

ESCUELA
COLOMBIANA
DE INGENIERÍA
JULIO GARAVITO

Predicción del comportamiento a tracción directa del UHPFRC mediante la técnica de Bosques Aleatorios.

Juan Sebastián Guzmán Guzmán

Escuela Colombiana de Ingeniería

Posgrado en Ingeniería Civil

Bogotá, Colombia

2020

Predicción del comportamiento a tracción directa del UHPFRC mediante la técnica de Bosques Aleatorios.

Juan Sebastián Guzmán Guzmán

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

Magister en Ingeniería Civil

Director (a):

MSc. Joaquín Abellán García

Codirector (a):

Ph.D. Nancy Torres Castellanos

Línea de Investigación:

Ingeniería estructural

Escuela Colombiana de Ingeniería Julio Garavito

Posgrado en Ingeniería Civil

Bogotá, Colombia

2020

Página de aceptación del jurado

El trabajo de grado de maestría titulado “Predicción del comportamiento a tracción directa del UHPFRC mediante la técnica de Bosques Aleatorios”, presentado por **Juan Sebastián Guzmán Guzmán**, cumple con los requisitos establecidos para optar al título de Magister en Ingeniería Civil con énfasis en estructuras.

Jurado

Ing. Camilo José Vega Vargas

Jurado

Ing. Ricardo Matallana Rodríguez

Joaquín Abellán García
Director de trabajo de grado

Nancy Torres Castellanos

Co-directora de trabajo de grado

Bogotá, D.C.,

Agradecimientos

A mis padres Ángela Guzmán y Nelson Guzmán, que gracias a su apoyo financiero y moral logré culminar esta nueva etapa de mi carrera profesional. Asimismo, a mi hermano Luis Miguel Guzmán, con quien comparto la mayor parte de mi tiempo aprendiendo y cultivando una gran amistad, y quien ha estado a mi lado en todo momento feliz y de dificultad.

A Lina Romero Matallana, quien me ha acompañado en mi vida sentimental y profesional desde hace bastantes años. Gracias por estar a mi lado y acompañarme en cada momento de esta aventura que vivimos los dos.

Al ingeniero y director del presente proyecto Joaquín Abellán García, quien desde el día uno demostró lo que es ser un gran profesional, mentor y compañero. También quiero agradecerle la paciencia y apoyo que brindó para que este trabajo de grado culminara de forma positiva. Incluyendo de igual manera a la doctora Nancy Torres Castellanos, co-directora del presente proyecto, por su tiempo y disposición para que pudiese llevar a cabo todas las tareas que requería esta investigación. Sin dejar por fuera a todo el equipo del laboratorio de estructuras de la Escuela Colombiana de Ingeniería Julio Garavito por el apoyo y disposición que brindaron durante el desarrollo del presente trabajo de grado.

Resumen

Los concretos de ultra-alto desempeño reforzados con fibras (UHPFRC, por sus siglas en inglés) se han convertido en un material de construcción de gran interés por parte de la comunidad científica. La capacidad de los UHPFRC de presentar un comportamiento de endurecimiento por deformación al ser sometidos a esfuerzos de tracción ha generado que cada vez más este nuevo material sea incluido en la construcción y rehabilitación de estructuras. Sin embargo, su elevado costo y complejidad en su producción han limitado su uso en la industria colombiana. Por lo tanto, es necesario reducir el costo de producción del UHPFRC, tanto en materias primas como en desarrollo. En el presente proyecto se realizan algoritmos de aprendizaje automático de tipo Bosques Aleatorios para predecir los parámetros del comportamiento a tracción directa del UHPFRC: g , capacidad de absorción de energía (expresada en kJ/m^3) y ϵ_{pc} , deformación bajo carga máxima post fisuración (expresado en %). El conocimiento de estos parámetros es fundamental para aplicaciones que requieran elevada ductilidad, como la rehabilitación y mejora sismo resistente de estructuras no dúctiles. Una vez desarrollados y validados estadística y experimentalmente los modelos predictivos, se utilizó un algoritmo de optimización multiobjetivo para determinar la mezcla y contenido de fibras que, utilizando una dosificación optimizada de la matriz cementante, alcanzase los requerimientos de ductilidad necesarios para el reforzamiento sísmico de estructuras ($g \geq 50 \text{ kJ/m}^3$ y $\epsilon_{pc} \geq 0.3\%$) al menor costo. Los resultados de esta tesis de maestría arrojaron que una mezcla de UHPFRC con una mezcla híbrida de fibra de acero de alta resistencia al 0.32% y de fibra de acero de resistencia normal conformada en forma de gancho al 1.52% en volumen (contenido total de fibras del 1.90%) fue suficiente para alcanzar los criterios de ductilidad descritos. Como conclusión se tuvo que los algoritmos de Bosques Aleatorios resultaron ser una herramienta efectiva para la predicción del comportamiento del UHPFRC, permitiendo reducir costos y tiempos de investigación en el desarrollo de nuevas dosificaciones.

Palabras clave: UHPFRC, Bosques Aleatorios, Aprendizaje Automático, optimización multiobjetivo, ductilidad, capacidad de absorción de energía, deformación bajo tensión máxima post-fisuración

Abstract

Ultra-high-performance fiber reinforced concretes (UHPFRC) have become a construction material of great interest within the scientific community. The capacity of UHPFRCs to present a strain-hardening behavior under direct tensile test has led to it being increasingly included in the construction and rehabilitation of structures. However, its high cost and complexity in its production has limited its use in Colombian industry. Therefore, it is necessary to reduce the production cost of UHPFRC, both in raw materials and in development. In this research, machine learning algorithms such as Random Forest are carried out to predict the parameters of the UHPFRC's direct tensile behavior: g , energy absorption capacity (measured in kJ/m^3) and ε_{pc} , strain under maximum post-cracking load (measured in %). Knowledge of these parameters is essential for applications that require high ductility, such as the rehabilitation and seismic retrofitting of existing non-ductile structures. Once the predictive models were developed and validated statistically and experimentally, a multi-objective optimization algorithm was used to determine the blend and fiber content that, using an optimized cementitious matrix dosage, would achieve the ductility requirements necessary for the seismic retrofitting applications of structures. ($g \geq 50 \text{ kJ/m}^3$ and $\varepsilon_{pc} \geq 0.3\%$) at the lowest cost. The results of this master's thesis showed that a mixture of UHPFRC with a hybrid mixture of 0.32% high strength steel fiber and 1.52% hook-shaped normal strength steel fiber by volume (1.90% of total volume fiber fraction) achieved the ductility criteria described at the lowest cost. As a conclusion, it was found that the Random Forest algorithms turned out to be an effective tool for predicting the behavior of the UHPFRC, allowing to reduce costs and research times in the development of new dosages.

Keywords: UHPFRC, Random Forest, Machine Learning, multi-objective optimization, ductility, energy absorption capacity, strain under maximum post-cracking stress

Contenido

1. Marco teórico.....	5
1.1 UHPFRC	6
1.2 Cemento	8
1.3 Humo de Sílice	10
1.4 Materiales cementantes suplementarios	11
1.5 Harina de cuarzo	12
1.6 Superplastificante de alto rango	13
1.7 Arena de sílice	14
1.8 Fibra de refuerzo	15
1.9 Resistencia a compresión	16
1.9.1 Ensayo de cilindro	16
1.9.2 Ensayo de cubos	17
1.10 Resistencia a tracción	18
1.11 Árboles de decisión	19
2. Estado del arte.....	21
2.1 Introducción al UHPFRC	21
2.1.1 Historia, desarrollo e introducción al mercado Latinoamericano	21
2.1.2 Composición y costos	25
2.1.3 Comportamiento a tracción directa	26
2.2 Aprendizaje automático	32
2.2.1 Aprendizaje supervisado	33
2.2.2 Aprendizaje no supervisado	33
2.2.3 Aprendizaje reforzado	34
2.3 Árboles de decisión y Bosques Aleatorios	38
3. Objetivos.....	44
3.1 Objetivo general	44
3.2 Objetivos específicos	44
4. Metodología.....	45
4.1 Base de datos	46
4.2 Elaboración de los Bosques Aleatorios	47
4.3 Programa experimental	49
4.3.1 Materiales	49
4.3.2 Cemento	51
4.3.3 Humo de sílice	51
4.3.4 Polvo de vidrio	51
4.3.5 Carbonato de calcio	51

4.3.6	Arena de sílice.....	52
4.3.7	Superplastificante de alto rango	52
4.3.8	Agua.....	52
4.3.9	Dosificaciones	52
4.3.10	Mezcla, elaboración de probetas y curado	53
4.3.11	Ensayo de tracción directa	55
5.	Análisis de resultados y discusión.....	56
5.1	Conjunto de datos.....	56
5.2	Tratamiento de los datos anómalos	59
5.2.1	Análisis de la base de datos mediante diagramas <i>bagplot</i>	59
5.3	Resultados experimentales del comportamiento a tracción directa del UHPFRC 73	
5.4	Algoritmo de aprendizaje automático supervisado tipo Bosques Aleatorios	77
5.4.1	Modelo predictivo para la deformación pos-fisuración (Y1) del UHPFRC	77
5.4.2	Modelo predictivo para la capacidad de absorción de energía (Y2) del UHPFRC 89	
5.5	Optimización del UHPFRC.....	100
6.	Conclusiones	104
7.	Recomendaciones	106
8.	Anexos.....	107
8.1	Ensayos de tracción directa	107
8.1.1	MB2%-SF50.....	107
8.1.2	MB2%-SF100.....	111
8.1.3	MB2%-SF150.....	117
8.1.4	OL2%-SF50	123
8.1.5	OL2%-SF100	129
8.1.6	OL2%-SF150	138

Lista de figuras

Figura 1-1. Proceso de producción del cemento (Quiroz & Salamanca, 2006).....	9
Figura 1-2. Humo de sílice (Abellan-Garcia et al., 2020)	11
Figura 1-3. Polvo de vidrio (Abellan-Garcia et al., 2020).....	12
Figura 1-4. Carbonato de calcio (Jaramillo, 2020)	12
Figura 1-5. Diferentes tipos de harina de cuarzo (Rashad, 2018).....	13
Figura 1-6. Superplastificante de alto rango (Jaramillo, 2020)	14
Figura 1-7. Arena de sílice (Abellan-Garcia et al., 2020)	14
Figura 1-8. Geometría de las fibras más comunes (NMX, 2014).	16
Figura 1-9. Ensayo a compresión de cilindros	17
Figura 1-10. Ensayo a compresión de cubos (Neira, 2020)	18
Figura 1-11. Ensayo de tracción indirecta del concreto	19
Figura 1-12. Ejemplo de un árbol de decisiones.....	20
Figura 2-1. Vista general del puente peatonal sobre el Barranco de las Ovejas (Carillo, 2013).....	23
Figura 2-2. Vista del puente peatonal sobre la avenida Las Vegas en Medellín en una fase muy avanzada de su construcción en 2017 (Abellán-García, Nuñez-Lopez, et al., 2020).	25
Figura 2-3. Composición y coste de mezcla media de UHPFRC. Número de dosificaciones observadas 128. Coste medio: 2.236.265 COP/m3. Contenido medio de fibras metálicas:1,84%(Abellán et al., 2018).	26
Figura 2-4. Endurecimiento por deformación del UHPFRC (K. Wille et al., 2014).....	27
Figura 2-5. Dimensiones recomendadas para la probeta tipo “dog-bone” (Japan Society of Civil Engineers, 2008).	29
Figura 2-6. Aprendizaje reforzado en el aprendizaje automático (Fumo, 2017).	34
Figura 2-7. Árbol de decisión para spam en correos electrónicos (Genuer & Poggi, 2020).	39
Figura 2-8. La imagen de la izquierda muestra un árbol de clasificación para predecir una respuesta determinada para un espacio x dado. La imagen de la derecha expone la partición asociada de las variables en el espacio (C_1 , C_2 y C_5 no aparecen debido a que estas no están asociadas a las hojas del árbol) (Genuer & Poggi, 2020)	40
Figura 2-9. Esquema general de los bosques aleatorios (Genuer & Poggi, 2020)	43
Figura 4-1. Distribución del tamaño de partícula de los materiales cementantes.....	50
Figura 4-2. Mezcladora tipo Hobart de 3.0 litros de capacidad.	54
Figura 4-3. Moldes para la elaboración de las probetas tipo hueso de perro	55
Figura 4-4. Probetas tipo hueso de perro y montaje en los ensayos de tracción directa. 56	

Figura 5-1. Influencia de la variable $X1$ frente al comportamiento a tracción del UHPFRC	60
Figura 5-2. Influencia de la variable $X2$ frente al comportamiento a tracción del UHPFRC	61
Figura 5-3. Influencia de la variable $X3$ frente al comportamiento a tracción del UHPFRC	61
Figura 5-4. Influencia de la variable $X4$ frente al comportamiento a tracción del UHPFRC	62
Figura 5-5. Influencia de la variable $X5$ frente al comportamiento a tracción del UHPFRC	63
Figura 5-6. Influencia de la variable $X6$ frente al comportamiento a tracción del UHPFRC	63
Figura 5-7. Influencia de la variable $X7$ frente al comportamiento a tracción del UHPFRC	64
Figura 5-8. Influencia de la variable $X9$ frente al comportamiento a tracción del UHPFRC	65
Figura 5-9. Influencia de la variable $X10$ frente al comportamiento a tracción del UHPFRC	65
Figura 5-10. Influencia de la variable $X11$ frente al comportamiento a tracción del UHPFRC	66
Figura 5-11. Influencia de la variable $X12$ frente al comportamiento a tracción del UHPFRC	66
Figura 5-12. Influencia de la variable $X35$ frente al comportamiento a tracción del UHPFRC	67
Figura 5-13. Comportamiento de las variables de entrada frente a $Y1$ posterior al tratamiento de los datos anómalos (parte 2)	70
Figura 5-14. Comportamiento de las variables de entrada frente a $Y2$ posterior al tratamiento de los datos anómalos (Parte 3).....	73
Figura 5-15. Comportamiento a tracción directa de endurecimiento por deformación del UHPFRC (parte 2)	75
Figura 5-16. Microfisuración en probetas de UHPFRC con fibra metálica con gancho en los extremos (MB)	76
Figura 5-17. Gráfico de error (RMSE) en variables respuestas normalizadas versus número de árboles en el modelo.....	78
Figura 5-18. Primero de los 500 árboles de decisión del modelo de Bosques Aleatorios para predecir $Y1$ (ϵ_{pc})	79
Figura 5-19. Diagrama de regresión para el modelo de $Y1$: (a) datos de entrenamiento; (b) datos experimentales y de validación.....	80
Figura 5-20. Dependencia parcial de las variables independientes para la predicción de la variable $Y1$ (Parte 1).	82
Figura 5-21. Noción de importancia de las variables independiente frente a $Y1$	89
Figura 5-22. Gráfico de error (RMSE) en variables respuestas normalizadas versus número de árboles en el modelo.....	90

Figura 5-23. Primero de los 500 árboles de decisión del modelo de Bosques Aleatorios para predecir Y_2 (g)	91
Figura 5-24. Diagrama de regresión para el modelo de Y_2 (a) datos de entrenamiento; (b) datos experimentales y de validación	92
Figura 5-25. Dependencia parcial de las variables independientes para la predicción de la variable Y_2 (parte 1)	94
Figura 5-26. Noción de importancia de las variables independiente frente a Y_2	100

Lista de tablas

	Pág.
Tabla 1-1. porcentajes típicos de los diferentes componentes del cemento	8
Tabla 2-1. Propiedades a tracción directa de diferentes UHPFRC	30
Tabla 4-1. Composición física y química del cemento y materiales cementantes suplementarios (Abellán, 2020).....	49
Tabla 4-2. Tipos de fibra incorporadas a la mezcla de UHPFRC	50
Tabla 4-3. Proporción de los materiales que componen las mezclas de UHPFRC.....	53
Tabla 4-4. Campaña experimental del UHPFRC.....	53
Tabla 5-1. Variables de entrada para los modelos de predicción del comportamiento a tracción del UHPFRC.....	57
Tabla 5-2. Valores promedio del comportamiento a tracción directa del UHPFRC.....	73
Tabla 5-3. Valores experimentales y valores obtenidos de los modelos de Bosques Aleatorios para Y1.	79
Tabla 5-4. Medidas de desempeño del modelo de Y1	80
Tabla 5-5. Valores experimentales y valores obtenidos de los modelos de Bosques Aleatorios para Y2.	91
Tabla 5-6. Medidas de desempeño del modelo de Y2	92
Tabla 5-7. Dosificación de UHPC a considerar en la optimización multiobjetivo (Abellán, Núñez, Torres, et al., 2020).....	101
Tabla 5-8. Fibras disponibles en el mercado colombiano a considerar en la optimización multiobjetivo (Abellán-García, 2020b)	101
Tabla 5-9. Objetivos de la optimización de las respuestas de la mezcla UHPFRC para aplicaciones de reforzamiento sísmico de estructuras	102
Tabla 5-10. Mezcla de UHPFRC optimizada para aplicaciones de reforzamiento sísmico de estructuras	103
Tabla 8-1. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF50-1	107
Tabla 8-2. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF50-2.....	109
Tabla 8-3. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF100-1	111
Tabla 8-4. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF100-2.....	114

Tabla 8-5. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF150-1	117
Tabla 8-6. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF150-2	120
Tabla 8-7. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF50-1	123
Tabla 8-8. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF50-2.....	126
Tabla 8-9. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF100-1	129
Tabla 8-10. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF100-2.....	132
Tabla 8-11. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF150-1	138
Tabla 8-12. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF150-2.....	140

Introducción

El desarrollo de nuevos concretos de alto desempeño capaces de desarrollar elevadas resistencias y ductilidad, en especial con respecto al comportamiento a tracción directa, ha sido de gran interés científico en los últimos años (Abellán-García, 2020b; Abellán-García, Nuñez-Lopez, et al., 2020). Un claro ejemplo de estos nuevos materiales es el concreto de ultra alto desempeño reforzado con fibra (UHPFRC, por sus siglas en ingles), el cual permite que, luego de que ocurra un proceso de fisuración en el concreto, la fibra actúe como puente en la matriz cementante y proporcione una resistencia al aumento de la abertura de la fisura (Pyo et al., 2015). Esto permite que el comportamiento de este concreto especial reforzado con fibras desarrolle un comportamiento estructural de endurecimiento por deformación y, por ende, de ductilidad.

