 0.05520 | 0.05520 |

La figura 4.12 muestra, adicionalmente, un comparativo de los valores calculados con los valores obtenidos de la predicción, tanto por el modelo neuronal entrenado con algoritmos genéticos como con el modelo entrenado con retro-propagación.

4.6.3 Ancho de grieta 200 MPa

A continuación se presentan resultados de la predicción del ancho máximo de grieta en las vigas con conexiones, en el denominado ciclo de carga de 200 MPa.

La figura 4.13 muestra, adicionalmente, un comparativo de los valores esperados y los valores obtenidos de la predicción, tanto para el modelo neuronal entrenado con algoritmos genéticos como para el modelo entrenado con retro-propagación.

4.6.4 Ancho de grieta 300 MPa

La tabla 4.5 presenta resultados de la predicción del ancho máximo de grieta, en las vigas con conexiones, para el ciclo de carga de 300 MPa.

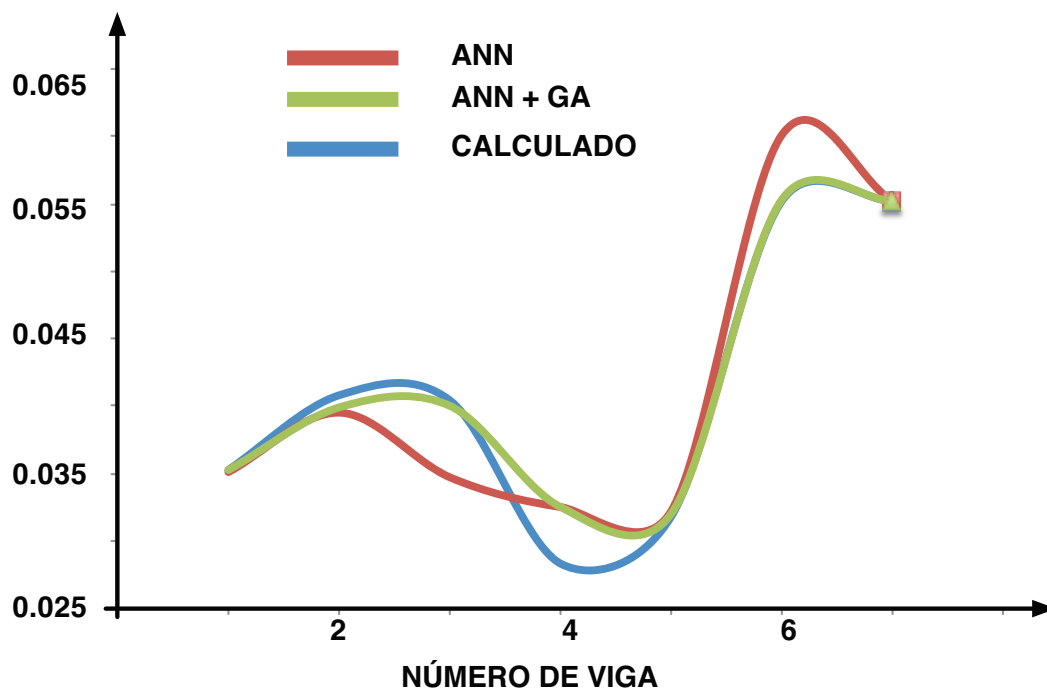


Figura 4.12: Comparación de resultados obtenidos para el diseño de las vigas con conexiones. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error.

Tabla 4.4: Predicción ancho de grieta 200 MPa

| Viga | ENTRADA 1 | ENTRADA 2 | calculado | W 200 Mpa PREDICCIÓN | |
|-------|-----------|-----------|-----------|-------------------------|--------|
| | | | | ANN | ANN+GA |
| No.03 | 0.129 | 0.317 | 0.181 | 0.232 | 0.222 |
| No.04 | 0.118 | 0.250 | 0.236 | 0.217 | 0.221 |
| No.05 | 0.088 | 0.190 | 0.161 | 0.158 | 0.160 |
| No.13 | 0.295 | 0.201 | 0.458 | 0.439 | 0.448 |
| No.17 | 0.113 | 0.258 | 0.227 | 0.200 | 0.202 |
| No.18 | 0.110 | 0.300 | 0.132 | 0.171 | 0.171 |
| No.24 | 0.103 | 0.212 | 0.194 | 0.191 | 0.194 |

Tabla 4.5: Predicción ancho de grieta 300 MPa

| Viga | ENTRADA 1 | ENTRADA 2 | calculado | W 300 Mpa PREDICCIÓN | |
|-------|-----------|-----------|-----------|-------------------------|--------|
| | | | | ANN | ANN+GA |
| No.04 | 0.9107 | 0.2500 | 0.0145 | 0.0145 | 0.0145 |
| No.08 | 0.8774 | 0.2230 | 0.0174 | 0.0151 | 0.0187 |
| No.12 | 0.5098 | 0.1900 | 0.0097 | 0.0126 | 0.0122 |
| No.16 | 0.4507 | 0.4020 | 0.0100 | 0.0107 | 0.0100 |
| No.19 | 0.2350 | 0.3000 | 0.0060 | 0.0068 | 0.0071 |
| No.23 | 0.2670 | 0.2120 | 0.0094 | 0.0084 | 0.0092 |
| No.24 | 0.2810 | 0.2430 | 0.0088 | 0.0082 | 0.0088 |

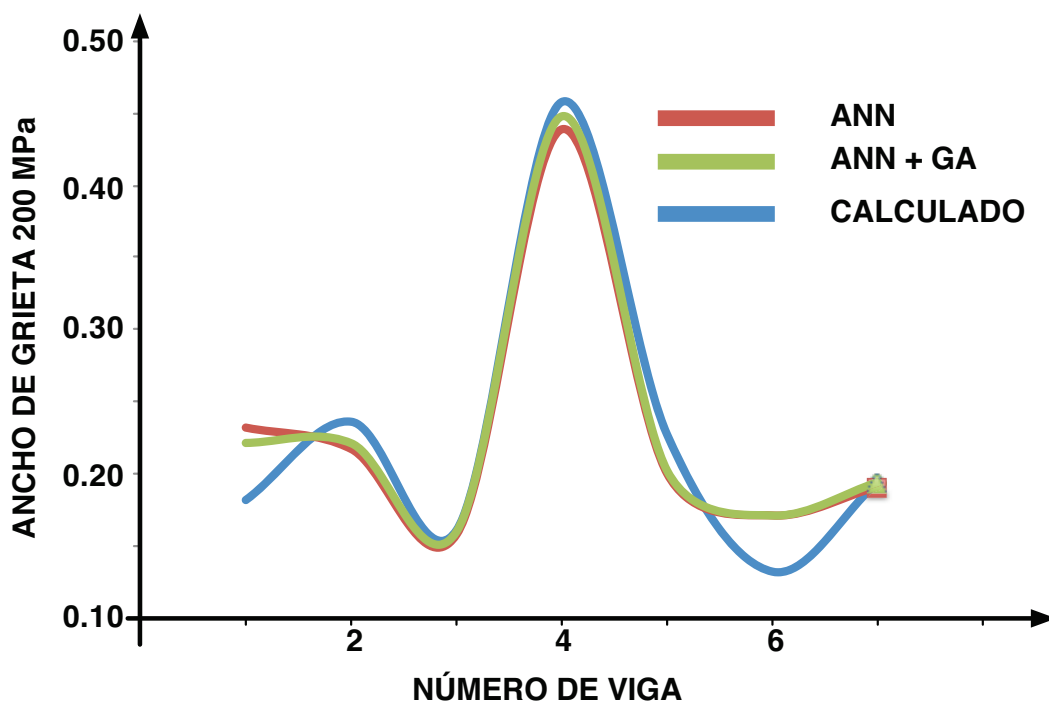


Figura 4.13: Comparación de resultados obtenidos para la predicción de ancho de grieta en el ciclo de 200 MPa en vigas con conexiones. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error.

La figura 4.14 muestra, adicionalmente, un comparativo de los valores calculados con los valores obtenidos de la predicción, tanto por el modelo neuronal entrenado con algoritmos genéticos como con el modelo entrenado con retro-propagación.