De acuerdo con el ACI Committee 239R-18 (2018) el UHPFRC se define como un concreto con una resistencia mínima a compresión de 150 MPa, con alta ductilidad y tenacidad al ser sometido a cargas de tracción, y que, por lo general, está reforzado con fibra para cumplir los requisitos especificados. No obstante, se ha especificado que el UHPFRC posee una alta durabilidad contra el ataque químico, abrasión y penetración de cloruros (Naaman & Wille, 2012 y Benjamin A., 2006). De igual manera, al implementar este material en los diseños y construcción de nuevas obras de infraestructura, se reducen secciones en los elementos estructurales en comparación con el concreto convencional, lo que implicaría una reducción en la producción de cemento y, como resultado, una reducción en las emisiones de CO₂ (Christopher et al., 2017).

Por otra parte, alcanzar deformaciones pos-fisuración del UHPFRC ha sido un reto para la comunidad científica. Esto se debe a que para ello se requieren grandes cantidades de dosificaciones de fibra de refuerzo, aproximadamente entre 4 y 6% del volumen total de la mezcla (S. H. Park et al., 2012). Estas grandes cantidades de fibra de refuerzo hacen que los costos de producción del UHPFRC sean excesivos y, por ende, no sea tenido en cuenta como material de construcción en los países Latinoamericanos.

Sin embargo, a través del tiempo se han realizado cada vez más investigaciones sobre el comportamiento a tracción directa del UHPFRC. De hecho, K Wille et al. (2011), pioneros en el estudio del UHPFRC, lograron obtener altas resistencias a tracción directa pos-fisuración (14.2MPa) y una deformación pos-fisuración de hasta 0.24%, mediante la incorporación a la matriz cementante de un contenido en volumen del 2.5% de fibra de acero recta. Por lo tanto, se logró establecer que era posible obtener comportamientos aceptables de tracción directa en el UHPFRC, con contenidos relativamente bajos de fibra.

La incertidumbre y cantidad de ensayos necesarios para determinar mezclas de UHPFRC óptimas llevó a los científicos a recurrir a herramientas de otras áreas de la ingeniería que permitiesen optimizar los tiempos y resultados experimentales (Abellán-García, Fernández-Gómez, & Torres-Castellanos, 2020). El desarrollo de modelos y algoritmos de inteligencia artificial y aprendizaje automático supervisado han sido aplicados en el desarrollo de nuevos materiales de construcción como lo es el UHPFRC. Los Bosques Aleatorios, Redes Neuronales o Regresión No-Lineal son algunos ejemplos de los modelos que pueden desarrollarse con el objetivo de realizar predicciones del comportamiento del concreto u otro material de construcción, y así, reducir considerablemente la campaña experimental (Nilsen et al., 2019).

Las técnicas de predicción de una respuesta construyen una relación entre las variables de entrada o independientes y las variables de salida o dependiente mediante procesos estadísticos. Dichos procesos o técnicas estadísticas permiten que una herramienta computacional aprenda de una base de datos consolidada sin ser programada explícitamente (Junfei Zhang et al., 2019). Sin embargo, se ha identificado que los coeficientes de correlación de los modelos resultan con valores erróneos debido a la cantidad de datos innecesarios incluidos en las variables de entrada (Auret & Aldrich, 2012). En una publicación realizada por Zhang et al. (2019), se establece que para evitar este tipo de inconveniente es necesario que se apliquen algoritmos de aprendizaje automático que sean capaces de medir la importancia de las variables de entrada, como en el caso de los Bosques Aleatorios. Estos algoritmos son capaces de realizar tareas de regresión y clasificación no lineal y no paramétrica, estableciendo la importancia de cada variable independiente (Genuer & Poggi, 2020).

En el presente proyecto se busca desarrollar algoritmos de aprendizaje automático supervisado del tipo Bosques Aleatorios, con el objetivo de predecir el comportamiento a tracción directa del UHPFRC, en particular la capacidad de absorción de energía (g) y la deformación unitaria bajo carga máxima (ϵ_{pc}). Para ello, es indispensable la recolección de la mayor cantidad de datos relacionados con el comportamiento a tracción directa del UHPFRC, identificando principalmente aquella literatura en la que se incluyan los deseados (ϵ_{pc} y g). Antes del entrenamiento de los modelos de Bosques Aleatorios fue necesario el realizar un tratamiento de los datos, con la finalidad de detectar y eliminar aquellas observaciones anómalas. Para realizar este análisis se utilizaron los diagramas *bagplot* o gráficos *bopxplot* bidimensionales. Una vez detectadas y eliminadas las observaciones anómalas, la base de datos resultante se dividió en dos: datos de entrenamiento (para entrenar los modelos) y datos de validación (para evaluar los modelos entrenados). Los modelos de Bosques Aleatorios se desarrollaron en el lenguaje de programación R (R Core Team, 2018) utilizando la función *randomForest* (Genuer & Poggi, 2020). Para la evaluación de los modelos se utilizaron los siguientes índices estadísticos: raíz del error cuadrático medio (RMSE), coeficiente de correlación (R^2), desviación estándar de los datos medidos (RSR), coeficiente de eficiencia de Nash-Stucliffe (E), error medio en valor absoluto (MAE), error promedio (AE) y error de sesgo medio normalizado (NMBE). Además de sobre los datos de validación, los modelos entrenados se evaluaron sobre trabajos experimentales.

Una vez entrenados y validados los modelos predictivos de Bosques Aleatorios, se utilizó un algoritmo de optimización multiobjetivo basado en el trabajo de Derringer & Suich (1980) que permitió identificar la dosificación de fibras que, sobre una mezcla de concreto optimizada por Abellán-García (2020b), obtuviesen los valores de ductilidad deseados ($g \geq 50 \text{ kJ/m}^3$ y $\epsilon_{pc} \geq 0.3\%$) al menor costo. Los valores objetivo para los parámetros de ductilidad del UHPFRC se corresponden a los recomendados para garantizar un comportamiento de alta ductilidad del UHPFRC (K. Wille et al., 2014). De esta forma, las dosificaciones obtenidas de fibra y demás variables independientes permitirán dar una noción de la materia prima necesaria para desarrollar un UHPFRC con un buen comportamiento a tracción directa, lo cual reduce considerablemente de la campaña experimental necesaria a futuro. De igual manera, las dosificaciones determinadas serán del menor costo posible en pesos colombianos, con el fin de aumentar el interés de diseñadores y constructores en Colombia y Latinoamérica en general de implementar el

UHPFRC en la elaboración de infraestructura nueva y el reforzamiento de infraestructura existente.

1. Marco teórico

Desde el inicio de la especie humana, se ha dispuesto de materiales extraídos de la naturaleza para la creación de refugios y estructuras que permitiesen la protección individual y colectiva de las diferentes sociedades. A través de los años, la evolución de la tecnología y del mismo ser humano ha contribuido a que hoy en día se implementen materiales duraderos, de altas resistencia y de alta ductilidad. El UHPFRC es un claro ejemplo de innovación y evolución en la búsqueda del material ideal para la construcción de nuevas estructuras y la rehabilitación de estructuras existentes, permitiendo obtener altas resistencia a compresión y adicionalmente resistencias y comportamientos a tracción que el concreto convencional no logra aportar (Abellán, Núñez, & Arango, 2020).

Por otra parte, el desarrollo de nuevos materiales de construcción no sería posibles de realizar sin la ayuda de la tecnología. Las herramientas computacionales permiten a los ingenieros realizar modelos matemáticos y estadísticos, con el fin de reducir las posibles infinitas combinaciones que pueden tener, por ejemplo, una mezcla de concreto del tipo UHPFRC (Abellán-García, 2020a; Abellán-García, Fernández-Gómez, Torres-Castellanos, et al., 2020; Jisong Zhang & Zhao, 2017b). La cantidad de cemento, humo de sílice, agua, agregado, fibra y demás componentes que se implementan en la elaboración del concreto son variables que pueden ser combinadas de infinidad de formas. El uso de la inteligencia artificial o aprendizaje automático (*machine learning* en inglés) permiten reducir la cantidad de ensayos necesarios para determinar si un material es apto o no para su uso en la ingeniería, o simplemente sirve como herramienta de predicción de las características y propiedades del material que podrían determinarse mediante ensayos de compresión y tracción, entre otros (Abellán, Sánchez, & Ospina, 2020; Ghafari, Bandarabadi, et al., 2015; Jisong Zhang & Zhao, 2017a).

A continuación, se describen los diferentes conceptos básicos que se mencionan en el presente proyecto, tales como la definición del UHPFRC y sus diferentes componentes, y

lo relacionado con el uso de Bosques Aleatorios (*Random Forest* en inglés) para la predicción el comportamiento a tracción directa del UHPFRC.

1.1 UHPFRC

Según el ACI Committee 239R-18 (2018) el UHPFRC se define como un concreto con una resistencia mínima a compresión de 150 MPa, con alta ductilidad y tenacidad al ser sometido a cargas de tensión, y que por lo general está reforzado con fibra para cumplir los requisitos especificados. No obstante, en la literatura se encuentran características adicionales para el UHPFRC, las cuales se listan a continuación (Eide & Hisdal, 2012):

- Resistencia a tracción directa sin adición de fibra entre 7 y 8 MPa.
- Relación agua/material cementante (W/B) menor a 0.25, y frecuentemente entre 0.16 y 0.2. Siendo el material cementante la mezcla de todos los materiales pulverulentos como cemento, humo de sílice, harina de cuarzo, entre otros.
- Alto contenido de material cementante, lo cual conlleva a reducir la porosidad en el compuesto.
- Incorporación de fibras para garantizar un comportamiento dúctil.

Por su parte, la Sociedad Japonesa de Ingenieros Civiles (JSCE, por sus siglas en inglés) en sus recomendaciones sobre el uso de compuestos cementantes de alto desempeño reforzados con fibra (HPFRCC, según sus siglas en inglés) ha desarrollado ecuaciones de diseño para el cálculo estructural a partir de los resultados de los ensayos a tracción directa propuestos en el mismo documento. Al realizar diseños estructurales con concreto convencional, se parte de la teoría de que el concreto resiste únicamente los esfuerzos de compresión a los que puede estar sometido en su vida útil, y que los esfuerzos de tensión serán resistidos en su totalidad por el acero de refuerzo introducido en el concreto. En el caso del UHPFRC, este compuesto es capaz de resistir una cierta cantidad de solicitaciones a tensión, lo cual permite que en el diseño de nuevas estructuras se reduzca o se elimine la cantidad de refuerzo convencional (barras de acero o mallas) en los elementos, y así, se logra disminuir los materiales de construcción (Martin-Sanz et al., 2016). Por esta razón, la JSCE propone en su documento de recomendaciones,

ecuaciones de resistencia a flexión, compresión, tensión y corte, que permiten que el ingeniero tenga una base sobre el aporte que a fibra de refuerzo tiene sobre los elementos estructurales, y de esta forma obtener diseños apropiados.

Se observa además que, a diferencia del concreto convencional, el empaquetamiento de partículas resulta ser un factor de gran importancia en el desarrollo del UHPFRC. De hecho, la baja porosidad y las excelentes propiedades mecánicas que presenta este nuevo material cementante se atribuyen al adecuado empaquetamiento de partículas. Algunos de las metodologías de diseño de mezclas de UHPFRC basadas en la optimización de empaquetamiento de partículas más relevantes serían el modelo de Andreasen y Andersen modificado (Funk & Dinger, 1994) y el modelo de empaquetamiento compresible (De Larrard, 1999). Las sobresalientes propiedades del UHPFRC, a consecuencia de su elevado grado de empaquetamiento de partículas, permiten reducir las secciones en elementos estructurales, por sus altas resistencias. Además, y debido a la adición de la fibra en dosificaciones adecuadas, obtener un comportamiento dúctil y apropiado para su aplicación en el refuerzo sismo resistente de estructuras no dúctiles (Abellán-García et al., n.d.; S. H. Park et al., 2012; Y. J. Park et al., 1984). Este extraordinario comportamiento del UHPFRC hace que sea un material de ingeniería sostenible y adecuado para el diseño, construcción y rehabilitación de estructuras (Dagenais et al., 2018). Se observa entonces que el UHPFRC se diferencia en varios aspectos con respecto al concreto convencional. El hecho de tener mayores resistencias a compresión y a tracción hace del UHPFRC un material ideal para la práctica de la ingeniería. Además, se ha observado que el UHPFRC es resistente al ataque de sustancias químicas como cloruros (Eide & Hisdal, 2012). El extraordinario comportamiento del UHPFRC hace que sea un material de ingeniería sostenible para cualquier aplicación.

La dosificación típica de UHPFRC se basa en cemento, humo de sílice, materiales cementantes suplementarios, harina de cuarzo, superplastificante reductor de agua de alto rango, arena silícea y fibras de refuerzo (Abellán-García et al., 2019).

1.2 Cemento

Actualmente, el cemento es la materia prima que más se utiliza en la construcción de nuevas edificaciones. El cemento es por excelencia un material barato y versátil, el cual sirve como aglomerante, con propiedades de adherencia y cohesión, y al mezclarse con otros materiales permite obtener altas resistencias a compresión y alta durabilidad. Por lo general, al hablar de cemento se hace referencia al cemento portland, el cual al ser mezclado con agua desarrolla la propiedad de fraguar y endurecerse, proceso llamado hidratación (Sanchez de Guzmán, 2001).

En Colombia, la primera fábrica del país se inauguró en el año 1905 por parte de la “Cemento Samper” (Sanchez de Guzmán, 2001). Esta fábrica cementera trabajó durante 4 años en un pequeño horno, con una producción de hasta 10 toneladas diarias. No fue hasta 1934 cuando se instalaron los primeros hornos rotatorios en el país, aumentando la producción de cemento de 10 a 150 toneladas al día. Sin embargo, con la evolución de la industria de la construcción, surgieron nuevos exponentes en el mercado, como cementos Argos en 1936 con una producción de 50 toneladas al día, Cementos del Valle en 1941, Cementos del Nare en 1943, Cementos Caribe en 1949 y Cementos Hércules en 1959.

El cemento se obtiene básicamente de la extracción de materias primas del suelo, con las cuales se producen el Clinker, principal compuesto del cemento. El cemento se compone de CaO , el cual se extrae de materiales ricos en cal (un claro ejemplo es la piedra caliza), SiO_2 y Al_2O_3 , extraído de la arcilla, pizarra, entre otros compuestos, y Fe_2O_3 , obtenida de minerales de hierro, costras de laminado o algún material semejante (Quiroz & Salamanca, 2006). En la Tabla 1-1 se exponen los porcentajes típicos de los diferentes componentes del cemento.

Tabla 1-1. porcentajes típicos de los diferentes componentes del cemento

	Óxido componente	Porcentaje Típico
Cal combinada	CaO	62.5%
Sílice	SiO ₂	21%
Alúmina	Al ₂ O ₃	6.5%

	Óxido componente	Porcentaje Típico
Hierro	Fe_2O_3	2.5%
Cal libre	CaO	0%
Azufre	SO_3	2%
Magnesio	MgO	2%
Álcalis	Na_2O y K_2O	0.5%
Pérdida al Fuego	P.F.	2%
Residuo Insoluble	R.I.	1%

Al extraer las diferentes materias primas que componen el cemento se realiza inicialmente el proceso de trituración y molienda de los componentes. La trituración del material extraído consiste en reducir el tamaño de la piedra bruta hasta alrededor de 1.5 cm o hasta alcanzar la granulometría deseada. Posteriormente, el material que resulta de la trituración pasa a la molienda, en donde mediante el uso de equipos mecánicos rotatorios se obtiene el polvo crudo, el cual es almacenado en silos. El material obtenido de la molienda es procesado en un horno rotatorio, el cual alcanza temperaturas de hasta 1450°C , proceso llamado calcinación, y del cual se obtiene un nuevo material denominado Clinker. Por último, el Clinker es almacenado en un silo para posteriormente ser mezclado en un 5 a 7% de yeso en equipos mecánicos, proceso llamado molienda de acabado (Quiroz & Salamanca, 2006). La Figura 1-1 expone un resumen del proceso de producción del cemento.

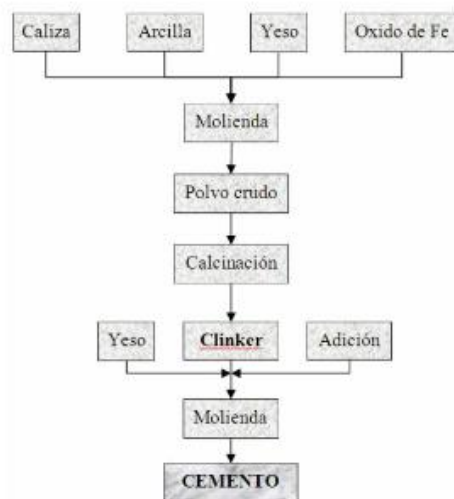


Figura 1-1. Proceso de producción del cemento (Quiroz & Salamanca, 2006).

Actualmente, las especificaciones de desempeño para los cementos hidráulicos disponibles en el mercado colombiano se describen en la Norma Técnica Colombiana, NTC (2014). Los tipos de cemento hidráulico están directamente relacionados con el desempeño del concreto, en el que se incluye el desarrollo de resistencia a compresión, resistencia a los sulfatos, calor de hidratación y resistencia a la reactividad álcali-sílice. Cabe mencionar que, el desempeño del concreto no depende únicamente del cemento hidráulico implementado, de igual manera se debe tener en cuenta la calidad de los demás componentes, el diseño de mezcla, la producción, el manejo y las condiciones ambientales. A continuación, se mencionan los tipos de concreto establecidos en la NTC (2014).

- **Tipo UG:** Es un cemento hidráulico para construcción general. Utilícese cuando uno o más de los tipos especiales no sean requeridos.
- **Tipo ART:** Cemento hidráulico de alta resistencia temprana.
- **Tipo MRS:** Cemento hidráulico de moderada resistencia a los sulfatos.
- **Tipo ARS:** Cemento hidráulico de alta resistencia a los Sulfatos.
- **Tipo MCH:** Cemento hidráulico de moderado calor de hidratación.
- **Tipo BHC:** Cemento hidráulico de bajo calor de hidratación.

1.3 Humo de Sílice

Es un producto inorgánico conformado por partículas esféricas muy finas, el cual se obtiene como consecuencia de procesos en la creación de silicio metal o ferro silicio en hornos eléctricos de arco (Malhotra et al., 2018). Hoy en día su uso en el concreto a aumentado exponencialmente debido a que su finura y propiedades de adherencia permiten obtener altas resistencias (Alla et al., 2020). El humo de sílice posee un alto contenido de SiO_2 y un bajo contenido de carbón, lo cual juega un papel importante en la zona de interacción interfacial (ITZ por sus siglas en inglés) del concreto (Shi et al., 2015a). La acumulación de cristales de hidróxido de calcio (CH) en el ITZ produce zonas de debilidad y fisuración en el concreto por las diferentes propiedades termo mecánicas de la pasta de cemento y los agregados. Es en este punto donde el humo de sílice gracias a sus propiedades

puzolánicas consume parte del CH y lo transforma en silicatos de calcio hidratado (CSH), los cuales contribuyen en la resistencia del concreto (Poon et al., 2001).

El humo de sílice se encuentra normalizado en las normas ASTM C1240 y el ACI 234R.

Por lo general las dosificaciones del humo de sílice en el concreto varían entre el 5% y 12% del peso de los materiales cementantes, en el caso de ser aplicado a estructuras de concreto que requieren altas resistencias o permeabilidad significativamente baja (Castellanos Torres, 2014).



Figura 1-2. Humo de sílice (Abellan-Garcia et al., 2020)

1.4 Materiales cementantes suplementarios

Con el objetivo de desarrollar el UHPFRC es necesario la implementación de materiales finos y que logren obtener una mezcla densa y de alta resistencia. El uso de materiales cementantes suplementarios permite además reducir las cantidades de cemento y humo de sílice del UHPFRC, reduciendo el costo y el impacto ambiental del concreto (Abellán-García, Núñez-López, et al., 2020). Un material cementante suplementario utilizado en el desarrollo del UHPFRC es el polvo de vidrio, producto de la molienda de residuos de vidrio reciclado, con granulometría que se ajusta a la típica de la harina de cuarzo y que sirve como material de relleno (Neira, 2020).



Figura 1-3. Polvo de vidrio (Abellan-Garcia et al., 2020)

Por otra parte, el carbonato de calcio resulta ser un material ideal para llenar los micro vacíos del empaquetamiento granular que se presenta en el UHPFRC. Este material se obtiene por lo general de la piedra caliza al pasar por un proceso de molienda, y que al ser incluida en la mezcla del UHPFRC actúa como lubricante y permite además reducir la cantidad de superplastificante necesario (Abellán, Fernández, Torres, et al., 2020).



Figura 1-4. Carbonato de calcio (Jaramillo, 2020)

1.5 Harina de cuarzo

Consiste en un mineral compuesto por dióxido de sílice, SiO_2 , localizado en varias rocas ígneas y metamórficas. Al ser incluido en mezclas de concreto este material contribuye en

la aceleración de la hidratación del cemento, mejora la trabajabilidad debido a que sirve como relleno de los vacíos entre los agregados y el material cementante, y aumenta la densidad y resistencia mecánica del concreto o incluso el UHPFRC (Rashad, 2018).



Figura 1-5. Diferentes tipos de harina de cuarzo (Rashad, 2018)

De acuerdo con Rashad (2018), debido a que la producción del cemento presenta un impacto significativo en el medio ambiente y requiere de grandes cantidades de energía, sustituir el cemento con harina de cuarzo puede reducir el consumo de energía y las emisiones de CO₂.

1.6 Superplastificante de alto rango

Los aditivos reductores de agua de alto rango (HRWRA, por sus siglas en inglés) son incluidos en mezclas de concreto con relaciones bajas de agua/material cementante y cuando se hace uso de fibras de refuerzo, dado a que la trabajabilidad del compuesto cementante se ve afectada negativamente. Según Alcaraz (n.d.), los superplastificantes de alto rango basado en policarboxilatos son ideales en estructuras que requieren de altas resistencias iniciales y trabajabilidad, haciéndolo un material fundamental en la industria de los prefabricados.



Figura 1-6. Superplastificante de alto rango (Jaramillo, 2020)

1.7 Arena de sílice

Es una combinación de sílice y oxígeno (SiO_2) en forma de cuarzo para su aplicación como agregado (Chaudhary et al., 2015). Para la producción de arena de sílice es necesario llevar a cabo un proceso de lavado, limpieza de los granos, tamizado para remover residuos gruesos y una remoción hierro, cromo y otros minerales mediante alteraciones físicas y químicas. De esta forma, es posible obtener granos de arena de sílice entre 1.15mm y 600 μm para ser incluidos como reemplazo de agregado fino en el concreto.



Figura 1-7. Arena de sílice (Abellan-Garcia et al., 2020)

1.8 Fibra de refuerzo

El concreto convencional es un material compuesto que se usa para la construcción, y que no posee la capacidad de resistir esfuerzos importantes a tracción por sí mismo. Es necesario que este material sea reforzado con otro tipo de materiales, como el acero, para que los esfuerzos a tracción que el concreto experimenta a lo largo de su vida útil sean soportados. Las barras de acero o mallas electrosoldadas normalmente son introducidas al concreto, ya que son capaces de resistir altas tensiones de tracción sin romperse o fracturarse (Malatesta & Contreras, 2009). Sin embargo, en los últimos años se ha investigado la posibilidad de reemplazar parcial o totalmente el refuerzo convencional por fibras de refuerzo, ya sean de acero, polipropileno, polietileno, PVA y hasta nylon.

Las fibras de refuerzo son pequeños filamentos con un límite elástico elevado, donde las dimensiones como el diámetro y la longitud (ver Figura 1-8) tienen una importancia muy significativa en las propiedades finales del concreto. Al introducir fibras en el concreto es posible que se reemplace parcial o totalmente el refuerzo convencional (barras de acero o mallas electrosoldadas). La aplicabilidad de las fibras de refuerzo varía desde reforzamiento de pisos industriales hasta la elaboración de túneles de carretera, ferroviarios o hidráulicos. El uso de fibras en el concreto contribuye a mejorar el proceso constructivo y el comportamiento sísmico de elementos estructurales, lo que redundará en viviendas más económicas y seguras (Gallo Arciniegas et al., 2013). Por tanto, la utilización de nuevos materiales de refuerzo que ayuden a la reducción de costos con un comportamiento igual o similar a los utilizados para la construcción puede ayudar a que la evolución de la ingeniería sea sostenible.

La geometría de la fibra determina la esbeltez, factor que tiene gran influencia en las características mecánicas del concreto con fibras. La longitud (l_f) y el diámetro (d_f) de la fibra de refuerzo dependen del tipo de fibra escogida, pero deben garantizar que la relación de aspecto o esbeltez (l_f/d_f) sea la más adecuada para su mezcla en el concreto. El ACI Committee 544.1R-96 (2002), indica que una mayor relación de aspecto es ideal para mejorar el comportamiento del concreto luego de sobrepasar su resistencia pico (a tracción directa o flexión) debido a que la resistencia de ser extraída de la matriz incrementa con la esbeltez. Sin embargo, la fibra con mayor relación de aspecto puede generar

inconvenientes por su tendencia a enredarse durante la mezcla del concreto. Por otra parte, la dosificación de la fibra en el concreto debe ser la adecuada para garantizar el buen desempeño del concreto. La dosificación de la fibra puede ser expresada en kg/m^3 (D_f) y en fracción de volumen (V_f), el cual corresponde al cociente en porcentaje entre D_f y la densidad del material de la fibra.




Figura 1-8. Geometría de las fibras más comunes (NMX, 2014).

1.9 Resistencia a compresión

Es la principal propiedad mecánica a la que cualquier tipo de concreto debe ser sometido. La resistencia a compresión (f'_c) es definida, por lo general, en términos de MPa, cuya determinación se realiza generalmente empleando pruebas destructivas a probetas cilíndricas, cúbicas o primas (Sanchez de Guzmán, 2001). Por lo tanto, la resistencia a compresión está dada de acuerdo con la ecuación 1-1.

$$f'_c = \frac{P}{A} \quad (1-1)$$

1.9.1 Ensayo de cilindro

El ensayo de probetas cilíndricas es una de las metodologías más utilizadas para la determinación de la resistencia a compresión del concreto. En Colombia, el ensayo de resistencia a compresión se desarrolla bajo la Norma Técnica Colombiana NTC-673, en la que se hace uso de cilindros de 150mm de diámetro por 300mm de altura. Sin embargo, cilindros de 100mm de diámetro por 200mm de altura son implementados actualmente por mayor facilidad y economía, dado que para concretos de alta resistencia se podría hacer uso de máquinas universales de menor capacidad. Las probetas son sometidas a esfuerzos de compresión a una velocidad aproximada de 1.3mm/min (NTC, 2000a). Por lo general, la superficie de contacto entre la máquina universal y el cilindro no es plana, ya que esto puede producir concentración de esfuerzos en la probeta, razón por la cual se

hace un refrentado de las tapas del cilindro con materiales como yeso o mezclas compuestas de azufre. La Figura 1-9 expone el montaje y ensayo a compresión de probetas cilíndricas.



Figura 1-9. Ensayo a compresión de cilindros

1.9.2 Ensayo de cubos

Este tipo de ensayo es poco generalizado y utilizado en Colombia, por lo cual no está normalizado en el país. En países europeos como Inglaterra y Alemania realizan ensayos a compresión con cubos de 50mm, 100mm y hasta 150mm de arista, siguiendo la norma BS-1881. Debido a que se tiene una probeta con 6 lados iguales no es necesario realizar un refrentado de las probetas, ya que la superficie de contacto entre la maquina universal y la probeta será plana (Sanchez de Guzmán, 2001). Se determina mediante el uso de la ecuación 1-1.

Dado el alto costo que representa realizar probetas cilíndricas de UHPFRC, por lo general se recurre a cubos para los ensayos de compresión. En varias investigaciones se ha determinado que, la resistencia a compresión de cilindros de UHPFRC y concreto en general, resultan ser hasta 0.8 veces la resistencia obtenida al ensayar cubos (Kusumawardaningsih et al., 2015). Cabe mencionar que, la resistencia a compresión de los cubos de UHPFRC no son resistencias uniaxiales, por lo tanto, es necesario convertir

los datos obtenidos a valores de probetas cilíndricas (Kusumawardaningsih et al., 2015). La Figura 1-10 ilustra el montaje y ensayo a compresión de probetas cúbicas.




Figura 1-10. Ensayo a compresión de cubos (Neira, 2020)

1.10 Resistencia a tracción

Es una de las propiedades mecánicas más difíciles de determinar mediante la implementación de ensayos directos. Se han presentado a través de los años incertidumbres sobre los métodos de ensayo directo a probetas de concreto, debido a que se podrían estar generando esfuerzos secundarios inducidos por los elementos que sujetan las probetas (Sanchez de Guzmán, 2001).

Con el objetivo de evitar esfuerzos secundarios en los ensayos de tracción en el concreto, ingenieros brasileños y japoneses desarrollaron de manera independiente métodos de ensayos de tracción indirecta. En Colombia, los ensayos de tracción indirecta se elaboran siguiendo la norma NTC-722, en la que se elaboran especímenes cilíndricos de 150mm y 300mm de altura, los cuales son sometidos a compresión a lo largo de dos líneas diametralmente opuestas (NTC, 2000b). La ilustra el montaje y ensayo de tracción indirecta de especímenes de concreto.




Figura 1-11. Ensayo de tracción indirecta del concreto

No obstante, la JSCE (Yokota et al., 2008), desarrolló recomendaciones para el diseño y construcción de compuestos cementantes de alto desempeño reforzados con fibra (HPFRCC, según sus siglas en inglés). En el documento desarrollado por la JSCE se propone un método de ensayo de tracción directa para concretos de muy alto desempeño, en el que se dispone de una probeta en forma de hueso de perro, la cual es sometida a esfuerzos de tracción mediante el uso de mordazas en ambos extremos del espécimen. Cabe mencionar que, se debe garantizar la inexistencia de excentricidades en las cargas aplicadas, ya que esto podría derivar en un comportamiento erróneo en la prueba. De igual manera, se debe evitar la concentración de esfuerzos en los extremos del alma del hueso de perro, ya que la probeta podría presentar una falla en estas zonas. Cabe mencionar que, en el capítulo 4 del presente proyecto se describe con mayor profundidad lo establecido por la JSCE para ensayos de tracción directa en el UHPFRC.