4.6.5 Discusión

Generalidades de los modelos propuestos

En esta sección se presentaron los resultados obtenidos de modelos basados en una combinación de ecuaciones disponibles para el análisis y diseño de vigas convencionales de hormigón reforzado y redes neuronales artificiales. Este nuevo esquema de modelamiento se constituye en la principal contribución de este trabajo. El aporte se observa en la capacidad de los modelos propuestos para predecir parámetros estructurales en vigas cuya geometría, configuración de refuerzo, y condiciones de contorno no son aquellas para las cuales las ecuaciones disponibles en códigos de construcción fueron diseñadas. Por simplicidad se adoptó una arquitectura de red neuronal denominada como PERCEPTRON, con una topología que consiste de una capa de entrada, una capa oculta o intermedia, y una capa de salida.

El número de neuronas en la capa intermedia fue determinado en base a un proceso




Figura 4.14: Comparación de resultados obtenidos para la predicción de ancho de grieta en el ciclo de 300 MPa en vigas con conexiones. Los datos corresponden a valores calculados a partir de datos experimentales, predicción obtenida del modelo neuronal con entrenamiento basado en algoritmos genéticos y retro-propagación de error.

simple en el que se evaluó un coeficiente de correlación que mide la distancia, norma, entre la salida deseada y la obtenida por el modelo cuando se varía el número de neuronas de la capa interna. El mayor coeficiente de correlación es el que determina el número de neuronas asignadas a la capa interna del modelo.

El diseño de los vectores de entrada y salida de la red se enriquece de ecuaciones disponibles en los códigos de diseño de estructuras de hormigón armado y toma en cuenta parámetros físicos que caracterizan la respuesta estructural de las nuevas vigas.

Dadas las características de las funciones sinusoidales (rango $[0,1]$) usadas como medios de procesamiento a nivel neuronal, se requiere de un proceso de normalización de los vectores de entrada y salida de la red, esto quiere decir que todos los valores ingresados y obtenidos de los modelos ha sido debidamente procesado para que la red trabaje con un set de valores dentro del rango $[0,1]$.

Durante el proceso de aprendizaje de las redes planteadas para cada uno de los casos en estudio, se proponen dos tipos diferentes de algoritmos, el primero es el método de retro-propagación y el segundo está basado en algoritmos genéticos. Estos algoritmos tienen en común el hecho de plantear estrategias de búsqueda en el espacio multidimensional de la función de error. La diferencia radica en que el algoritmo genético, en base a una estrategia de búsqueda-optimización aleatoria, evita una respuesta que refleje mínimos locales. El algoritmo de retro-propagación, basado en gradientes, puede incurrir en errores al reflejar un mínimo local de la función de error.

Los resultados obtenidos para de los 4 modelos propuestos en este estudio muestran coeficientes de correlación, con respecto a las respuestas experimentales, que varían entre 0.98 y 0.998. Estos resultados destacan el potencial predictivo de la propuesta, en especial si se toma en cuenta el alto nivel de no-linealidad del fenómeno físico en estudio.

Adicionalmente, el tiempo requerido para: el pre-procesamiento, procesamiento, y post-procesamiento de los resultados, es mucho menor que el que se requiere para modelar este tipo de problemas en base a herramientas de mayor difusión en la comunidad de ingenieros civiles, como por ejemplo, el método de elemento finito. Este hecho redundante en simplicidad y por tanto ratifica el cumplimiento de uno de los objetivos de este trabajo.

Dentro de este contexto, la estrategia de modelamiento propuesta en este estudio, ha decir por los resultados obtenidos, tiene el potencial de constituirse en una alternativa de solución a problemas altamente no-lineales relacionados con el análisis y diseño de estructuras de hormigón armado - pre-fabricadas, pre y post tensadas, fabricadas in-situ, etc. - con configuraciones y geometría diferentes a aquellas establecidas en los códigos de construcción. Paralelamente, es necesario mencionar que la herramienta diseñada en este trabajo, será de mucha utilidad en procesos de investigación en los cuales

el contar con criterios válidos para la toma de decisiones es de mucha importancia.

CASO I: Predicción de la capacidad última

La red neuronal en la que se implementa un algoritmo de retro-propagación de error, como estrategia de aprendizaje, requiere de 12 neuronas en la capa oculta. Este valor se determina de acuerdo al procedimiento descrito anteriormente y permite obtener un coeficiente de correlación máximo de 0.991. La contraparte, esto es, el modelo entrenado en base a algoritmos genéticos, requiere de 84 neuronas en la capa interna para alcanzar un coeficiente de correlación de 0.998. Como se puede ver, tanto en la tabla 4.2 como en la figura 4.11 el modelo entrenado con algoritmos genéticos genera resultados con un nivel de aproximación muy alto. El costo en tiempo que implica el procesamiento con un mayor número de neuronas en el caso del entrenamiento con algoritmos genéticos es mayor, sin embargo los resultados obtenidos reflejan una mejor aproximación al obtener un mayor coeficiente de correlación (modelo - experimento) tal como fue expuesto en líneas anteriores.

CASO II: Diseño a flexión

Igual número de neuronas en la capa interna son requeridos para alcanzar el mayor coeficiente de correlación en los modelos de redes neuronales planteados para el diseño a flexión de las vigas con conexiones. Con 12 neuronas en la capa interna, el modelo entrenado en base al algoritmo de retro-propagación produce resultados, que evaluados en comparación a la respuesta experimental esperada, muestran una correlación de 0.994. El modelo entrenado con algoritmos genéticos genera un coeficiente de correlación de 0.997 en base a 12 neuronas en la capa interna.

Se usaron 30000 iteraciones en cada uno de los modelos como criterio de extensión del proceso de aprendizaje. En el caso del entrenamiento basado en retro-propagación de error se emplearon 12 segundos, mientras que su contraparte, el entrenamiento basado en algoritmos genéticos empleó 16 segundos en un procesador Core 2 Duo, 2.66 MHz.

CASO II: Ancho de grieta

El proceso de agrietamiento del hormigón es altamente no-lineal. Su predicción por métodos tradicionales es una tarea compleja, y las ecuaciones disponibles actualmente se basan en la experimentación. Este empirismo limita la aplicabilidad de las ecuaciones así generadas a ciertas condiciones de borde. En el caso de las vigas con conexiones

que se estudian en este trabajo, las ecuaciones disponibles no son aplicables, pues su geometría, configuración y características especiales del refuerzo no son aquellas bajo las cuales dichas ecuaciones fueron generadas.

Ciclo de 200 MPa. El ciclo de 200 MPa corresponde a un estado de esfuerzos en el que el acero en su totalidad trabaja en el rango elástico. De cierto modo esto se ve reflejado en el hecho de que el número de neuronas requerido, en el modelo que usa retro-propagación del error como estrategia de aprendizaje de la red, es menor que en el siguiente caso de estudio, esto es el ciclo de 300 MPa en donde la respuesta de la estructura es enteramente no-lineal. El número de neuronas en la capa interna del modelo que implementa retro-propagación es 12 en contraparte del modelo entrenado con algoritmos genéticos que requiere de 80 neuronas para alcanzar su máximo rendimiento en términos de la aproximación cuantificada como función del coeficiente de correlación entre respuesta del modelo y respuesta esperada.

Usando un computador con procesador Core 2 Duo, 2.66 MHz se ejecutaron 30000 iteraciones en 14 segundos para entrenar la red en base al algoritmo de retro-propagación de error.

En el caso de entrenamiento de la red con algoritmos genéticos se obtuvo la mejor población de pesos de conexiones (entrenamiento) en 29000 iteraciones. El tiempo de procesamiento fue de 41 segundos, lo cual como se puede ver excede al tiempo requerido por el algoritmo de retro-propagación, pero redundante en una mejor aproximación en los valores de ancho de grieta. Si tomamos en cuenta la no-linealidad involucrada en este fenómeno y los tiempos cortos de procesamiento podemos argumentar la efectividad de la metodología propuesta para la solución de este problema.

El rendimiento del modelo fue evaluado, como se dijo, en términos del coeficiente de correlación entre predicciones y datos obtenidos experimentalmente o deseados. Para el caso de retro-propagación dicho coeficiente de correlación fue 0.955, mientras que para el caso de entrenamiento con algoritmos genéticos el coeficiente de correlación fue 0.974. Estos valores muestran el aumento significativo de precisión en los valores obtenidos cuando se usó algoritmos genéticos, justificando de esta manera su uso en este caso específico.