1.11 Árboles de decisión

El aprendizaje automático (*machine learning en inglés*) ha sido centro de investigación a nivel mundial desde su reconocimiento como disciplina a mediados de los años 50 (Quinlan, 1986). Uno de los métodos utilizados para el aprendizaje automático es mediante la implementación de árboles de clasificación y regresión, también llamados árboles de

decisión. Comúnmente, los árboles de decisión se implementan como una estrategia para alcanzar un objetivo específico. Sin embargo, su campo en el aprendizaje automático es amplio a la hora de predecir o estimar datos analíticos (Nilsen et al., 2019).

En la vida cotidiana, es posible realizar un árbol de decisión para cada una de las decisiones que se toman en el día. En un ejemplo expuesto por Seif (2018), determina que el simple hecho de establecer qué actividades se podrían realizar el fin de semana puede derivar en la creación de un árbol de decisiones. Puede que el clima determine si una persona tiene el ánimo de pasar el fin de semana con amigos o solo en casa. Si el día es soleado y los amigos están disponibles podrían jugar fútbol, o si el día es lluvioso podrían ver una película en casa. Por otra parte, si los amigos no están disponibles podría quedarse en casa jugando videojuegos sin importar el clima. La Figura 1-12 expone cómo sería en este caso un árbol de decisiones para el ejemplo anterior.

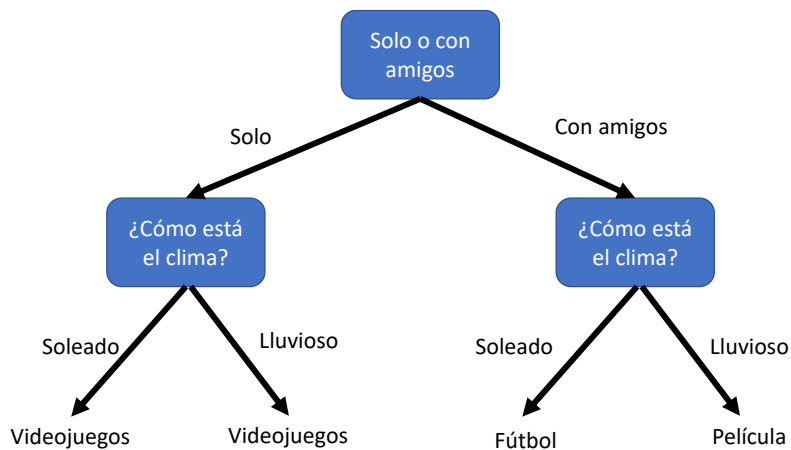


Figura 1-12. Ejemplo de un árbol de decisiones

Esto constituye un ejemplo de árboles de decisiones en la vida real. Básicamente lo que se realiza es una clasificación de los componentes que pueden afectar la toma de decisiones de manera secuencial y jerárquica, lo que al final nos lleva a obtener un resultado específico. No obstante, Seif (2018) especifica que es posible llevar el árbol de decisiones del ejemplo a un nivel más complicado, en donde se vea involucrado, por ejemplo, la temperatura del ambiente. Esto es lo que busca realizar en los árboles de

decisión del aprendizaje automático, construir un árbol con decisiones jerárquicas que nos lleven a la predicción de un resultado, ya sea de clasificación o regresión.

2. Estado del arte

A continuación, se describe la evolución del UHPFRC y cómo este compuesto ha sido estudiado por varios investigadores en los últimos años, analizando composición, costos, aplicaciones y propiedades, haciendo énfasis en la propiedad en la que se enfoca este estudio: el comportamiento a tracción directa. La descripción de los resultados obtenidos por otros investigadores sobre el comportamiento a tracción directa del UHPFRC, permite obtener una idea de los resultados que se esperan en el presente proyecto. Asimismo, se expone cómo el UHPFRC se ha implementado en el mundo y Latinoamérica para la construcción de estructuras con alta durabilidad y resistencia.

Por último, se describe cómo la inteligencia artificial (I.A) ha evolucionado, y cómo el uso de Bosques Aleatorios, herramienta empleada en el presente trabajo, ha permitido a investigadores a predecir y clasificar problemas de ingeniería y demás.

2.1 Introducción al UHPFRC

2.1.1 Historia, desarrollo e introducción al mercado Latinoamericano

El concreto convencional ha sido el material con mayor demanda en la industria de la construcción desde su aparición en el siglo XVIII (Pérez, 2014). Al ser un material capaz de brindar altas resistencias a compresión, resistencia al fuego, durabilidad en las estructuras, entre otras características, permite la construcción de obras de ingeniería al servicio de la sociedad. Sin embargo, en los últimos años la tecnología del concreto ha evolucionado, ofreciendo materiales con mayor resistencia a compresión, baja porosidad,

mejor trabajabilidad, estética, y al incorporarse fibra de refuerzo, mayor ductilidad (Abellán et al., 2018). Estos nuevos materiales de construcción, como lo es el UHPFRC, desplazan cada vez más al concreto convencional en la construcción y diseño de proyectos.

Las investigaciones y el uso de UHPFRC han aumentado de la mano de los avances de la ingeniería y la tecnología. Este concreto especial se empezó a desarrollar en la década de 1970 con la aparición de los superplastificantes (reductores de agua de alto rango), que mejoraban la manejabilidad del concreto bajando drásticamente su relación a/c, llegando a obtener resistencias a compresión entre 60 y 120 MPa (Sohail et al., 2018). Sin embargo, no fue hasta 1997 cuando se realizó la primera estructura en concreto de polvos reactivos (RPC por sus siglas en inglés). El puente Sherbrooke en Canadá, de 60 m de luz, fue construido con 42 m³ de RPC introducido en tubos de acero de pared delgada, obteniendo una resistencia a compresión de 350 MPa, y permitiendo omitir el uso de refuerzo principal en los elementos del puente debido a la alta ductilidad (Sohail et al., 2018).

Desde la construcción del puente de Sherbrooke, el interés por el diseño y construcción de estructuras con UHPFRC ha aumentado. Países como Estados Unidos, Francia, Japón, Alemania y Países Bajos han investigado el UHPFRC para que sea implementado en el diseño de puentes peatonales, puentes viales, fachadas, balcones y prefabricados (Abellán et al., 2018). De hecho, existen recomendaciones sobre el uso del UHPFRC realizadas por la JSCE, el comité 239 del instituto americano del concreto (ACI-239, por sus siglas en inglés) y la asociación francesa de ingeniería civil (AFGC, por sus siglas en francés). Estas recomendaciones han sido aplicadas en diversos proyectos alrededor del planeta, como en España, donde se realizó un puente peatonal sobre el Barranco de las Ovejas (ver Figura 2-1). El proyecto consistió en una estructura de 45 metros de luz con prefabricados de UHPFRC, conservando los precios iniciales establecidos por los clientes (Serna Ros et al., 2012). Por lo tanto, la implementación del UHPFRC en la construcción de nuevos proyectos es viable. Las investigaciones deben continuar para crear códigos de construcción que lo haga un material reglamentado como lo es el acero estructural y el concreto reforzado.



Figura 2-1. Vista general del puente peatonal sobre el Barranco de las Ovejas (Carillo, 2013).

Por otra parte, las estructuras actuales diseñadas y construidas con concreto convencional se proyectan a tener una vida útil entre los 40 y 50 años para las estructuras convencionales y 100 años para las obras de infraestructura. Se estima que la incorporación parcial del UHPFRC en la construcción de puentes u otras estructuras, aumente la vida útil de éstas hasta 75 años más, y si realizaran estructuras utilizando UHPFRC en su totalidad, la vida útil podría ser de varias centenas de años (Doiron et al., 2018). Por lo tanto, el UHPFRC se posiciona en el sector de la construcción con el fin de reducir los costos totales a largo plazo y reducir los tiempos de construcción en los proyectos de ingeniería.

A pesar de los grandes avances en las investigaciones y diseño de estructuras con UHPFRC, su introducción en el mercado Latinoamérica ha sido tardío. La falta de reglamentación, el desconocimiento y el elevado precio inicial por metro cúbico del UHPFRC ha frenado su incorporación en los proyectos latinoamericanos. El UHPFRC es un material compuesto por materiales finos exclusivos y fibra de acero, polietileno o polivinilo de alcohol (PVA), como se verá en el siguiente punto, lo que hace que su precio inicial por metro cúbico sea hasta 15 o 20 veces más alto que el concreto convencional. Como consecuencia, se trata de un material poco atractivo para los constructores, a pesar de que en los proyectos se pueden llegar a reducir los materiales de construcción en hasta un 75% (Christopher et al., 2017). Así mismo, al diseñarse estructuras esbeltas, se reduce

el consumo de metros cúbicos de concreto, causando un impacto favorable en el medio ambiente, ya que según la agencia de evaluación medioambiental de los Países Bajos, cerca del 9.5% de las emisiones de CO₂ en el planeta son generadas por la producción de cemento, la cual podría reducirse al utilizar UHPFRC (Olivier et al., 2014).

No obstante, sin importar las dificultades, la empresa colombiana Argos S.A ha sido la primera productora de concreto en desarrollar UHPC en Latinoamérica. En Colombia, se cuenta además con dos infraestructuras construidas con este material: el puente peatonal sobre la avenida Las Vegas en Medellín (Abellán, Núñez, & Arango, 2020) y un puente peatonal en la Universidad Nacional sede Manizales (Abellán, Núñez, & Arango, 2020). En el caso del puente de Medellín, Argos S.A. propuso que el UHPFRC fuera implementado en la construcción de este puente peatonal que conecta a la universidad EAFIT con su edificio de idiomas, siendo la primera obra de infraestructura realizada con UHPFRC en Latinoamérica. El puente consta de 29 dovelas prefabricadas de UHPFRC con resistencia a compresión de 170MPa a los 28 días. Inicialmente, se proponía que el puente fuera diseñado en estructura metálica, pero al optar por el UHPFRC se presentó un ahorro de hasta el 33% del precio total del proyecto (Abellán et al., 2018). Una imagen de este puente durante su construcción se puede ver en la Figura 2 2.

El éxito en la construcción de estas infraestructuras ha llevado a la empresa Argos S.A., en colaboración con universidades como la Escuela Colombiana de Ingeniería Julio Garavito, a continuar con las investigaciones sobre el uso del UHPFRC. Estas investigaciones tienen como objetivo buscar reducir los costos iniciales por metro cúbico, ya que este resulta ser el principal problema por el cual no es implementado con mayor frecuencia en Colombia y Latinoamérica.



Figura 2-2. Vista del puente peatonal sobre la avenida Las Vegas en Medellín en una fase muy avanzada de su construcción en 2017 (Abellán-García, Nuñez-Lopez, et al., 2020).

2.1.2 Composición y costos

Como se ha visto, el UHPFRC está compuesto por materiales finos exclusivos que permiten obtener una matriz densa, y fibras de refuerzo para mejorar la ductilidad del compuesto. Mediante el análisis de 128 dosificaciones propuestas en la literatura sobre el UHPFRC, es posible determinar una dosificación promedio y su costo por metro cúbico (Abellán et al., 2018), la cual se observa en la Figura 2-3.




Figura 2-3. Composición y coste de mezcla media de UHPFRC. Número de dosificaciones observadas 128. Coste medio: 2.236.265 COP/m³. Contenido medio de fibras metálicas: 1,84% (Abellán et al., 2018).

Se evidencia en la Figura 2-3 que, el elemento que más influencia tiene en el costo por metro cúbico del UHPFRC es la fibra de refuerzo. Por tanto, es necesario reducir la cantidad de fibra en el UHPFRC, manteniendo sus propiedades, con el fin de disminuir los costos iniciales. Para ello, es necesario garantizar un incremento de la adherencia entre la matriz cementante y la fibra de refuerzo, acompañado de una alta resistencia de la fibra, con el fin de aumentar la cantidad de puntos de contacto entre el refuerzo y la mezcla, y tener como efecto una mejora en la adherencia fibra-matriz que pueda conducir a una reducción de la cantidad de fibras en el UHPFRC (K Wille et al., 2011). Esto ha llevado a que se haga uso de materiales locales muy finos como el humo de sílice y materiales cementantes suplementarios (polvo de vidrio o escoria granular) para reemplazar parcialmente el contenido de cemento, y así, obtener una mezcla de UHPFRC de mayor densidad de empaquetamiento (Shi et al., 2015a). Por lo tanto, una de las principales dificultades para la producción de UHPFRC es el alto costo que este representa con respecto al concreto convencional, debido a su alto contenido de materiales exclusivos y fibra de refuerzo, lo que lleva a un bajo interés de las empresas locales por la producción y comercialización de UHPFRC.

2.1.3 Comportamiento a tracción directa

El UHPFRC al estar reforzado con fibras, ya sean de acero, polietileno o PVA, pasa de presentar una falla frágil a dúctil, por lo cual es posible estudiar su comportamiento post-fisuración. Este comportamiento está directamente relacionado con el diámetro (d_f),

longitud (l), dosificación, orientación y material de la fibra. En la Figura 2-4 se expone una curva típica de esfuerzo-deformación de un ensayo de tracción directa del UHPFRC. Esta curva se divide básicamente en tres partes. La primera parte corresponde a la zona elástica del material, donde los esfuerzos son proporcionales a las deformaciones y alcanza hasta la fisuración del concreto (σ_{cc} , ε_{cc}); la segunda parte corresponde al endurecimiento por deformación, en donde se presenta el fenómeno de multifisuración de la probeta, hasta alcanzar la máxima tensión (σ_{pc} , ε_{pc}); y la tercera parte corresponde a la apertura total de la fisura, donde la tensión baja hasta un valor de 0, mientras que la deformación aumenta (K. Wille et al., 2014). Se concluye entonces que, para que exista endurecimiento por deformación es necesario que la tensión de la matriz que produce la primera fisura (σ_{cc}) sea menor que la tensión máxima pos-fisuración (σ_{pc}).

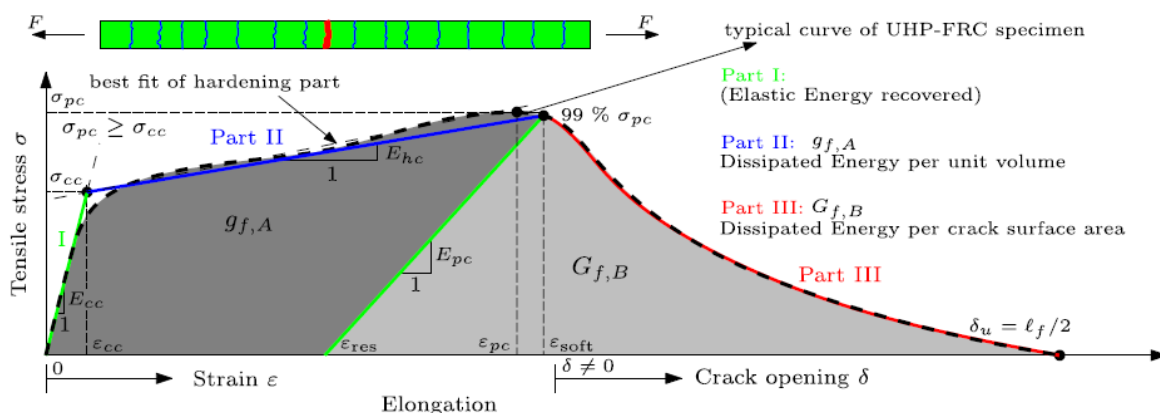


Figura 2-4. Endurecimiento por deformación del UHPFRC (K. Wille et al., 2014).

K. Wille et al. (2014), en una de sus investigaciones sobre el comportamiento post-fisuración del UHPFRC, establece que, los valores de la capacidad de absorción de energía (g) deben ser iguales o mayores a 50 kJ/m^3 , lo cual clasificaría al UHPFRC como un material de alta capacidad de absorción de energía. Asimismo, Kay Wille et al. (2011) indican que, para aplicaciones estructurales de UHPFRC, en conjunto con concreto reforzado convencional, se debe alcanzar por lo menos un valor de ε_{pc} igual o mayor a 0.3%, lo cual garantiza que las fibras contribuirán como mínimo con el estado de plastificación de las barras de refuerzo.

A pesar de que existen recomendaciones por parte de la JSCE (Japan Society of Civil Engineers, 2008) para efectuar ensayos de tracción directa en el UHPFRC, no existe una

normativa que establezca los procedimientos que se deben llevar a cabo. Esto ha llevado a los investigadores a proponer sus propios métodos de ensayo con el fin de obtener una respuesta de endurecimiento por deformación. Se proponen probetas de ensayo tipo prisma, cilindros y “dog-bone”, siendo este último el recomendado por la JSCE.

Se ha estudiado la posibilidad de utilizar probetas prismáticas para determinar el comportamiento a tensión del UHPFRC, siguiendo la norma para ensayo a tensión de probetas metálicas ASTM E8. Graybeal & Baby (2013), efectuaron ensayos a prismas de 50.8×50.8×431.8 mm³ de UHPFRC con pletinas de aluminio pegadas en los extremos, con el fin de aplicar cargas de tensión. Se encontró que con esta metodología de ensayo fue posible obtener la primera parte de la curva de esfuerzo-deformación (ver Figura 2-4), no obstante, no fue posible evaluar el comportamiento pos-fisuración, ya que en este punto las pletinas influenciaban los resultados de las pruebas (Benjamin A. Graybeal & Baby, 2013). Por otra parte, con el objetivo de lograr un comportamiento pos-fisuración, Denarié, Habel, & Brühwiler (2003) realizaron ensayos a probetas prismáticas pero con un corte en la mitad, con el fin de producir la falla en este punto, sin embargo, gran parte de los ensayos realizados mostraron que este tipo de probeta con corte en la mitad es ideal para evaluar la tercera parte de la curva de esfuerzo-deformación (Figura 2-4).

Se observa entonces que, obtener las tres partes de curva de esfuerzo-deformación en una misma prueba de tensión directa resulta tedioso y complicado (ver Figura 2-4). A pesar de ello, se recomienda el uso de probetas en forma de hueso de perro o “dog-bone”, las cuales son sujetadas mediante mordazas en sus extremos, sin apoyarse en los cambios de sección y sin generar excentricidades en el montaje, con el objetivo de que no haya concentración de esfuerzos en los extremos, se presente un escenario de multifisuración y la falla se genere en el alma. La Figura 2-5 muestra las dimensiones recomendadas para estas probetas por la JSCE. No obstante, al no ser una norma consolidada, diversos investigadores han diseñado diferentes formas y dimensiones de este tipo de probeta, obteniendo resultados satisfactorios. Un ejemplo de ello es un estudio realizado por Park, Kim, Ryu, & Koh (2012), donde se realizaron ensayos de tracción directa a probetas tipo “dog-bone” de UHPFRC reforzado con una mezcla de micro-fibra y macro-fibra de acero, con dimensiones en el alma de 220×50×100 mm. Park et al. (2012), mantuvieron la

dosificación de micro-fibra en 1.0%, mientras variaban la dosificación de macro-fibra de 0 a 1.5%, obteniendo en las pruebas realizadas las tres partes de la curva esfuerzo-deformación, un proceso de micro fisuración en las probetas y resistencias a tracción pos-fisuración (σ_{pc}) de hasta 18.6 MPa con porcentaje de deformación de 0.64%.




Figura 2-5. Dimensiones recomendadas para la probeta tipo “dog-bone” (Japan Society of Civil Engineers, 2008).

Así mismo, Kay Wille, Kim, & Naaman (2011) hacen uso de su propio “dog-bone” con dimensiones en el alma de 177.8x50.8x25.4 mm. En este caso, los investigadores estudiaron la posibilidad de reducir la cantidad de fibra de acero en el UHPFRC sin que se evidencien pérdidas consideradas en las propiedades mecánicas del material. Para ello, utilizaron tres tipos de fibra de acero con dosificaciones de 1.0 a 2.5%, lo cual les permitió concluir que es posible obtener una alta resistencia a tensión pos-fisuración (hasta 15 MPa) y una alta ductilidad ($\epsilon_{pc} = 0.6\%$) con una baja fracción de volumen de fibra de acero (cerca del 2.0%).

Sin embargo, en la literatura existen numerosos estudios que siguen las recomendaciones internacionales, como las realizadas por la JSCE. Kwon, Nishiwaki, Kikuta, & Mihashi (2014) en la búsqueda de obtener un material de alta resistencia y ductilidad. Ellos desarrollaron un compuesto cementante de muy altas prestaciones reforzado con fibra de acero híbrida (UHP-HFRCC), en donde realizaron ensayos de tracción directa mediante el uso de probetas tipo “dog-bone” recomendadas por la JSCE con un espesor de 30 mm

(ver Figura 2-5). Los investigadores encontraron que al mezclar 1.0% de micro-fibra (recta) y 2.0% de macro-fibra (con extremos conformados en forma de gancho) es posible obtener resistencia a tensión hasta de 20.1 MPa y porcentaje de deformación de 0.98%, concluyendo que puede ser un material aplicado a la ingeniería estructural, debido a la alta absorción de energía observada en la investigación. Así mismo, Yu, Wang, Yu, & Xu (2017) realizaron investigaciones sobre el comportamiento pos-fisuración del HPFRCC siguiendo las recomendaciones de la JSCE. Los investigadores realizaron probetas tipo “dog bone” reforzados con fibra de polietileno ($V_f=1.96\%$) que fueron sometidos a ensayos de tracción directa. En los resultados se observó que, aunque la resistencia a compresión no llegaba a los 150 MPa, se llegaban a resistencias a tracción de hasta 17.84 MPa y un porcentaje de deformación de 11.98%, en lo que se concluye que el material es dúctil, y se podría pensar en aplicaciones sismo resistentes.

La Tabla 2-1 expone un resumen de los resultados obtenidos por varios autores para las propiedades a tracción directa del UHPFRC. Estos estudios realizados indican que el UHPFRC es capaz de alcanzar resistencias a tracción de hasta 20.1 MPa, lo cual es un incremento del 151% al ser comparado con las resistencias a tracción del UHPC (7-8 MPa). Así mismo, se observa que el porcentaje de deformación puede llegar a valores superiores a 0.3%, lo cual refleja la alta ductilidad del compuesto. Por lo tanto, al implementar el UHPFRC en el diseño y construcción de obras de ingeniería, es posible omitir o reducir la cantidad de barras de acero necesarias para soportar los esfuerzos de tensión que el concreto no puede resistir.

Tabla 2-1. Propiedades a tracción directa de diferentes UHPFRC

Nombre	Fibra 1				Fibra 2				Propiedades mecánicas			Referencia
	Tipo	d_f (mm)	l_f (mm)	V_f (%)	Tipo	d_f (mm)	l_f (mm)	V_f (%)	σ_{pc} (MPa)	ϵ_{pc} (%)	f'_c (MPa)	
RPC	Acero	0.15	12	2.40	-	-	-	-	7.8	n/a	230	(Maroliya, 2012)
M1Q	Acero	0.15	6	2.50	-	-	-	-	9.0	n/a	150	(Schmidt et al., 2001)
Ceracem	Acero	0.30	20	2.50	-	-	-	-	9.7	0.25	199	(Jungwirth & Muttoni, 2004)
Ductal	Acero	0.20	13-15	2.00	-	-	-	-	12.0	0.30	160-240	(Chanvillard & Rigaud, 2003)
HPFRCC	Acero	0.30	30	2.00	-	-	-	-	12.0	0.46	84	(Sujiravorakul, 2001)
S-UHP-FRC	Acero	0.20	13	2.50	-	-	-	-	14.2	0.24	200	(Kay Wille et al., 2011)

Nombre	Fibra 1			Fibra 2			Propiedades mecánicas			Referencia		
	Tipo	d_f (mm)	l_f (mm)	V_f (%)	Tipo	d_f (mm)	l_f (mm)	V_f (%)	σ_{pc} (MPa)		ε_{pc} (%)	f'_c (MPa)
T-UHP-FRC	Acero	0.30	30	2.00	-	-	-	-	14.9	0.61	200	(Kay Wille et al., 2011)
H-UHP-FRC	Acero	0.38	30	2.00	-	-	-	-	14.0	0.45	200	(Kay Wille et al., 2011)
U-S-2	Acero	0.20	13	2.00	-	-	-	-	15.5	0.39	200	(K. Wille et al., 2014)
U-S-2.5	Acero	0.20	13	2.50	-	-	-	-	16.5	0.47	200	(K. Wille et al., 2014)
U-S-3	Acero	0.20	13	3.00	-	-	-	-	17.8	0.45	200	(K. Wille et al., 2014)
U-H-1.5	Acero	0.38	30	1.50	-	-	-	-	12.4	0.49	200	(K. Wille et al., 2014)
U-H-2	Acero	0.38	30	2.00	-	-	-	-	14.7	0.48	200	(K. Wille et al., 2014)
U-H-3	Acero	0.38	30	3.00	-	-	-	-	19.3	0.42	200	(K. Wille et al., 2014)
U-T-1.5	Acero	0.30	18	1.50	-	-	-	-	11.1	0.38	200	(K. Wille et al., 2014)
U-T-2	Acero	0.30	18	2.00	-	-	-	-	14.2	0.44	200	(K. Wille et al., 2014)
U-T-3	Acero	0.30	18	3.00	-	-	-	-	19.6	0.41	200	(K. Wille et al., 2014)
HFC	Acero	0.70	60	1.00	Acero	0.20	13	0.50	12.0	n/a	120	(Markovic, 2006)
HFC	Acero	0.70	60	0.50	Acero	0.20	13	1.00	9-10	n/a	125	(Markovic, 2006)
LS10SS10	Acero	0.30	30	1.00	Acero	0.20	13	1.00	13.3	0.47	200	(S. H. Park et al., 2012)
HA10SS15	Acero	0.38	30	1.00	Acero	0.20	13	1.50	13.8	0.56	200	(S. H. Park et al., 2012)
HB10SS15	Acero	0.78	62	1.00	Acero	0.20	13	1.50	12.0	0.61	200	(S. H. Park et al., 2012)
T10SS15	Acero	0.30	30	1.00	Acero	0.20	13	1.50	18.6	0.64	200	(S. H. Park et al., 2012)
S1H0.5	Acero	0.16	6	1.00	Acero	0.38	30	0.50	11.9	0.073	192	(Kwon et al., 2014)
S1H1.0	Acero	0.16	6	1.00	Acero	0.38	30	1.00	12.4	0.086	181	(Kwon et al., 2014)
S1H1.5	Acero	0.16	6	1.00	Acero	0.38	30	1.50	16.1	1.06	181	(Kwon et al., 2014)
S1H2.0	Acero	0.16	6	1.00	Acero	0.38	30	2.00	20.1	0.98	176	(Kwon et al., 2014)
PVA0.5-S1.5	Acero	0.2	13	1.5	PVA	0.038	8	-	-	-	160	(Meng & Khayat, 2018)
UHP-ECC	Polietileno	0.024	12	2.06	-	-	-	-	19.2	8.7	111	(Yu et al., 2018)
UHDCC-3	Polietileno	0.025	18	1.96	-	-	-	-	17.8	8.49	117	(Yu et al., 2017)
PVA-0.6	PVA	0.038	8	0.60	-	-	-	-	-	-	132	(Srince et al., 2012)
PVA-0.8	PVA	0.038	8	0.80	-	-	-	-	-	-	128	(Srince et al., 2012)
1% PVA	PVA	0.038	8	1.00	-	-	-	-	-	-	124	(Li, 2015)

2.2 Aprendizaje automático

La inteligencia artificial puede desarrollarse desde dos puntos de vista diferentes (Brown & O'Leary, 1995). El primero puede considerarse desde la perspectiva de la inteligencia misma, en el que se establece que, la inteligencia artificial consiste en que las maquinas o computadores sean inteligentes y que actúen como podría hacerlo una persona. En este caso es importante tener en cuenta que, la inteligencia requiere del conocimiento para ser desarrollada, por lo cual, científicos, mediante la recolección de información y entrenamiento de los modelos, buscan resolver problemas complejos con la ayuda de máquinas. Por otro lado, está el segundo punto de vista, correspondiente a la investigación, en donde se considera que la inteligencia artificial es el estudio de cómo hacer que las maquinas ejecuten acciones que por el momento los humanos hacemos mejor. Ejemplos de esto último serían los drones, trenes, buses, tracto mulas o carros sin operador.

Ahora bien, el aprendizaje automático, al ser una de las ramas de la inteligencia artificial, está compuesto por algoritmos que son capaces de aprender tareas complejas, para así desarrollar modelos de predicción partiendo de datos históricos existentes (Muthukrishnan et al., 2020). Básicamente, la inteligencia artificial tiene como objetivo simular la inteligencia humana, mientras que, el aprendizaje automático se enfoca en el desarrollo de modelos que permitan la predicción de resultados mediante el uso de extensas bases de datos históricos. Por ende, la disponibilidad de una gran cantidad de datos y la posibilidad de tener acceso a potentes computadoras en la actualidad permite que el aprendizaje automático sea aplicable a cualquier campo de investigación, ya sea en la robótica, la ingeniería y hasta en los diagnósticos clínicos en la medicina (Muthukrishnan et al., 2020).

Las aplicaciones a las que puede ser sometido el aprendizaje automático son infinitas, permitiendo obtener resultados mediante el uso de varios modelos estadísticos que hacen posible realizar la clasificación o regresión de los datos disponibles. El objetivo de usar modelos de predicción o clasificación es que, mediante el análisis de los datos, el modelo desarrollado sea capaz de aprender de la experiencia. De acuerdo con Chollet & Allaire (2018) para realizar el aprendizaje automático se necesitan principalmente de tres factores:

- Datos u observaciones: Corresponden a la base de datos que servirá como experiencia para obtener la predicción o clasificación de resultados
- Ejemplos de datos de salida esperados: Para que sea posible la predicción o clasificación de datos, es necesario que el modelo parta de ejemplos en donde la variable de respuesta ya ha sido determinada mediante procesos experimentales.
- Una forma de medir si el algoritmo seleccionado hace un buen trabajo: Es necesario determinar la distancia que existe entre los datos de salida reales y los datos de salida estimados por el modelo. Esto permite determinar si es necesario realizar ajustes en el modelo o no.

Actualmente, existe una gran variedad de tipos de algoritmos en el aprendizaje automático. A pesar de que no se ha determinado una clasificación oficial de los tipos de algoritmos utilizados en el desarrollo del aprendizaje automático, comúnmente son divididos en categorías, las cuales se nombran y describen a continuación (Fumo, 2017):

2.2.1 Aprendizaje supervisado

Este algoritmo consiste en determinar un objetivo o variable dependiente, la cual quiere ser predicha mediante un conjunto de predictores determinados, los cuales corresponden a variables independientes. Mediante el uso de este conjunto de variables independientes, se crea una función que transforma las variables de entrada en variables de salida deseables. Este proceso de entrenamiento de los datos se repite hasta que se obtiene un modelo con los niveles de deseabilidad adecuados (Ray, 2017). Algunos algoritmos comunes son los algoritmos del vecino más cercano (*Nearest Neighbor Algorithm en inglés*), algoritmos Naive Bayes, árboles de decisión, regresión lineal, máquinas de vector soporte (*Support Vector Machines en inglés*), Bosques Aleatorios y redes neuronales.

2.2.2 Aprendizaje no supervisado

En este caso, no se poseen variables dependientes o de salida para ser predichas mediante modelos estadísticos. El aprendizaje no supervisado es comúnmente implementado en casos en donde no se poseen datos con etiqueta, o que indiquen características individuales en las variables de entrada. Por lo tanto, el algoritmo se

encarga de agrupar los datos de entrada en categorías y grupos, sin ser capaz de especificar las características individuales de cada uno de los integrantes del grupo (Zambrano, 2018). Algunos algoritmos no supervisados que se desarrollan actualmente son los K-medias (*k-means clustering en inglés*), redes neuronales del tipo *autoencoder*, y reglas de asociación. En el campo de la estadística, el análisis de componentes principales (PCA por sus siglas en inglés) también estaría dentro de este grupo.

2.2.3 Aprendizaje reforzado

Al implementar ese algoritmo, el software o máquina es entrenada para que sea capaz de tomar decisiones específicas. Para lograr esto, el software se expone a un entorno en el que se entrena a si mismo constantemente, ejecutando acciones de prueba y error (Ray, 2017). Posteriormente, el software es capaz de aprender de experiencias pasadas y de reconocer cual es la decisión adecuada para ser implementada en el manejo de un problema determinado. Cabe mencionar que es necesario brindar una noción de recompensa al software, con el fin de que este aprenda un nuevo comportamiento; esto es conocido como señal de reforzamiento (Fumo, 2017). Algunos algoritmos reconocidos son Q-learning, diferencia temporal (*TD por sus siglas en ingles*) y el proceso de decisión Markov.