Ciclo de 300 MPa. En el caso de entrenamiento basado en retro-propagación de error, se emplearon 30000 iteraciones para ajustar los pesos de las conexiones entre neuronas. El proceso de entrenamiento tomó 13 segundos en un procesador Core 2 Duo, 2.66 MHz.

La contraparte, esto es, el modelo de red neuronal entrenado en base a algoritmos genéticos requirió de 30000 iteraciones igualmente, con la diferencia de que el proceso de entrenamiento tomó 50 segundos.

El mayor número de neuronas requerido por los modelos planteados para la predicción de grietas, en un estado de esfuerzos en el que el acero se comporta plásticamente alcanzando los 300MPa en tensión, es a decir por los resultados, consecuencia de alto nivel de no-linealidad presente en el fenómeno en estudio.

El coeficiente de correlación en el caso del modelo entrenado en base a retro-propagación de error fue 0.948, mientras que en el caso en el que se usó algoritmos genéticos fue de 0.971. El incremento de tiempo de procesamiento en el segundo caso queda justificado por la mayor precisión obtenida en el modelo.

Capítulo 5

CONCLUSIONES Y RECOMENDACIONES

Como resultado de este trabajo de investigación cuyo principal objetivo es proponer nuevas herramientas de diseño y análisis de elementos estructurales de hormigón reforzado, con geometría y configuración que no se ajustan a las recomendaciones impuestas por códigos de construcción, se obtienen las siguientes conclusiones:

5.1 CONCLUSIONES

1 La estrategia de modelamiento propuesta en esta investigación combina:

- (a.) ecuaciones teóricas y empíricas disponibles en textos y/o códigos de diseño de estructuras convencionales de hormigón reforzado,
- (b.) datos experimentales obtenidos en ensayos a flexión de vigas con configuración y geometría que difieren de las especificadas en dichos textos y/o códigos, y que fueron descritas en detalle en secciones anteriores, y
- (c.) modelos de redes neuronales con arquitectura y topologías simples que puedan ser implementados o que estén al alcance de un usuario no necesariamente entrenado en esta temática,

para generar modelos que permitan analizar y diseñar un nuevo tipo - no convencional - de elementos estructurales de hormigón reforzado pre-fabricados. En el contexto de este estudio se ha denominado como - no convencional - al elemento estructural cuya geometría y/o configuración de refuerzo no se ajusta a las especificaciones y requerimientos establecidos por los códigos de construcción. Por tanto, las ecuaciones que se plantean, en dichos documentos, para evaluar parámetros estructurales relacionados a la resistencia, serviciabilidad, y durabi-

lidad de elementos estructurales no son aplicables.

2 Otro de los objetivos específicos de este estudio fue alcanzado con el planteamiento de cuatro modelos que implementan la estrategia propuesta en el numeral [1] y que están en capacidad de:

(a.) Predecir la capacidad última a flexión de vigas pre-fabricadas de hormigón reforzado unidas con conectores mecánicos,

(b.) Diseñar a flexión vigas pre-fabricadas de hormigón reforzado unidas con conectores mecánicos,

(c.) Predecir el ancho máximo de grieta superficial en vigas pre-fabricadas de hormigón reforzado unidas con conectores mecánicos en un estado de esfuerzo en el que el acero usado como anclaje alcanza 200MPa. en tensión

(d.) Predecir el ancho máximo de grieta superficial en vigas pre-fabricadas de hormigón reforzado unidas con conectores mecánicos en un estado de esfuerzo en el que el acero usado como anclaje alcanza 300MPa. en tensión

3 Con el fin de alcanzar uno de los objetivos fundamentales de este trabajo, esto es, generar una herramienta de diseño estructural versátil y fácil de usar, se decidió trabajar con una arquitectura de red que pueda ser implementada con facilidad o que este al alcance del diseñador estructural. La arquitectura en cuestión responde al esquema denominado PERCEPTRON y fue diseñada con una capa de neuronas como vector de entrada, una capa oculta o intermedia para procesamiento, y una capa de salida que alberga al vector de resultados.

4 Se utilizó el concepto de coeficiente de correlación para la evaluación del rendimiento de los modelos planteados. El coeficiente de correlación evalúa la distancia, norma, entre el valor obtenido y/o calculado de datos experimentales y la respuesta del modelo de red neuronal.

5 Los vectores de entrada de los modelos neuronales propuestos (ver secciones 4.4 y 4.5) recogen la física del fenómeno en estudio en base a ecuaciones establecidas para vigas convencionales en códigos de construcción y parámetros adicionales que abstraen características específicas de la nueva geometría y configuración de las vigas en estudio.

- 6 El número de neuronas de la capa oculta o intermedia de las redes neuronales se determinó en un proceso que evalúa el rendimiento de la red en función del número de neuronas. El mayor coeficiente de correlación que se obtuvo de este proceso se asocia con el número óptimo de neuronas requerido en la capa interna.
- 7 La función de transferencia utilizada en todas las neuronas internas de los modelos propuestos es del tipo sinusoidal. Esto impone restricciones en el tipo de entradas y salidas que pueden ser prescritas a la red, pues todos estos valores deben estar encerrados en el set $[0,1]$.
- 8 En este estudio se cuenta con una base de datos experimentales que resulta de ensayar a flexión, (ver secciones 2.4.3 y 2.5), un total de 24 vigas pre-fabricadas de hormigón reforzado unidas con conectores mecánicos y 5 vigas monolíticas convencionales que sirven como téstigos. Este grupo de datos experimentales fue dividido para ser usado tanto en la etapa de entrenamiento de la red como en la etapa de verificación y/o producción. Esta división de datos responde a recomendaciones encontradas en la literatura y que explícitamente indican que 70% de los datos disponibles debería ser usado para el proceso de aprendizaje, y 30% en la etapa de validación y/o producción.
- 9 Pese a no ser parte de los objetivos planteados al inicio de este trabajo, se optó por utilizar dos estrategias de entrenamiento de los modelos neuronales. El primer algoritmo empleado fue el de retro-propagación de error, y el segundo mecanismo de entrenamiento empleado se basó en algoritmos genéticos. Los resultados obtenidos como consecuencia de la aplicación de estos dos tipos de entrenamiento permiten establecer comparaciones y dar luces sobre el potencial de este tipo de herramientas en aplicaciones de ingeniería estructural.
- 10 Durante la fase de entrenamiento de la red se evaluó el tiempo de procesamiento requerido para ejecutar 30000 iteraciones. El criterio para fijar el número de iteraciones en este valor se basa en observaciones que indican que los algoritmos de entrenamiento empleados alcanzan un punto de estabilidad alrededor de este valor. En todos los casos, las características de búsqueda aleatoria del algoritmo genético se reflejan en mayores tiempos de procesamiento.

- 11** El coeficiente de correlación utilizado para evaluar la capacidad predictiva de los modelos propuestos, muestra el potencial de este esquema de modelamiento para solucionar problemas altamente no-lineales. Al contrario de las limitaciones impuestas por técnicas numéricas que requieren de un conocimiento detallado de la respuesta constitutiva del hormigón reforzado y del mecanismo de falla, la metodología propuesta prueba que se pueden obtener buenas aproximaciones al fenómeno con relativa simplicidad y un reducido tiempo de procesamiento. Los resultados obtenidos para los casos de estudio que se refieren al agrietamiento de las vigas, muestran coeficientes de correlación que varían entre 0.948 y 0.963 para el entrenamiento basado en retro-propagación de error y entre 0.954 y 0.975 cuando los modelos fueron entrenados con algoritmos genéticos. Estos valores son altos si se toma en cuenta el elevado nivel de no-linealidad presente en la respuesta mecánica de este nuevo tipo de estructuras.

- 12** El primer caso de estudio da solución al problema de evaluación de la capacidad última del nuevo tipo de vigas. Con la finalidad de recoger en el vector de entrada parámetros estructurales que cumplan un rol determinante en la respuesta a flexión de las vigas, se recurre a la teoría de estructuras de hormigón armado y se diseña en base a la ecuación 3.3 dicho vector. En este caso particular el vector de entrada consiste de una sola entrada. Por otro lado, el único elemento del vector de salida de la red es el término derecho de la ecuación 3.3 y representa el inverso de la capacidad a flexión última de las vigas. Se usa el inverso del momento último por la necesidad de normalizar tanto las entradas como salidas de los modelos neuronales.