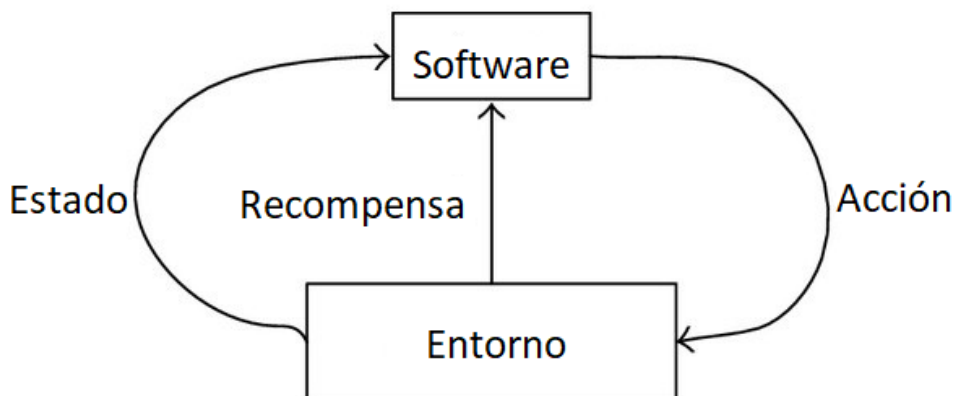


Figura 2-6. Aprendizaje reforzado en el aprendizaje automático (Fumo, 2017).

En el campo de la ingeniería estructural y de los materiales de construcción, se han implementado algoritmos de aprendizaje automático para la detección de daños estructurales, identificación de sistemas estructurales, modelación del comportamiento de un material específico, proporciones en las mezclas de concreto y comportamiento mecánico del concreto (Abellán-García, 2020c). De hecho, en los últimos años, la predicción de las propiedades mecánicas de diferentes compuestos cementantes ha sido uno de los campos de estudio más desarrollados, dado que de esta forma es posible reducir considerablemente la cantidad de ensayos necesarios para validar un nuevo compuesto o material de construcción. Por lo tanto, al desarrollar modelos de predicción mediante el uso de algoritmos de aprendizaje automático, no solo se reducen tiempos en la ejecución y aprobación de materiales de construcción, sino que, adicionalmente, se reducen los costos de producción de probetas y ensayos de laboratorio.

Ahora bien, dado que lo que se busca en la ingeniería es predecir o realizar una clasificación de algún problema o escenario presentado en el diario común, por lo general se implementan algoritmos de aprendizaje supervisado como redes neuronales o *Bosques Aleatorios*. Varios estudios se han realizado a través del tiempo para el desarrollo de algoritmos enfocados en temas relacionados con la ingeniería civil, específicamente en el desarrollo de nuevos compuestos y materiales de construcción que permitan reducir costos, impacto ambiental y tiempo de ejecución de obras a nivel mundial. Un claro ejemplo de esta evolución en los materiales de construcción es el desarrollo y mejoramiento del UHPFRC (Abellán-García, 2020a, 2020b; Abellán-García, Fernández-Gómez, Torres-Castellanos, et al., 2020).

Dado que el UHPFRC es un concreto sin agregado grueso, requiere de materiales alternos como humo de sílice, polvo de vidrio, harina de cuarzo, entre otros, que permitan obtener una alta densidad de empaquetamiento de la mezcla (Abellán-García, 2020c). Depende de la dosificación de cada uno de sus componentes para obtener los mejores resultados en temas de resistencia a compresión, baja permeabilidad y alta durabilidad. Por lo cual, la inteligencia artificial juega un papel importante en el desarrollo de este tipo de materiales, debido a que es posible implementar algoritmos que den una noción de los resultados que se podrían esperar en ensayos de resistencias a compresión, tracción, flexión, entre otros,

sin la necesidad de evaluar experimentalmente la infinidad de posibles mezclas en los componentes del UHPFRC.

Abellán-García (2020), en uno de sus estudios sobre la predicción de las propiedades mecánicas del concreto, implementa algoritmos de redes neuronales de cuatro capas en el UHPC (concreto de ultra alto desempeño sin fibras). Específicamente, desarrolla un modelo con el objetivo de predecir, a través del lenguaje R, la resistencia a compresión a los 28 días del UHPC, teniendo en cuenta un espectro de cualquier combinación que involucrara materiales como el cemento y otros materiales cementantes suplementarios como humo de sílice, ceniza volante, escoria de alto horno, polvo de vidrio, cascara de arroz, entre otros. Se recopilieron 717 datos de la literatura existente y 210 datos de ensayos propios en el laboratorio, concluyendo luego de correr y analizar el modelo que, las predicciones obtenidas sobre la resistencia a compresión a los 28 días resultan ser aproximaciones eficientes, y que el modelo desarrollado podría ser ejecutado para estimar la resistencia a compresión de una mezcla de UHPC dada en corto tiempo y sin necesidad de realizar ensayos de laboratorio.

No solo es posible determinar la resistencia a compresión del concreto mediante el uso de algoritmos de aprendizaje automático. Abellán García et al. (2020), implementan un modelo de redes neuronales de múltiples capas para la predicción de la resistencia a flexión del UHPFRC, concretamente estableciendo cuatro variables de respuesta, el esfuerzo a flexión luego de la primera fisura, su correspondiente deflexión, el esfuerzo máximo o módulo de ruptura, y su correspondiente deflexión. A través de la recolección de 615 datos existentes en la literatura y 81 datos obtenidos en ensayos experimentales, se realiza un algoritmo de redes neuronales para cada una de las variables de salida. Una vez obtenidos los resultados, Abellán García et al. (2020) concluyen que, los modelos desarrollados en la investigación brindan una buena aproximación en la predicción del comportamiento del UHPFRC bajo esfuerzos de flexión con carga a los tercios medios y en la mitad de las probetas.

No obstante, una gran variedad de algoritmos de aprendizaje automático supervisado ha sido utilizados en la predicción de las propiedades mecánicas del concreto. Kang et al. (2020), estudian la posibilidad de predecir la resistencia a compresión y flexión del concreto reforzado con fibras de acero. Para ello, se estableció una base de datos compuesta por

220 datos de resistencia a compresión y flexión, con la cual implementaron algoritmos de aprendizaje automático como la regresión lineal, la regresión Ridge, la regresión Lasso, el algoritmo del vecino más cercano (KNN), regresión mediante árbol de decisión, regresión por bosques aleatorios, regresión *gradient boosting* y máquinas de vector soporte. Kang et al. (2020) establecen que, las predicciones obtenidas con los algoritmos de regresión *gradient boosting*, regresión del árbol de decisión, y Bosques Aleatorios resultan ser las que permiten una mayor aproximación al resultado real. Asimismo, se identifica que, la relación agua cemento y el humo de sílice son las variables de entrada de mayor importancia en la predicción de la resistencia a compresión, mientras que, el contenido de humo de sílice y la fracción de volumen de la fibra de acero resultan tener mayor impacto en la resistencia a flexión, como se esperaba en un principio.

Resultados similares a los obtenidos por Kang et al. (2020) fueron validados en una investigación realizada por Nguyen et al. (2020). Nguyen et al. (2020) analizan la resistencia a compresión y tensión del concreto de alto desempeño (HPC por sus siglas en inglés), en donde se busca predecir su comportamiento implementando los algoritmos de máquinas de vector soporte, perceptrón multicapa, regresión *gradient boosting* y regresión *gradient boosting* extrema. Se recopilaron de la literatura existente 1330 datos de resistencia a compresión y 714 datos de tensión del HPC, los cuales fueron procesados en los algoritmos de aprendizaje automático supervisado. Nguyen et al. (2020) concluyen que, los mejores resultados en la predicción de la resistencia a compresión y tensión del HPC se obtienen con los algoritmos de regresión *gradient boosting* y regresión *gradient boosting* extrema. Kang et al. (2020) indica que los modelos basados en arboles de decisión y técnicas de *boosting* presentan mejores resultados debido a que clasifican de acuerdo con las características de cada una de las variables para hacer nodos y brazo de decisión, permitiéndoles gradualmente obtener mejores desempeños.

Varios estudios se han realizado para estimar las resistencias del concreto a compresión, flexión y tensión, brindando innumerables ventajas en la investigación de nuevos materiales. Sin embargo, los algoritmos de aprendizaje automático pueden ser aplicados en temas ajenos a las resistencias del concreto. Un claro ejemplo de esto es una investigación adelantada por Cai et al. (2020), en donde se hace uso del aprendizaje automático para la predicción de la concentración de cloruro superficial del concreto

expuesto a condiciones marítimas, el cual resulta ser un parámetro esencial para el diseño de durabilidad y predicción de la vida útil de las estructuras en concreto. Una base de datos con un total de 642 resultados obtenidos en la literatura existente permitió hacer uso de algoritmos como la regresión lineal, la regresión del proceso gaussiano, máquinas de vector soporte, redes neuronales perceptrón multicapa y Bosques Aleatorios. El modelo desarrollado Cai et al. (2020) consistió en la combinación de los algoritmos implementados. Con un total de 12 variables de entrada, se estableció que las predicciones son acertadas en la mayoría de los casos y que el modelo es fácilmente adaptable para la predicción de otras propiedades de durabilidad del concreto. Cabe resaltar que, Cai et al. (2020) recomiendan ampliar la base de datos, con el fin de que el entrenamiento y verificación de las predicciones tengan una mayor predicción.

2.3 Árboles de decisión y Bosques Aleatorios

Los Bosques Aleatorios son aproximaciones basadas en el método de los árboles de decisiones, en los cuales se realizan marcos de decisión basados en la teoría de la información (Nilsen et al., 2019). Los árboles de clasificación y regresión (CART, por sus siglas en inglés), fueron introducidos al campo de la estadística y aprendizaje estadístico por Breiman et al. (1984), para la construcción de árboles predictores para problemas de regresión y clasificación.

Un CART es considerado como un árbol al revés, en donde la raíz corresponde la parte superior de este. Las hojas del árbol corresponden a nodos sin descendientes y los demás nodos de árbol son nodos sin fin de donde se derivan dos nodos adicionales (Genuer & Poggi, 2020). Por lo tanto, el árbol de decisión es considerado como árbol de decisión de dos salidas por nodo intermedio. Los nodos intermedios son nombrados por una condición, por lo general por una pregunta, y las hojas del árbol (nodos finales) son nombradas por una clase o un valor de la variable de respuesta. Una vez creado un árbol de decisión es fácil implementarlo para la predicción de una respuesta. De hecho, para determinar el valor de predicción \hat{y} para una variable x determinada, solo basta con recorrer a través de un solo camino desde la raíz hasta las hojas del árbol, respondiendo una secuencia de preguntas hasta leer el valor de y establecido en la última hoja del árbol (Genuer & Poggi, 2020). La condición corresponde a que, al avanzar a través del árbol de decisión se verifica

y se continúa por el nodo de la izquierda, y si no cumple con la condición simplemente se continúa por el nodo de la derecha.

En un ejemplo presentado por Genuer & Poggi (2020), se predicen qué correos electrónicos pueden ser spam mediante la ocurrencia de caracteres “!” y “\$”, estableciendo que, valores mayores a 7.95 y 0.65% respectivamente, serán aquellos determinados como spam usando un simple árbol de decisión (ver Figura 2-7).




Figura 2-7. Árbol de decisión para spam en correos electrónicos (Genuer & Poggi, 2020).

Por lo tanto, un CART consiste en una partición binaria de un espacio de entrada X y el cual posteriormente determina una división óptima y sucesiva para la predicción deseada (Genuer & Poggi, 2020). Esto significa que para la construcción de un CART es necesario pasar por dos procesos diferentes. El primero, corresponde a la construcción del árbol máximo o completo y el segundo, corresponde al proceso de “pruning”, en el que se construye una serie de subárboles óptimos partiendo del árbol máximo, con el objetivo de evitar problemas de sobreoptimización.

Para la elaboración de árbol máximo, una parte del espacio obtenido se divide en dos partes diferentes. De esta forma, es posible asociar el árbol de decisión de dos salidas por nodo en la partición construida paso por paso (Genuer & Poggi, 2020). Los nodos del árbol corresponden a los elementos de la partición. En este orden de ideas, la raíz del árbol se

asocia al espacio global de entrada, y los dos nodos que se derivan de esta se asocian con los dos subespacios, obteniendo así la primera división, y se continua hasta formar el árbol de decisiones. La Figura 2-8 ilustra la relación entre el árbol de decisión de dos salidas por nodo y la partición asociada de las variables en el espacio.




Figura 2-8. La imagen de la izquierda muestra un árbol de clasificación para predecir una respuesta determinada para un espacio x dado. La imagen de la derecha expone la partición asociada de las variables en el espacio (C_1 , C_2 y C_5 no aparecen debido a que estas no están asociadas a las hojas del árbol) (Genuer & Poggi, 2020)

Con el fin de explicar mediante la estadística el concepto de los árboles de decisiones, se establece que el espacio de entrada corresponde a R^p , en donde p es número de variables (Genuer & Poggi, 2020). En este caso, R^p se considera como la raíz del árbol, el cual contiene todas las observaciones y datos recopilados en una base de datos. De acuerdo con Genuer & Poggi (2020), el proceso de división de los nodos de un árbol de decisión está dado por la siguiente expresión:

$$\{X^j \leq d\} \cup \{X^j > d\}, \quad (2-1)$$

Donde, $j \in \{1, \dots, p\}$ y $d \in R$. El proceso de división de los nodos de acuerdo con la ecuación 2-1 significa que, para todas las observaciones o información contenida en la base de datos, cuyo valor de la j -ésima variable es menor que d debe ir hacia el siguiente nodo de

la izquierda, y si todas las observaciones cuyo valor es mayor a d deben continuar hacia el nodo de la derecha.

En el caso de las regresiones, se busca minimizar la varianza que resulta de dividir un nodo t en dos nuevos nodos t_L y t_R , en donde la varianza del nodo t está definida como:

$$V(t) = \frac{1}{\#t} \sum_{i: x_i \in t} (y_i - \bar{y}_t)^2 \quad (2-2)$$

Donde \bar{y}_t y $\#t$ son, respectivamente, el promedio y el número de observaciones y_i pertenecientes al nodo t . Según especifica Genuer & Poggi (2020), lo que busca maximizar es:

$$V(t) - \left(\frac{\#t_L}{\#t} V(t_L) + \frac{\#t_R}{\#t} V(t_R) \right) \quad (2-3)$$

Ahora, en el segundo paso para la construcción de un algoritmo CART, el proceso de “pruning”. En este paso se procede a buscar cual es el mejor árbol intermedio entre el árbol máximo (T_{max}), el cual tiene variancia alta y baja parcialidad, y el árbol que consiste únicamente de la raíz, el cual tiene una variancia muy baja pero alta parcialidad (Genuer & Poggi, 2020). Por lo tanto, el proceso de “pruning” consiste en un modelo de selección, donde los modelos competentes son los subárboles del árbol máximo y, por ende, todos corresponden a subárboles de decisión de dos salidas por nodo de T_{max} teniendo la misma raíz que T_{max} .

El proceso o paso de “pruning” al final consiste en un algoritmo que busca asegurar la extracción de un conjunto de subárboles T_1, \dots, T_K , todos derivados de T_{max} . La idea principal es penalizar el entrenamiento del error de un subárbol dado derivado de T_{max} , como se observa en la siguiente expresión:

$$\overline{err}(T) = \frac{1}{n} \sum_{\{hoja\ t\ de\ T\}} \sum_{\{x_i, y_i\} \in t} (y_i - \bar{y}_t)^2 \quad (2-4)$$

Genuer & Poggi (2020) menciona que debido a la función lineal del número de hojas $|T|$ conlleva al siguiente criterio de penalidad:

$$crit_{\alpha}(T) = \overline{err}(T) + \alpha |T| \quad (2-5)$$

Se tiene entonces que, $\overline{err}(T)$ mide la aproximación que existe entre el modelo T con los datos recopilados y disminuye cuando el número de hojas incrementa, mientras $|T|$ cuantifica la complejidad del modelo T . Por otro lado, entre mayor es el valor del parámetro α , mayor es la penalización de los modelos complejos (Genuer & Poggi, 2020).

Una vez determinado en qué consisten los CART y como pueden ser utilizados en la predicción o clasificación de una base de datos determinada, es posible hacer uso de estos para obtener un mejor desempeño en el modelo. En lugar de buscar optimizar un solo predictor de manera inmediata como en el caso de los CART, se puede crear una gran cantidad de predictores, los cuales necesariamente no deben ser óptimos (Genuer & Poggi, 2020). Dado a que los árboles individuales son creados de manera aleatoria, un bosque de estos permitiría establecer una extensa exploración del espacio de todos los árboles de predicción posibles, lo que conlleva a un mejor desempeño.

Los Bosques Aleatorios corresponden a un conjunto de árboles de decisiones, entre mayor sea el bosque y la información que lo alimente, mejor será el resultado obtenido. De hecho, los bosques aleatorios son uno de los algoritmos de aprendizaje automático supervisado más avanzados actualmente, los cuales permiten reducir las variables de entrada menos relevantes de acuerdo a su grado de importancia (Pengcheng et al., 2020).

De acuerdo con Breiman (2001), el Bosque Aleatorio es un clasificador, el cual consiste en una colección de árboles predictores, $\{\hat{h}(\cdot, \theta_1), \dots, \hat{h}(\cdot, \theta_q)\}$, donde q corresponde a vectores aleatorios independientes e idénticamente distribuidos del conjunto de datos recopilados en la base de datos. Por lo tanto, el bosque aleatorio predictor \hat{h}_{RF} se obtiene mediante la acumulación de árboles de decisión aleatorios (ver figura 2-9. Lo anterior puede ser implementado para regresión mediante la ecuación 2-6, lo que básicamente corresponde al promedio del resultado de cada árbol de predicción individual.

$$\hat{h}_{RF}(x) = \frac{1}{q} \sum_{l=1}^q \hat{h}(x, \theta_l) \quad 2-6$$

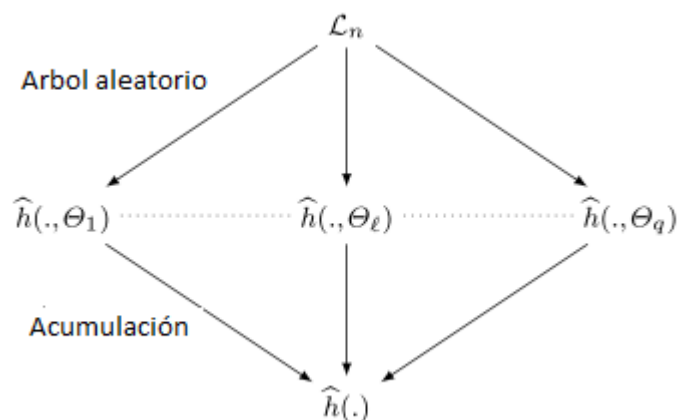


Figura 2-9. Esquema general de los bosques aleatorios (Genuer & Poggi, 2020)

Cabe mencionar que, para implementar el algoritmo de bosques aleatorios, es necesario llevar a cabo el método de muestra “*bootstrap*”, el cual básicamente abarca dos pasos. El primer paso consiste en reacomodar de manera aleatoria la base de datos original para así establecer una nueva e independiente, denominada base de datos homogeneizada. Se resalta que, la nueva base de datos contiene la misma cantidad de muestras que la base de datos original (Pengcheng et al., 2020). Aquellas muestras que no son incluidas en la nueva base de datos son denominadas como datos fuera del saco (Out-of-bag en inglés, OOB por sus siglas en inglés), y la probabilidad de que alguna de las muestras de la base de datos original no sea incluida en la nueva base de datos de forma inmediata está dada de acuerdo con la ecuación 2-7 (Pengcheng et al., 2020):

$$p = \left(1 - \frac{1}{n}\right)^n \quad 2-7$$

donde n es el número de muestras de la base de datos original. En el segundo paso, el predictor básico es entrenado de forma independiente usando la nueva base de datos y al hacer uso del método de acumulación se calcula la predicción promedio de todos los resultados de los predictores obtenidos (Pengcheng et al., 2020).

3. Objetivos

3.1 Objetivo general

Identificar una dosificación optimizada de fibra en el UHPFRC mediante la técnica de Bosques Aleatorios y optimización multiobjetivo que permita alcanzar los parámetros de ductilidad necesarios para aplicaciones de refuerzo sismo resistente ($\epsilon_{pc} \geq 0.3\%$ y $g \geq 50 \text{kJ/m}^3$) al menor costo por metro cúbico para su implementación en el mercado latinoamericano.

3.2 Objetivos específicos

1. Elaborar una base de datos mediante la consulta de la literatura existente relacionada con el comportamiento pos-fisuración del UHPFRC.
2. Crear un modelo de aprendizaje automático supervisado del tipo Bosques Aleatorios para la predicción de la capacidad de absorción de energía (g) a tracción directa del UHPFRC.
3. Crear un modelo de aprendizaje automático supervisado del tipo Bosques Aleatorios para la predicción de la deformación unitaria bajo carga máxima (ϵ_{pc}) a tracción directa del UHPFRC.
4. Determinar para ambos modelos mediante dependencias parciales el efecto de cada una de las variables de entrada al modelo en la variable respuesta (g y ϵ_{pc})
5. Efectuar una serie de dosificaciones de UHPFRC con diferentes matrices y fibras para validar, mediante ensayos de tracción directa, los resultados de los modelos desarrollados.

4. Metodología

El presente capítulo describe el procedimiento que se llevó a cabo para cumplir con los objetivos descritos en el capítulo 3 del presente proyecto. Para elaborar un modelo de aprendizaje automático supervisado es necesario la construcción de una amplia base de datos, en la que se agrupa la información existente en la literatura relacionada con el comportamiento a tracción directa de diferentes clases de concretos dúctiles, de altas prestaciones, UHPFRC, entre otros.

Es importante, luego de haber agrupado una gran cantidad de información, determinar el modelo de aprendizaje automático supervisado a implementar, definiendo las diversas variables de entrada y salida para la predicción del comportamiento a tracción directa del UHPFRC. En este caso se definen dos variables de salida: la deformación o alargamiento pos-fisuración (ϵ_{pc}) y la capacidad de absorción de energía (g) del UHPFRC. La predicción de estas variables se realiza mediante la implementación de un modelo de regresión, el cual consiste en algoritmos de aprendizaje automático supervisado del tipo Bosques Aleatorios.

Al consolidar la base de datos y al definir el algoritmo de aprendizaje automático a utilizar, se procede a entrenar el modelo y validarlo. Las variables de salida obtenidas al desarrollar el algoritmo de Bosques Aleatorios deben ser validado con los resultados reales conocidos. Además, se realizaron ensayos de tracción directa a probetas en forma de hueso de perro, siguiendo las recomendaciones establecidas por JSCE, con el objetivo de validar los modelos desarrollados y así determinar si son apropiados para su empleo en la optimización multiobjetivo. La optimización de UHPFRC tuvo como objetivo el identificar la dosificación de fibras que permita obtener una deformación pos-fisuración superior o igual

a 0.30% y una capacidad de absorción de energía superior o igual a 50kJ/m³ al menor costo posible, utilizando como matriz de UHPC una mezcla optimizada con materias primas colombianas (Abellán-García, 2020b). Cabe mencionar que, los procedimientos que se llevaron a cabo en la presente investigación se realizaron mediante el procesamiento de los datos en el lenguaje de programación R (R Core Team, 2018).

4.1 Base de datos

Para la consolidación de la base de datos para su procesamiento y el desarrollo del modelo de Bosques Aleatorios, se utilizó la base de datos confeccionada por (Abellán-García, 2020b) para su investigación doctoral. Esta base de datos incorpora los resultados de 108 artículos científicos y 7 simposios y conferencias internacionales. En ella se agrupan un total de 34 variables independientes, dos variables respuesta (ϵ_{pc} y g) y un total de 980 observaciones.

Con el objetivo de realizar una base de datos adecuada para elaborar los modelos de Bosques Aleatorios, es necesario realizar un tratamiento de datos anómalos mediante el uso de diagramas *bagplot* o diagramas de *boxplot* bidimensionales para cada una de las variables de salida. Es decir, se evalúa la normalidad de los datos en función de cada una de las variables independientes y cada una de las variables respuesta en este caso la deformación pos-fisuración (ϵ_{pc}) y la capacidad de absorción de energía (g). De esta forma se detectan y eliminan los posibles datos anómalos antes de entrenar los modelos (Everitt & Hothorn, 2015).

Posterior al tratamiento de los datos anómalos, se procede a dividir el total de los datos en dos grupos. El primero grupo corresponde a los datos de entrenamiento, en el que por lo general se toma un total de 80% de los datos, y el segundo grupo consiste en los datos de validación para evaluar los modelos de Bosques Aleatorios desarrollados.

Por otra parte, una vez eliminados los datos anómalos de la base de datos, es conveniente realizar la normalización de los datos. La normalización de los datos elimina la posibilidad de que ocurran sesgos en los modelos de aprendizaje automático supervisado (Abellán, 2020). Aunque normalmente la normalización de datos no es utilizada en el desarrollo de

algoritmos de Bosques Aleatorios, en el presente proyecto se obtuvieron mejores valores de correlación con los modelos basados en datos normalizados frente a los modelos basados en datos no normalizados. Para la normalización se hizo uso de la escala lineal en un rango de 0 a 1 para todos los casos. La ecuación 4-1 representa el caso de escala lineal (Abellán, 2020).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad 4-1$$

donde x_{norm} representa el valor de normalización de la variable x , x_{min} y x_{max} representan el mínimo y máximo valor de a variable x , respectivamente.

4.2 Elaboración de los Bosques Aleatorios

Para la elaboración de los bosques aleatorios se implementó el lenguaje de programación R (R Core Team, 2018), mediante uso de la función *randomForest* (Genuer & Poggi, 2020). Inicialmente, el modelo realiza una base de datos tipo “*Bootstrapped*”, en el que se crea una nueva base de datos del mismo tamaño de la original. Sin embargo, los datos o muestras de la nueva base de datos se toman de forma aleatoria de la base de datos original, permitiendo tomar una misma muestra más de una vez.

Una vez creada la nueva base de datos tipo “*bootstrapped*” se crean los árboles de decisión implementando cierta cantidad de variables de entrada en cada paso. Este procedimiento se repite la cantidad de veces necesaria hasta obtener la cantidad de árboles de decisión deseada, lo que hace a los Bosques Aleatorios más eficientes que el uso de árboles de decisión individuales (Breiman, 2001). La cantidad de árboles de decisión se determina de forma empírica, sin embargo, de acuerdo con Oshiro et al. (2012), luego de analizar un total de 29 bases de datos se demostró que, al usar 128 árboles de decisión, no hay cambios significativos en los resultados con respecto a los obtenidos al implementar 256, 512, 1024, 2048 y 4096 árboles de decisión. Para el presente proyecto, se implementaron un total de 500 árboles de decisión.

Al procesar cada uno de los 500 árboles de decisión se manipulan todas las variables independientes para obtener un resultado de la variable dependiente. En teoría, para cada árbol de decisión se obtiene una predicción del valor de la variable dependiente o de salida.

Sin embargo, el resultado final de la predicción corresponde al promedio de todos los valores obtenidos para cada uno de los árboles de decisión (Genuer & Poggi, 2020). Cabe mencionar que, este proceso se debe realizar para cada una de las variables dependientes que se estén evaluando, en este caso la deformación pos-fisuración y la capacidad de absorción de energía, ya que para cada una de ellas se desarrolla un modelo diferente.

Los valores de predicción obtenidos deben ser evaluados bajo diversos parámetros estadísticos, con el objetivo de determinar la efectividad de los modelos entrenados. Para el presente proyecto, se hizo uso de ocho parámetros estadísticos para establecer el nivel de precisión de los modelos de Bosques Aleatorios desarrollados. Se implementó la raíz del error cuadrático medio (RMSE), coeficiente de correlación (R^2), desviación estándar de los datos medidos (RSR), coeficiente de eficiencia de Nash-Stucliffe (E), error medio en valor absoluto (MAE), error promedio (AE) y error de sesgo medio normalizado (NMBE).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{n}} \quad 4-2$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{\sum_{i=1}^n (\hat{a}_i)^2} \quad 4-3$$

$$RSR = \sqrt{\frac{RMSE}{\frac{1}{n} \sum_{i=1}^n (a_i - \bar{a}_i)^2}} \quad 4-4$$

$$E = 1 - \frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{\sum_{i=1}^n (a_i - \bar{a}_i)^2} \quad 4-5$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |a_i - \hat{a}_i| \quad 4-6$$

$$AE = \frac{1}{n} \sum_{i=1}^n (a_i - \hat{a}_i) \quad 4-7$$

$$NMBE(\%) = \frac{\frac{1}{n} \sum_{i=1}^n (a_i - \hat{a}_i)}{\bar{a}_i} \times 100 \quad 4-8$$

donde a_i es el valor real de la variable de respuesta, \hat{a}_i es el valor estimado por el modelo de Bosques Aleatorios, \bar{a}_i es la media de los valores reales de respuesta, y n es el número de observaciones.

4.3 Programa experimental

Con el objetivo de realizar una validación de los resultados obtenidos mediante el uso de los algoritmos de Bosques Aleatorios, se elaboraron probetas en forma de hueso de perro de UHPFRC con el fin de ser sometidas a ensayos de tracción directa en los laboratorios de la Escuela Colombiana de Ingeniería Julio Garavito. Las pruebas a tracción directa del UHPFRC se llevaron a cabo con dosificaciones optimizadas y desarrolladas por el ingeniero Joaquín Abellán en su tesis doctoral, y siguiendo las recomendaciones establecidas por la JSCE.

A continuación, se describen los materiales y procedimientos que se llevaron a cabo para el desarrollo de los ensayos de tracción directa del UHPFRC.

4.3.1 Materiales

Para la elaboración de las probetas de UHPFRC se implementaron materiales comercialmente asequibles en el mercado colombiano, a excepción del polvo de vidrio que fue fabricado a partir de residuos de la industria del vidrio. Cemento tipo III ASTM, humo de sílice, arena de sílice, carbonato y polvo de vidrio de 28 μ m fueron los materiales cementantes utilizados para la elaboración de las mezclas de UHPFRC. La Tabla 4-1 expone la composición química y física del cemento y demás materiales cementantes suplementarios. Asimismo, en la Figura 4-1 se ilustra la distribución del tamaño de partícula de los materiales usados en el presente proyecto.

Tabla 4-1. Composición física y química del cemento y materiales cementantes suplementarios (Abellán, 2020)

	Cemento	Humo de Sílice	Polvo de vidrio 28 μ m	Carbonato de calcio	Arena de sílice
Gravedad específica	3.15	2.20	2.55	2.73	2.65
Pérdida de ignición %	2.58	0.60	1.00	42.21	0.20
SiO ₂ , %	19.42	92.29	72.89	0.90	99.80
Al ₂ O ₃ , %	4.00	0.59	1.67	0.10	0.14
CaO, %	64.42	3.89	9.73	55.71	0.17
MgO, %	1.52	0.26	2.08	0.70	0.01
SO ₃ , %	1.93	0.07	0.01	0.10	-

	Cemento	Humo de Sílice	Polvo de vidrio 28 μm	Carbonato de calcio	Arena de sílice
Na ₂ O, %	0.19	0.31	12.54	0.03	-
K ₂ O, %	0.39	0.54	0.76	0.00	0.05
TiO ₂ , %	0.38	0.01	0.04	0.00	-
Mn ₃ O ₄ , %	0.05	0.01	0.01	0.01	-
Fe ₂ O ₃ , %	3.61	0.24	0.81	0.05	0.04

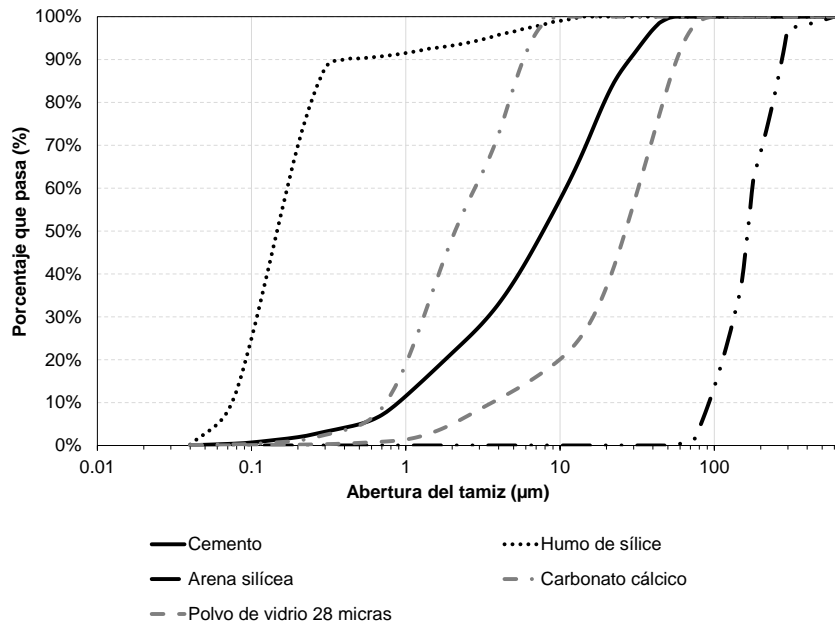


Figura 4-1. Distribución del tamaño de partícula de los materiales cementantes

Por otra parte, con fin de obtener un comportamiento dúctil en la mezcla de UHPFRC, se incorporaron fibras de acero recta de alta resistencia DRAMIX 13/0.20 (OL), y fibra de acero de resistencia normal con gancho 60/0.75 tipo malla en bolsa (MB). Las características físicas y mecánicas de las fibras de acero utilizadas en el presente proyecto se indican en la Tabla 4-2.