- 13** El modelo neuronal diseñado para predecir la capacidad última de las vigas y entrenado en base al algoritmo de retro-propagación dió como resultado en coeficiente de correlación de 0.975. La fase de entrenamiento se ejecutó hasta el límite de 30000 iteraciones en 40 segundos y se requirió de 12 neuronas en la capa interna.

- 14** En contraparte al entrenamiento basado en retro-propagación se utilizó algoritmos genéticos para entrenar el modelo neuronal propuesto para la predicción del momento último. Se requirieron 12 neuronas en la capa interna, y se empleó 61 segundos en 30000 iteraciones. El coeficiente de correlación que resultó en el proceso predictivo fue de 0.997. Evidentemente el nivel de precisión alcanzado en la predicción del momento último es mayor en el caso de entrenamiento basado en algoritmos genéticos, y el tiempo de procesamiento, pese a ser mayor, no re-

presenta ninguna desventaja para esta aproximación pues sigue siendo reducido en comparación al tiempo requerido por técnicas disponibles actualmente y que en general implementan tecnología de elementos finitos.

- 15** Alineado con el estudio de la capacidad a flexión, se propuso una metodología de diseño para las vigas con conexiones. La metodología recoge las ecuaciones propuestas para el diseño de vigas convencionales y las usa como parte de una estrategia basada en redes neuronales. El objetivo es determinar la cuantía de acero necesaria para resistir esfuerzos de tensión. La topología de la red neuronal planteada consiste de una neurona de entrada y una neurona de salida. La capa intermedia, tanto en el caso del modelo entrenado en base a retro-propagación de error como en el modelo que usa algoritmos genéticos, tiene 12 neuronas.
- 16** El entrenamiento basado en retro-propagación de error en 30000 iteraciones tomó 55 segundos en un procesador Intel Core 2 Duo 2.66 GHz. El coeficiente de correlación que resultó de este proceso de entrenamiento para la etapa de producción fue de 0.978.

La contraparte, es decir el modelo entrenado en base a algoritmos genéticos requirió de 96 segundos para optimizar el peso de las conexiones entre neuronas generando un coeficiente de correlación para la etapa de validación del modelo de 0.997.
- 17** Como se puede ver, el modelo entrenado en base a algoritmos genéticos presenta resultados en la etapa de predicción mas cercanos a los obtenidos experimentalmente. Esto se consigue sin un significativo aumento en tiempo de procesamiento.
- 18** Para la evaluación del ancho máximo de grieta superficial en el ciclo de 200 MPa., la topología de la red neuronal puede describirse de la siguiente manera:

 - (1) Vector de entrada con dos términos. El primer elemento del vector de entrada emplea la ecuación empírica propuesta por estándares japoneses para la estimación del ancho máximo de grieta en elementos de hormigón reforzado convencionales, y el segundo término es la relación entre el espaciamiento de refuerzo longitudinal y el espaciamiento de la barras de anclaje.
 - (2) Vector de salida con una sola neurona en la que se obtiene directamente la predicción del modelo neuronal para el ancho máximo de grieta en las vigas con conexiones.
 - (3) En el caso de entrenamiento basado en retro-propagación de error, la capa de neuronas interna consiste de 12 neuronas que usan una función sinusoidal como función de transferencia.

(4) Cuando la red neuronal es entrenada con algoritmos genéticos, la capa interna requiere de 60 neuronas para alcanzar el mayor coeficiente de correlación en los resultados de la predicción.

- 19** El coeficiente de correlación en el modelo neuronal entrenado con el algoritmo de retro-propagación y que fue diseñado para predecir el ancho máximo de grieta superficial fue 0.955. Su contraparte el modelo entrenado con algoritmos genéticos tiene un mejor rendimiento si se mira al coeficiente de correlación de 0.974 obtenido en la etapa de validación.
- 20** El último caso de estudio, esto es agrietamiento en el ciclo de 300 MPa, encierra mayor complejidad. Se propone un modelo de red neuronal para la predicción del ancho máximo de grieta en un estado de esfuerzos en el que, adicionalmente a la respuesta no lineal del hormigón, el acero de refuerzo se comporta también plásticamente. A este nivel de esfuerzos, las ecuaciones empíricas disponibles en los códigos de construcción fracasan el momento de evaluar la magnitud del agrietamiento, inclusive en estructuras convencionales de hormigón armado. Las respuestas obtenidas, de la combinación del modelo neuronal con dichas ecuaciones, muestran el potencial de esta metodología para dar respuesta a fenómenos altamente no lineales como lo es el agrietamiento de estructuras de hormigón reforzado.
- 21** El modelo entrenado en base al algoritmo de retro-propagación requiere de 24 neuronas en la capa interna para alcanzar su mejor capacidad predictiva. Trece (13) segundos fueron necesarios para ejecutar 30000 iteraciones de ajuste de peso de conexiones, luego de lo cual, el modelo alcanza estabilidad en los resultados. El coeficiente de correlación en la etapa de validación fue de 0.948.
- 22** El vector de entrada consiste de 2 elementos, el primero evalúa la ecuación propuesta por estándares japoneses para evaluar ancho máximo de grieta en estructuras convencionales de hormigón armado, y el segundo es la relación entre el espaciamiento de refuerzo convencional, y el espaciamiento de la barras de anclaje. Por otro lado, el vector de salida tiene una sola neurona, y es la que recoge la predicción del ancho de grieta en las vigas con conexiones.
- 23** El segundo modelo usado para predecir el ancho de grieta en las vigas con conexiones en el estado de esfuerzos, identificado como 300MPa, es entrenado en base

a algoritmos genéticos. Se requirieron 60 neuronas para alcanzar el máximo rendimiento de la red, y 50 segundos para ejecutar 30000 mutaciones en el proceso de optimización genética de los pesos de conexiones. Los resultados muestran un coeficiente de correlación mas alto en relación a su contraparte el modelo entrenado en base a retro-propagación del error. El coeficiente de correlación en la etapa de validación fue de 0.971.

- 24** Los resultados obtenidos en esta investigación muestran el gran potencial que tiene la propuesta de fortalecer las ecuaciones propuestas para el análisis y diseño de estructuras convencionales de hormigón reforzado con modelos de redes neuronales para la predicción y/o evaluación de diversos parámetros estructurales en estructuras no convencionales, es decir estructuras para las cuales no existen ecuaciones o teorías que permitan describir su comportamiento.
- 25** En todos los casos estudiados, el esquema que usa algoritmos genéticos en la etapa de entrenamiento genera mayores coeficientes de correlación, es decir genera mejores predicciones. En general, se puede decir que la razón de la mayor eficiencia, del esquema que combina Redes Neuronales Artificiales con Algoritmos Genéticos, se debe a la capacidad del algoritmo genético de evitar mínimos locales en el proceso de optimización en el espacio multidimensional del error.

5.2 RECOMENDACIONES

- 1** El uso de modelos basados en redes neuronales genera una herramienta alternativa de diseño en la que no se genera un entendimiento explícito del fenómeno físico que se trata de modelar. Consecuentemente, su uso se recomienda en los siguientes casos: (1) Análisis estructural en los procesos de generación de nuevas tipologías de elementos estructurales, (2) Uso de nuevos materiales, de los cuales la respuesta constitutiva no ha sido completamente descrita, (3) Costos elevados en la etapa de experimentación.
- 2** Se recomienda el uso de Algoritmos Genéticos para el entrenamiento de los modelos neuronales en casos donde la respuesta estructural este caracterizada por un alto nivel de no linealidad. En este caso la eficiencia de este tipo de entrnamiento muestra una clara ventaja sobre su contraparte, los modelos neuronales entrena-

dos por retro propagación del error en todos los casos estudiados en este proyecto.

- 3 La selección del grupo de datos para el entrenamiento debe hacerse en base a un análisis estadístico de los mismos. Existen recomendaciones en la literatura que han sido debidamente referenciados en este documento que pueden usarse para este propósito.

- 4 El uso de ecuaciones existentes en la literatura como un mecanismo para combinar los diferentes parámetros físicos que gobiernan un fenómeno brinda la posibilidad de diseñar un vector de entrada de datos de los modelos neuronales representativo del problema en estudio. La estrategia utilizada en este proyecto, se ajusta a este esquema de diseño de los vectores de entrada y ha generado resultados satisfactorios de predicción y que han sido cuantificados en base al coeficiente de correlación. En base a esta experiencia positiva de modelamiento, se recomienda su uso en problemas estructurales en los que se cuente con un marco teórico referencial previo.

Bibliografía

- [1] ACI Committee 318. Manual of concrete practice. In ACI Committee 318, editor, *Manual of Concrete Practice*. ACI Publications, 2005.
- [2] H. Adeli and H. Park. Counter propagation neural network in structural engineering. *ASCE Journal of Structural Engineering*, 8:1205–1212, 1995.
- [3] T. Arahaki, Y. Yamada, T. Oshiro, and Y. Masuda. Prediction of reinforcement corrosion in concrete structures by neural networks. *Proceedings JCI Japan*, 20:257–262, 1998.
- [4] C. Avila, Y. Tsuji, T Sugiyama, and Y. Iizuka. Flexural behavior of precast rc beams joined by cast iron couplers. *Cement Science and Concrete Technology*, 57:683–690, 2003.
- [5] A. Basma, S. Barakat, and S. Al-Oraimi. Prediction of cement degree of hydration using artificial neural networks. *ACI Materials Journal*, 96:167–172, 1999.
- [6] T. Belytschko, R. Gracie, and X. Mei. *Bridging the Scales in Science and Engineering*, chapter Concurrent Coupling of Atomistic and Continuum Models. Claredon Press, 2008.
- [7] CEB-FIP. Ceb-fip model code 1990. In Comite Euro International du Beton, editor, *CEB-FIP Model Code 1990*. Thomas Telford, 1993.
- [8] Public Work Research Center. *Connecting Device of Precast Concrete RC Member KT-JOINT*. Public Work Research Center, JAPAN, 2000.
- [9] Instituto Ecuatoriano de Normalización. Norma ecuatoriana de la construcción. In INEN, editor, *Norma Ecuatoriana de la Construcción*. Instituto Ecuatoriano de Normalización, 2002.
- [10] A. Goh. Prediction of ultimate shear strength of deep beams using neural networks. *ACI Structural Journal*, 96:28–32, 1995.

- [11] N. Hawkins. Proposed revision to 1997 nehrp recommended revisions for seismic regulations for precast concrete structures. *PCI Journal*, 45:34–44, 2000.
- [12] S. Haykin. *Neural Networks a Comprehensive Foundation*. Prentice Hall, New Jersey USA, 1994.
- [13] T. Hsu. *Unified Theory of Reinforced Concrete*. CRC Press, USA, 1993.
- [14] M Kunieda, N. Kuriyara, and K. Rokugo. Prediction of ultimate shear strength of deep beams using neural networks. *Proceedings JCI Japan*, 18:1257–1262, 1996.
- [15] J. Ochs, M Ehsani, and T. Hicks. Moment resistant connections in precast concrete frames for seismic regions. *PCI Journal*, pages 62–71, 1993.
- [16] Japan Society of Civil Engineers. Concrete standard specifications for concrete structures, structural performance verification. In JSCE Publications, editor, *Concrete Standard Specifications for Concrete Structures, Structural Performance Verification*. JSCE, 2002.
- [17] J. Oh, J. Kim, and G. Lee. Application of neural networks for proportioning of concrete mixes. *ACI Materials Journal*, 99:61–67, 1999.
- [18] R. Park and T. Paulay. *Reinforced Concrete Structures*. John Wiley & Sons Ltd., 1975.
- [19] M. Shahin, H. Maier, and M. Jaksa. Evolutionary data division methods for developing artificial neural network models in geotechnical engineering. *University of Adelaide, Research Report*, 2000.
- [20] H. Takeda and T. Maruya. Estimation of chloride penetration into concrete by neural network. *JCI Concrete Research and Technology*, 29:133–142, 1998.
- [21] KAIEI TECHNO. *Precast Concrete Connecting Device*. KAIEI TECHNO Co. Ltda, JAPAN, 2000.

BIBLIOGRAFÍA

- [1] ACI Committee 318. Manual of concrete practice. In ACI Committee 318, editor, *Manual of Concrete Practice*. ACI Publications, 2005.
- [2] H. Adeli and H. Park. Counter propagation neural network in structural engineering. *ASCE Journal of Structural Engineering*, 8:1205–1212, 1995.
- [3] T. Arahaki, Y. Yamada, T. Oshiro, and Y. Masuda. Prediction of reinforcement corrosion in concrete structures by neural networks. *Proceedings JCI Japan*, 20:257–262, 1998.
- [4] C. Avila, Y. Tsuji, T Sugiyama, and Y. Iizuka. Flexural behavior of precast rc beams joined by cast iron couplers. *Cement Science and Concrete Technology*, 57:683–690, 2003.
- [5] A. Basma, S. Barakat, and S. Al-Oraimi. Prediction of cement degree of hydration using artificial neural networks. *ACI Materials Journal*, 96:167–172, 1999.
- [6] T. Belytschko, R. Gracie, and X. Mei. *Bridging the Scales in Science and Engineering*, chapter Concurrent Coupling of Atomistic and Continuum Models. Claredon Press, 2008.
- [7] CEB-FIP. Ceb-fip model code 1990. In Comite Euro International du Beton, editor, *CEB-FIP Model Code 1990*. Thomas Telford, 1993.
- [8] Public Work Research Center. *Connecting Device of Precast Concrete RC Member KT-JOINT*. Public Work Research Center, JAPAN, 2000.
- [9] Instituto Ecuatoriano de Normalización. Norma ecuatoriana de la construcción. In INEN, editor, *Norma Ecuatoriana de la Construcción*. Instituto Ecuatoriano de Normalización, 2002.
- [10] A. Goh. Prediction of ultimate shear strength of deep beams using neural networks. *ACI Structural Journal*, 96:28–32, 1995.

- [11] N. Hawkins. Proposed revision to 1997 nehrp recommended revisions for seismic regulations for precast concrete structures. *PCI Journal*, 45:34–44, 2000.
- [12] S. Haykin. *Neural Networks a Comprehensive Foundation*. Prentice Hall, New Jersey USA, 1994.
- [13] T. Hsu. *Unified Theory of Reinforced Concrete*. CRC Press, USA, 1993.
- [14] M Kunieda, N. Kuriyara, and K. Rokugo. Prediction of ultimate shear strength of deep beams using neural networks. *Proceedings JCI Japan*, 18:1257–1262, 1996.
- [15] J. Ochs, M Ehsani, and T. Hicks. Moment resistant connections in precast concrete frames for seismic regions. *PCI Journal*, pages 62–71, 1993.
- [16] Japan Society of Civil Engineers. Concrete standard specifications for concrete structures, structural performance verification. In JSCE Publications, editor, *Concrete Standard Specifications for Concrete Structures, Structural Performance Verification*. JSCE, 2002.
- [17] J. Oh, J. Kim, and G. Lee. Application of neural networks for proportioning of concrete mixes. *ACI Materials Journal*, 99:61–67, 1999.
- [18] R. Park and T. Paulay. *Reinforced Concrete Structures*. John Wiley & Sons Ltd., 1975.
- [19] M. Shahin, H. Maier, and M. Jaksa. Evolutionary data division methods for developing artificial neural network models in geotechnical engineering. *University of Adelaide, Research Report*, 2000.
- [20] H. Takeda and T. Maruya. Estimation of chloride penetration into concrete by neural network. *JCI Concrete Research and Technology*, 29:133–142, 1998.
- [21] KAIEI TECHNO. *Precast Concrete Connecting Device*. KAIEI TECHNO Co. Ltda, JAPAN, 2000.

Apéndice

DESCRIPCIÓN DE LA HERRAMIENTA

A Introducción

NeurosolutionS for Excel es la herramienta utilizada para la implementación de los modelos basados en redes neuronales propuestos en este trabajo. La herramienta es un add-in de Microsoft Excel que permite el acceso al poder de Neurosolutions como un ambiente de redes neuronales mientras el usuario trabaja en una entorno familiar como el de Microsoft Excel. La figura A1 muestra el menu inicial de la interfaz gráfica de la herramienta Neurosolutions. El primer ícono (extremo izquierdo, superior) permite al usuario acceder al módulo que hace interfaz con Microsoft Excel

B Construcción del modelo de red neuronal

B1 Selección del modelo de red neuronal

Con ayuda del módulo NeuralBuilder, parte de la aplicación NeuroSolutions, el usuario puede caminar a través del proceso de diseño del modelo de red neuronal de una forma interactiva. El menú de opciones mostrado en la figura B1 contiene varios tipos de redes neuronales. Cada uno de los paradigmas listados en el menú presenta ventajas y desventajas dependiendo de la aplicación. Una vez el usuario a decidido el modelo de red, la herramienta le guiará por todo el proceso de diseño.

B2 Selección del grupo de datos para entrenamiento

El primer paso para el diseño de un modelo basado en redes neuronales es determinar una colección de datos que será usado para entrenamiento. La pantalla mostrada en la figura B2 permite definir los siguientes datos:

- 1 Algoritmo de optimización de la red

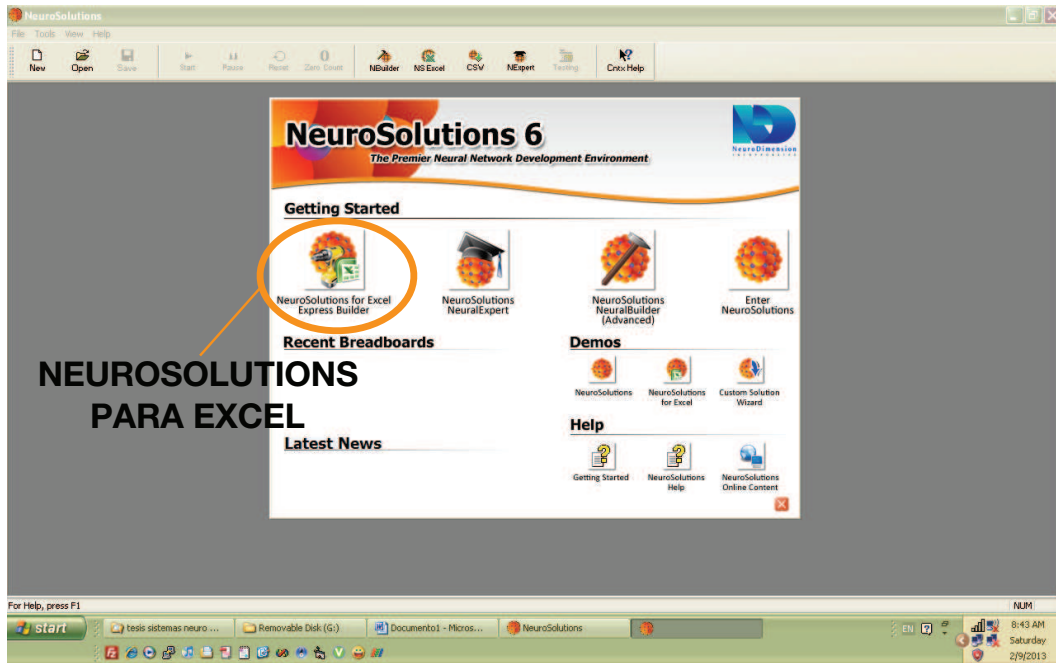


Figura A1: Neurosolutions for Excel

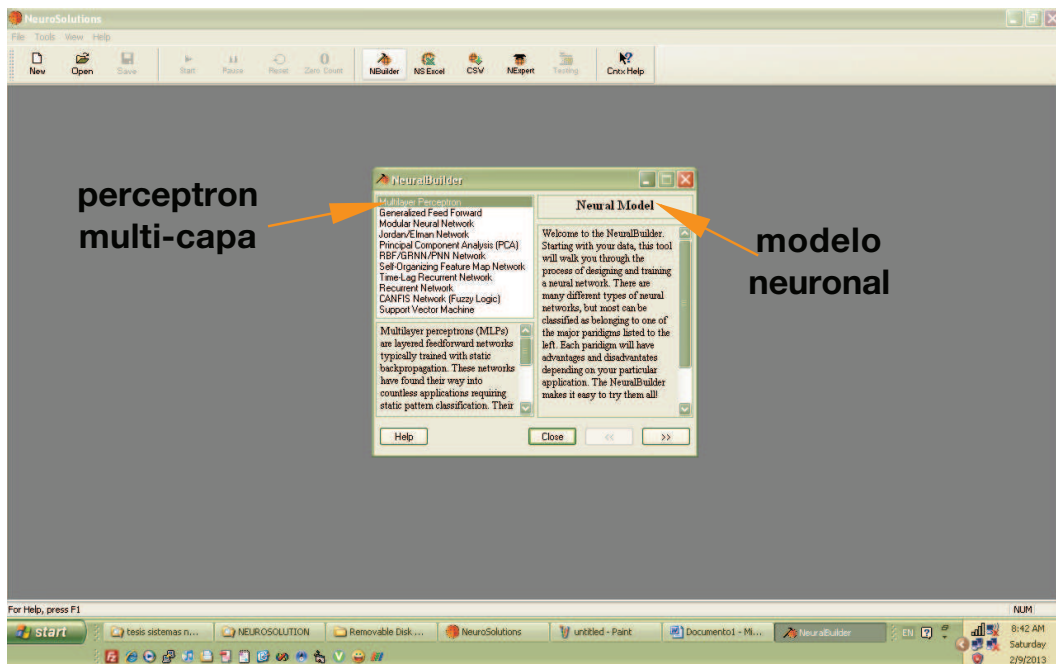


Figura B1: Selección de datos de entrenamiento

INPUT INPUT DESIRED

ENTRENAMIENTO

| | A | B | C | D |
|----|------------|-----------|------------|--------------|
| 1 | (S/E)beams | .SCE | Cs/Cr | W200MPa |
| 2 | B.No.4.S1 | 0.118 | 0.25 | 0.236 |
| 3 | B.No.11.S1 | 0.131 | 0.238 | 0.274 |
| 4 | B.No.12.S1 | 0.065 | 0.19 | 0.091 |
| 5 | B.No.14.S1 | 0.377 | 0.238 | 0.512 |
| 6 | B.No.2.S1 | 0.106 | 0.178 | 0.279 |
| 7 | B.No.5.S2 | 0.10983 | 0.292 | 0.18 |
| 8 | B.No.6.S2 | 0.1032448 | 0.21166667 | 0.194 |
| 9 | B.No.6.S1 | 0.032 | 0.335 | 0.038 |
| 10 | B.No.16.S1 | 0.121 | 0.402 | 0.142 |
| 11 | B.No.2.S2 | 0.10983 | 0.3 | 0.132 |
| 12 | B.No.7.S2 | 0.125568 | 0.24333333 | 0.249 |
| 13 | B.No.4.S2 | 0.2239032 | 0.3 | 0.315 |
| 14 | B.No.9.S1 | 0.291 | 0.251 | 0.483 |
| 15 | B.No.17.S1 | 0.046 | 0.201 | 0.013 |
| 16 | B.No.1.S2 | 0.112968 | 0.258 | 0.227 |
| 17 | B.No.15.S1 | 0.207 | 0.402 | 0.421 |
| 18 | B.No.3.S2 | 0.1117128 | 0.36 | 0.196 |
| 19 | B.No.1.S1 | 0.107 | 0.238 | 0.151 |
| 20 | B.No.3.S1 | 0.129 | 0.317 | 0.181 |
| 21 | B.No.13.S1 | 0.295 | 0.201 | 0.458 |
| 22 | B.No.8.S1 | 0.336 | 0.223 | 0.456 |
| 23 | B.No.7.S1 | 0.214 | 0.201 | 0.354 |
| 24 | B.No.10.S1 | 0.116 | 0.407 | 0.132 |
| 25 | B.No.5.S1 | 0.088 | 0.19 | 0.161 |

Figura B2: Selección del Modelo de Red Neuronal

- 2 Columnas que alimentan las neuronas de entrada del modelo de red neuronal
- 3 Columnas que alimentan las neuronas de salida del modelo de red neuronal. En el caso del grupo de datos para entrenamiento, esta columna corresponde a las respuestas deseadas en base a las cuales se produce el mapping de los datos de entrada.

B3 Selección del grupo de datos para validación cruzada y prueba

En el panel mostrado en la figura B3 el usuario puede especificar datos para validación cruzada como para prueba. La validación cruzada es un método altamente recomendado como un criterio de finalización de la etapa de entrenamiento. Este método monitorea el error y para el proceso de entrenamiento si la magnitud del error empieza a tomar una tendencia creciente. Este es considerado el punto de mejor generalización.

Por otro lado el grupo de datos de prueba es usado para verificar el rendimiento del modelo de red neuronal conjuntamente con el proceso de entrenamiento. Una vez que la red es entrenada los pesos de las conexiones son congelados, el grupo de datos de prueba es ingresado a la red para entonces comparar la respuesta deseada con la respuesta obtenida por el modelo.

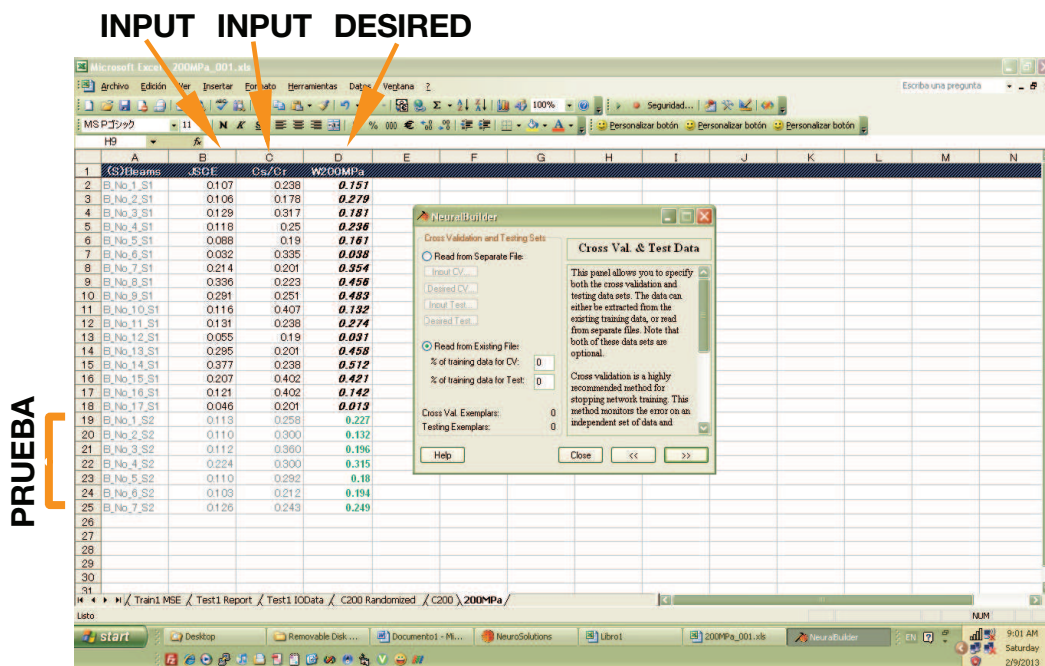


Figura B3: Selección de datos para prueba

B4 Configuración de la topología del PERCEPTRON

Un modelo de red tipo PERCEPTRON multi-capa es una red de alimentación hacia adelante, comunmente entrenado por retro-propagación del error. En el panel mostrado en la figura B4, el usuario puede especificar el número de capas ocultas con las que se configurará a la red. En este proyecto, por simplicidad, se eligió el modelo PERCEPTRON con una sola capa interna. Vale recalcar que la literatura [12] reconoce a este modelo neuronal como simple de usar, y con capacidad para aproximar cualquier mapeo entre entrada/salida.

B5 Definición del número de neuronas internas

El panel mostrado en la figura B5 es usado para especificar los parámetros requeridos por la capa interna de la red neuronal. Las simulaciones de la herramienta Neurosolutions se basan en una notación vectorial por eficiencia. Esto implica que cada capa contiene un vector de elementos de procesamiento, y los parámetros especificados se aplican a todos los elementos del vector. Los parámetros requeridos dependen del modelo seleccionado, pero todos requieren de una función no-lineal de transferencia en cada nodo.

Adicionalmente, cada capa tiene asociada una regla y parámetros de aprendizaje. La regla de aprendizaje y la función no lineal de transferencia pueden ser seleccionados de una lista de opciones, tal como se muestra en la figura B5.

NÚMERO DE CAPAS

The screenshot shows a Microsoft Excel spreadsheet with columns labeled (S)Elems, JSCE, Cs/Cr, and W200MPa. The data rows show values for various elements (B.No. 1_S1 to B.No. 17_S1 and B.No. 1_S2 to B.No. 7_S2). A NeuralBuilder dialog box is open, showing a neural network diagram and configuration options. The 'Hidden Layers' field is set to 1. An orange arrow points to this field.

| (S)Elems | JSCE | Cs/Cr | W200MPa |
|------------|-------|-------|---------|
| B.No.1_S1 | 0.107 | 0.238 | 0.151 |
| B.No.2_S1 | 0.106 | 0.178 | 0.279 |
| B.No.3_S1 | 0.129 | 0.317 | 0.181 |
| B.No.4_S1 | 0.118 | 0.25 | 0.296 |
| B.No.5_S1 | 0.088 | 0.19 | 0.161 |
| B.No.6_S1 | 0.032 | 0.335 | 0.038 |
| B.No.7_S1 | 0.214 | 0.201 | 0.354 |
| B.No.8_S1 | 0.336 | 0.223 | 0.456 |
| B.No.9_S1 | 0.291 | 0.251 | 0.483 |
| B.No.10_S1 | 0.116 | 0.407 | 0.132 |
| B.No.11_S1 | 0.131 | 0.238 | 0.274 |
| B.No.12_S1 | 0.055 | 0.19 | 0.031 |
| B.No.13_S1 | 0.295 | 0.201 | 0.458 |
| B.No.14_S1 | 0.377 | 0.238 | 0.572 |
| B.No.15_S1 | 0.207 | 0.402 | 0.421 |
| B.No.16_S1 | 0.121 | 0.402 | 0.142 |
| B.No.17_S1 | 0.046 | 0.201 | 0.013 |
| B.No.1_S2 | 0.113 | 0.258 | 0.227 |
| B.No.2_S2 | 0.110 | 0.300 | 0.132 |
| B.No.3_S2 | 0.112 | 0.360 | 0.196 |
| B.No.4_S2 | 0.224 | 0.300 | 0.315 |
| B.No.5_S2 | 0.110 | 0.292 | 0.10 |
| B.No.6_S2 | 0.103 | 0.212 | 0.194 |
| B.No.7_S2 | 0.126 | 0.243 | 0.249 |

Figura B4: Configuración de la topología de red

FUNCION DE TRANSFERENCIA

The screenshot shows the same Excel spreadsheet as Figure B4. The NeuralBuilder dialog box is now open to the 'Hidden Layer #1' configuration screen. The 'Transfer' dropdown menu is set to 'TanhAxon'. An orange arrow points to this dropdown menu.

| (S)Elems | JSCE | Cs/Cr | W200MPa |
|------------|-------|-------|---------|
| B.No.1_S1 | 0.107 | 0.238 | 0.151 |
| B.No.2_S1 | 0.106 | 0.178 | 0.279 |
| B.No.3_S1 | 0.129 | 0.317 | 0.181 |
| B.No.4_S1 | 0.118 | 0.25 | 0.296 |
| B.No.5_S1 | 0.088 | 0.19 | 0.161 |
| B.No.6_S1 | 0.032 | 0.335 | 0.038 |
| B.No.7_S1 | 0.214 | 0.201 | 0.354 |
| B.No.8_S1 | 0.336 | 0.223 | 0.456 |
| B.No.9_S1 | 0.291 | 0.251 | 0.483 |
| B.No.10_S1 | 0.116 | 0.407 | 0.132 |
| B.No.11_S1 | 0.131 | 0.238 | 0.274 |
| B.No.12_S1 | 0.055 | 0.19 | 0.031 |
| B.No.13_S1 | 0.295 | 0.201 | 0.458 |
| B.No.14_S1 | 0.377 | 0.238 | 0.572 |
| B.No.15_S1 | 0.207 | 0.402 | 0.421 |
| B.No.16_S1 | 0.121 | 0.402 | 0.142 |
| B.No.17_S1 | 0.046 | 0.201 | 0.013 |
| B.No.1_S2 | 0.113 | 0.258 | 0.227 |
| B.No.2_S2 | 0.110 | 0.300 | 0.132 |
| B.No.3_S2 | 0.112 | 0.360 | 0.196 |
| B.No.4_S2 | 0.224 | 0.300 | 0.315 |
| B.No.5_S2 | 0.110 | 0.292 | 0.10 |
| B.No.6_S2 | 0.103 | 0.212 | 0.194 |
| B.No.7_S2 | 0.126 | 0.243 | 0.249 |

Figura B5: Selección de parámetros de aprendizaje

B6 Datos experimentales

La figura B6 muestra los datos experimentales disponibles para este estudio en formato Excel. En la figura B6 se presentan los datos de entrenamiento y de validación utilizados en el caso de estudio en el cual se predice el ancho de grieta a un nivel de esfuerzos de 200MPa. El ordenamiento de los datos es aleatorio y se lo consigue con ayuda de opciones disponibles en la herramienta.

B7 Resultados del proceso de validación

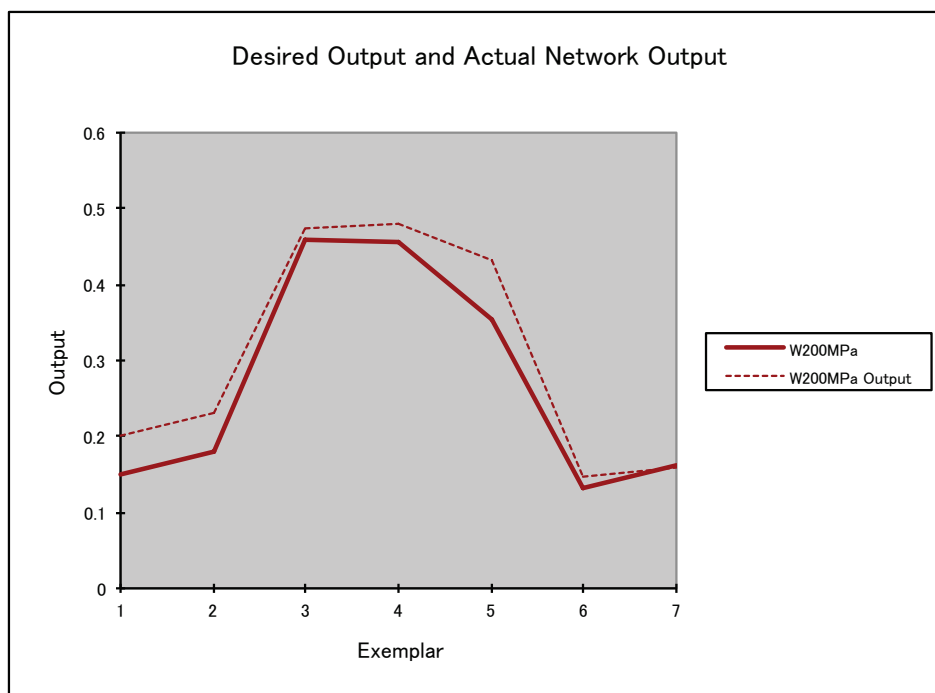
En la figura B7 se muestran los resultados del proceso de validación en un ejercicio de prueba para el modelo neuronal de predicción del ancho de grieta a un nivel de esfuerzos de 200MPa. El panel de resultados muestra gráficamente la relación entre las respuestas deseadas (línea roja continua) y la predicción del modelo (línea roja entrecortada). Adicionalmente se obtienen algunos datos estadísticos que permiten cuantificar el rendimiento del modelo propuesto para la predicción. El valor utilizado en este estudio para determinar el rendimiento de la red es el coeficiente de correlación r , que en este ejemplo demostrativo tiene un valor de 0.9839716. El coeficiente de correlación muestra un gran nivel de aproximación. Esta es la tendencia observada en todos los casos tratados como parte de este proyecto.

Finalmente, la figura B8 muestra resultados de la convergencia obtenida en el proceso de entrenamiento de la red. En este caso demostrativo de la herramienta, se utilizaron 30000 iteraciones (epochs) como criterio de finalización del proceso de entrenamiento. Los resultados muestran un error (Mean Square) evaluado entre la respuesta deseada y la predicción del modelo, que tiene un valor de 0.00228.

The figure displays two screenshots of a Microsoft Excel spreadsheet containing experimental data. The data is organized in a table with columns labeled (S)Beams, JSGE, Cs/Cr, and W200MPa. The rows represent different beam configurations, numbered 1 through 25. The values in the W200MPa column are bolded and represent the primary data points. The top screenshot shows a highlighted cell in row 8, column F, and the bottom screenshot shows a highlighted cell in row 10, column G.

| (S)Beams | JSGE | Cs/Cr | W200MPa |
|------------|-----------|------------|--------------|
| B.No.4.S1 | 0.118 | 0.25 | 0.236 |
| B.No.11.S1 | 0.131 | 0.238 | 0.274 |
| B.No.12.S1 | 0.055 | 0.19 | 0.031 |
| B.No.14.S1 | 0.377 | 0.238 | 0.512 |
| B.No.2.S1 | 0.106 | 0.178 | 0.279 |
| B.No.5.S2 | 0.10983 | 0.292 | 0.18 |
| B.No.6.S2 | 0.1032448 | 0.21166667 | 0.194 |
| B.No.8.S1 | 0.032 | 0.335 | 0.038 |
| B.No.16.S1 | 0.121 | 0.402 | 0.142 |
| B.No.2.S2 | 0.10983 | 0.3 | 0.132 |
| B.No.7.S2 | 0.125568 | 0.24333333 | 0.249 |
| B.No.4.S2 | 0.2239032 | 0.3 | 0.315 |
| B.No.9.S1 | 0.291 | 0.251 | 0.483 |
| B.No.17.S1 | 0.046 | 0.201 | 0.013 |
| B.No.1.S2 | 0.112968 | 0.258 | 0.227 |
| B.No.15.S1 | 0.207 | 0.402 | 0.421 |
| B.No.3.S2 | 0.1117128 | 0.36 | 0.196 |
| B.No.1.S1 | 0.107 | 0.238 | 0.151 |
| B.No.3.S1 | 0.129 | 0.317 | 0.181 |
| B.No.13.S1 | 0.295 | 0.201 | 0.458 |
| B.No.9.S1 | 0.336 | 0.223 | 0.458 |
| B.No.7.S1 | 0.214 | 0.201 | 0.354 |
| B.No.10.S1 | 0.116 | 0.407 | 0.132 |
| B.No.5.S1 | 0.088 | 0.19 | 0.161 |


Figura B6: Datos experimentales aleatoriamente dispuestos y división entre el set de entrenamiento y validación



| JSCE | Cs/Cr | W200MPa | W200MPa Output |
|-------|-------|---------|----------------|
| 0.107 | 0.238 | 0.151 | 0.199567 |
| 0.129 | 0.317 | 0.181 | 0.2309196 |
| 0.295 | 0.201 | 0.458 | 0.4726171 |
| 0.336 | 0.223 | 0.456 | 0.4809076 |
| 0.214 | 0.201 | 0.354 | 0.4310111 |
| 0.116 | 0.407 | 0.132 | 0.1467352 |
| 0.088 | 0.19 | 0.161 | 0.1593465 |

| Performance | W200MPa |
|---------------|-------------|
| MSE | 0.001690762 |
| NMSE | 0.091039842 |
| MAE | 0.033058721 |
| Min Abs Error | 0.001653464 |
| Max Abs Error | 0.077011081 |
| r | 0.983971632 |

Figura B7: Resultados del proceso de validación



| Best Network | Training |
|---------------------|-----------------|
| Epoch # | 30000 |
| Minimum MSE | 0.002283376 |
| Final MSE | 0.002283376 |

Figura B8: Resultados de la convergencia del proceso de entrenamiento