Tabla 4-2. Tipos de fibra incorporadas a la mezcla de UHPFRC

Variable	Descripción	
Dramix OL 13/0.20	Tipo de fibra	Fibra recta
	Longitud, l_f , mm	13
	Diámetro, d_f , mm	0.20

Variable	Descripción	
	Relación de aspecto, l_f/d_f	65
	Resistencia a tracción, MPa	2750
Malla en bolsa	Tipo de fibra	Con gancho
	Longitud, l_f , mm	60
	Diámetro, d_f , mm	0.75
	Relación de aspecto, l_f/d_f	80
	Resistencia a tracción, MPa	1225

4.3.2 Cemento

El cemento utilizado en la mezcla de UHPFRC fue suministrado por la empresa Argos, correspondiente a un cemento tipo III ASTM, y el cual ha sido implementado en las investigaciones sobre el concreto avanzado (UHPC) que adelanta esta empresa. El cemento tipo III ASTM tiene un contenido de C_3S de 65%, un tamaño de partícula promedio (d_{50}) de $8\mu\text{m}$, una gravedad específica de 3.15 y un bajo contenido de C_3A (Abellán, 2020).

4.3.3 Humo de sílice

El humo de sílice implementado en la presente investigación cumple con lo especificado en la norma ASTM C-1240, con un alto contenido de SiO_2 , cercado al 93%, una gravedad específica de 2.20 y un tamaño de partícula promedio de $0.15\mu\text{m}$ (Abellán, 2020).

4.3.4 Polvo de vidrio

El polvo de vidrio implementado en la mezcla de UHPFRC se obtiene mediante el proceso de reciclaje del vidrio, el cual pasa por un proceso de molienda a diferentes velocidades con el objetivo de obtener diferentes tamaños de partícula. Para este caso, se utiliza polvo de vidrio con un tamaño de partícula promedio de $28\mu\text{m}$.

4.3.5 Carbonato de calcio

Para el presente proyecto, se utilizó carbonato de calcio tipo Betocarb con un tamaño de partícula promedio de $2\mu\text{m}$. De acuerdo con Jaramillo (2020), este material optimiza la relación agua-cemento, el cual es ideal para la elaboración de concretos fluidos y

autocompactantes, y contribuye a la disminución de emisiones de CO₂, al contribuir a la sustitución parcial del cemento,

4.3.6 Arena de sílice

Arena de sílice con una gravedad específica de 2.65 y un tamaño máximo del grano de 600µm fue implementado en la elaboración de las mezclas de UHPFRC.

4.3.7 Superplastificante de alto rango

Con el objetivo de alcanzar una relación agua/material cementante muy baja ($w/b = 0.146$) en la mezcla de UHPFRC, se incorporó un superplastificante reductor de alto rango (HRWR, por sus siglas en inglés), el cual está basado en éteres policarboxílicos modificados.

4.3.8 Agua

El agua implementada para el desarrollo de la mezcla de UHPFRC fue extraída directamente de la red de acueducto de Bogotá.

4.3.9 Dosificaciones

Se tiene como objetivo obtener experimentalmente el comportamiento de endurecimiento por deformación de dosificaciones UHPFRC que permitan evaluar los modelos desarrollados. Para ello, se consideraron dos tipos de fibra: a) fibra metálica OL13/0.2 de Dramix; y b) fibra metálica conformada en ganchos MB de Dramix; además de tres dosificaciones de UHPC distintas, totalizando 6 dosificaciones de UHPFRC. Por cada dosificación se realizan ensayos de tracción directa a 2 probetas en forma de hueso de perro por mezcla a los 28 días de haber sido fundidas. Cabe aclarar que, el presente proyecto hace parte de una extensa investigación sobre el UHPC en el desarrollo de la tesis doctoral del ingeniero Joaquín Abellán (Abellán, 2020), y que en el presente trabajo de investigación hace uso de las dosificaciones propuestas y desarrolladas en la tesis doctoral mencionada.

Por tanto, por cada tipo de fibra, un total de tres dosificaciones de UHPFRC fueron desarrolladas en el presente proyecto, con un contenido en fracción de volumen de fibra (V_f) de 2% para todos los casos. La diferencia entre las tres dosificaciones se enmarca en la variación del contenido de humo de sílice. Con el objetivo de analizar la adherencia entre la fibra y la matriz cementante, y reducir los costos de producción se evalúan tres contenidos de humo de sílice diferentes, los cuales corresponden a dosificaciones de 50, 100 y 150 kg/m³. En la Tabla 4-3 y la Tabla 4-4 se exponen las dosificaciones de UHPFRC utilizadas en la elaboración de las probetas en forma de hueso de perro y la campaña experimental, respectivamente.

Tabla 4-3. Proporción de los materiales que componen las mezclas de UHPFRC

Mezcla	Cemento (g)	Humo de sílice (g)	Polvo de vidrio 28 μ m (g)	Carbonato de calcio (g)	Agua (g)	HRWRA (g)	Arena de sílice (g)	Fibra MB (g)	Fibra OL (g)
MB2%-SF100	690.00	115.00	370.88	240.93	236.90	24.15	961.40	186.88	-
MB2%-SF50	690.00	57.50	343.46	365.56	233.04	23.00	941.85	186.88	-
MB2%-SF150	690.00	172.50	350.43	193.33	241.88	24.15	937.25	186.88	-
OL2%-SF100	690.00	115.00	370.88	240.93	236.90	24.15	961.40	-	186.88
OL2%-SF50	690.00	57.50	343.46	365.56	233.04	23.00	941.85	-	186.88
OL2%-SF150	690.00	172.50	350.43	193.33	241.88	24.15	937.25	-	186.88

Tabla 4-4. Campaña experimental del UHPFRC

Ensayo	Probeta	b (mm)	d (mm)	L (mm)	Número de probetas por mezcla	Número total de mezclas	Número total de especímenes
Tracción directa	Hueso de perro	30	30	80	2	6	12

4.3.10 Mezcla, elaboración de probetas y curado

La mezcla de todos los materiales cementantes, arena de sílice, agua, HRWR y fibra de acero se realizó en una mezcladora tipo Hobart de 3 litros de capacidad (ver Figura 4-2). El procedimiento que se llevó a cabo para la mezcla y elaboración de las probetas de UHPFRC se realizó siguiendo el siguiente procedimiento: primero se alistaron cada una de las dosificaciones de cada material. Todos los materiales cementantes fueron mezclados en seco por aproximadamente 10 minutos. El agua y el HRWR fueron premezclados en la mezcladora tipo Hobart a velocidad 1 por aproximadamente 1.5 minutos, para

posteriormente añadir gradualmente los materiales cementantes previamente mezclados hasta obtener una mezcla fluida. Una vez se tiene la fluidez deseada se continúa mezclando a velocidad 2 por 1 minuto. Luego, se incorpora gradualmente la arena de sílice mientras se mezcla por aproximadamente 3 minutos a velocidad 2. Una vez introducida la arena de sílice a la mezcla se continúa a velocidad 2 por aproximadamente 2 minutos. Por último, se añade la fibra de acero a la mezcla y se mezcla a velocidad 2 por 2 minutos.



Figura 4-2. Mezcladora tipo Hobart de 3.0 litros de capacidad.

El ensayo de flujo estático de UHPFRC se realizó una vez finalizada a mezcla, siguiendo el método establecido en la ASTM C1437 (ASTM, 2013). Una vez se toman los valores de flujo la mezcla se introduce de nuevo a la mezcladora tipo Hobart y se mezcla por aproximadamente 1 min adicional, con el fin de no perder fluidez en la mezcla. Luego de transcurrido el tiempo, se vertió la mezcla de UHPFRC en los moldes de hueso de perro (ver Figura 4-3), para posteriormente ser vibrados en una mesa vibratoria. Cabe mencionar que, los moldes de hueso de perro se realizaron siguiendo las recomendaciones establecidas por la JSCE (Japan Society of Civil Engineers, 2008).



Figura 4-3. Moldes para la elaboración de las probetas tipo hueso de perro

Una vez se tienen las probetas tipo hueso de perro de UHPFRC en estado fresco se envuelven en filme plástico y se dejan en temperatura ambiente por 24 horas. Al transcurrir las 24 horas, las probetas se remueven de los moldes y se llevan a un cuarto de curado a 20°C durante 28 días, para realizar los ensayos de tracción directa.

4.3.11 Ensayo de tracción directa

La geometría y el método de ensayo para los ensayos de tracción directa del UHPFRC se llevó a cabo siguiendo las recomendaciones establecidas por la JSCE (Japan Society of Civil Engineers, 2008). Se implementó una probeta con una sección transversal de 30 x 30 mm y una longitud del vástago de 80mm. Los ensayos de tracción directa se realizaron en una máquina universal mediante el uso de mordazas en los extremos de las probetas, evitando la concentración de esfuerzos en los extremos del vástago, con el objetivo de que no se produjeran fallas en esta zona. Asimismo, las probetas fueron alineadas cuidadosamente para evitar posibles excentricidades al momento de aplicar la carga. Los ensayos de tracción directa se llevaron a cabo a una velocidad de 0.50 mm/min de acuerdo con la JSCE (Japan Society of Civil Engineers, 2008). Las medidas de elongación o alargamiento del vástago de las probetas se realizaron instalando dos LVDT a ambos costados, siendo el promedio de las dos lecturas el resultado final. Las lecturas de las cargas aplicadas a las probetas fueron tomadas directamente de los datos aportados por la máquina universal. En la Figura 4-4 se expone la geometría, montaje y probetas implementadas en los ensayos de tracción directa.



Figura 4-4. Probetas tipo hueso de perro y montaje en los ensayos de tracción directa

5. Análisis de resultados y discusión

5.1 Conjunto de datos

Tal como se indicó en el capítulo 4.1 del presente proyecto, la base de datos bruta (sin tratar) contaba con un total de 980 observaciones (Abellán-García, 2020b). Las dosificaciones y propiedades del UHPFRC fueron extraídos de una gran variedad de artículos y simposios internacionales sobre el UHPC/UHPFRC. Cabe resaltar que, la base de datos incluye como variables independientes fibras de refuerzo metálica y sintéticas en las dosificaciones, incorporadas se forma individual (fibra 1) o en algunas ocasiones una mezcla híbrida de los dos tipos de fibra (fibra 1 y fibra 2). Asimismo, dado que el tipo de fibra implementado en las dosificaciones de UHPFRC corresponde a una variable independiente cualitativa, es necesario transformarla en una variable dicotómica, en la que asigna un valor de 1 si la fibra se incluye en la mezcla y 0 si ocurre lo contrario. En la Tabla 5-1 se exponen las 34 variables independientes que se consideraron en la base de datos.

Cabe mencionar que, las variables independientes incluidas en la base de datos están relacionadas directamente con la deformación pos-fisuración y la capacidad de absorción de energía.

Tabla 5-1. Variables de entrada para los modelos de predicción del comportamiento a tracción del UHPFRC.

Variable	Descripción	Unidad
X1	Contenido de cemento	kg/m ³
X2	Contenido de humo de sílice	kg/m ³
X3	Materiales cementantes suplementarios	kg/m ³
X4	Contenido de harina de cuarzo	kg/m ³
X5	Contenido de agua	kg/m ³
X6	Contenido de superplastificante (HRWR)	kg/m ³
X7	Contenido de arena	kg/m ³
X9	Tamaño máximo de la arena	µm
X10	Relación en peso de agua/material cementante	N. A
X11	Fracción de volumen total de la fibra	%
X12	Factor fibra total, definido como $X_T = X_{f1} + X_{f2}$	N. A
X13	Variable dicotómica cuyo valor es 1 si la fibra 1 es una fibra de metálica recta y 0 si no lo es	N. A
X14	Variable dicotómica cuyo valor es 1 si la fibra 1 es una fibra de metálica con gancho y 0 si no lo es	N. A
X15	Variable dicotómica cuyo valor es 1 si la fibra 1 es una fibra de metálica retorcida y 0 si no lo es	N. A
X16	Variable dicotómica cuyo valor es 1 si la fibra 1 es una fibra de polietileno y 0 si no lo es	N. A
X17	Variable dicotómica cuyo valor es 1 si la fibra 1 es una fibra de polipropileno y 0 si no lo es	N. A
X18	Variable dicotómica cuyo valor es 1 si la fibra 1 es una fibra de polivinilo de alcohol (PVA) y 0 si no lo es	N. A
X19	Resistencia a tracción de la fibra 1	MPa
X20	Longitud de la fibra 1 (l_{f1})	mm
X21	Diámetro equivalente de la fibra 1 (d_{f1})	mm
X22	Fracción de volumen de la fibra 1 (V_{f1})	%

Variable	Descripción	Unidad
X23	Factor fibra 1, definido como $X_{f1} = V_{f1} \times l_{f1}/d_{f1}$	N. A
X24	Variable dicotómica cuyo valor es 1 si la fibra 2 es una fibra de metálica recta y 0 si no lo es	N. A
X25	Variable dicotómica cuyo valor es 1 si la fibra 2 es una fibra de metálica con gancho y 0 si no lo es	N. A
X26	Variable dicotómica cuyo valor es 1 si la fibra 2 es una fibra de metálica retorcida y 0 si no lo es	N. A
X27	Variable dicotómica cuyo valor es 1 si la fibra 2 es una fibra de polietileno y 0 si no lo es	N. A
X28	Variable dicotómica cuyo valor es 1 si la fibra 2 es una fibra de polipropileno y 0 si no lo es	N. A
X29	Variable dicotómica cuyo valor es 1 si la fibra 2 es una fibra de polivinilo de alcohol (PVA) y 0 si no lo es	N. A
X30	Resistencia a tracción de la fibra 2	MPa
X31	Longitud de la fibra 2 (l_{f2})	mm
X32	Diámetro equivalente de la fibra 2 (d_{f2})	mm
X33	Fracción de volumen de la fibra 2 (V_{f2})	%
X34	Factor fibra 2, definido como $X_{f2} = V_{f2} \times l_{f2}/d_{f2}$	N. A
X35	Resistencia a compresión del concreto	MPa
Y1	Alargamiento o deformación pos-fisuración (ϵ_{pc})	%
Y2	Capacidad de absorción de energía (g)	kJ/m ³

Tal y como se observa en la Tabla 5-1, las variables X1 a X35 representan las variables independientes que conforman las dosificaciones del UHPFRC, y las cuales influyen directamente en el comportamiento a tracción de este compuesto cementante, siendo Y1 y Y2 las variables dependientes o de salida. De igual manera, se evidencia la ausencia de la variable X8, debido a que esta representaba el contenido de agregado grueso en la mezcla, siendo cero para todas las dosificaciones de UHPFRC, una vez realizado el proceso de limpieza de datos anómalos. Por último, se identifica que, las variables X13 a X23 representan las características físicas y mecánicas de la fibra 1 y las variables X24 a

X34 representan las características físicas y mecánicas de la fibra 2, en donde es posible que se presenten 3 casos en cada dosificación: la primera corresponde a que se incluya un solo tipo de fibra en la mezcla, el segundo corresponde al caso en se incluyan 2 tipos de fibra en una misma dosificación, y el tercero en caso de que no se incluya ningún tipo de fibra.

5.2 Tratamiento de los datos anómalos

Antes de realizar un algoritmo de regresión para la predicción de alguna respuesta, es necesario lidiar con los datos anómalos (Seheult et al., 1989). Una herramienta efectiva para identificar la dispersión de datos y datos anómalos es el uso de los diagramas de caja bivariado (Abellán, Sánchez, & Ospina, 2020), como se observó en el capítulo 5.1 del presente proyecto. Por lo tanto, los diagramas de caja bivariado permiten determinar aquellos datos que afectarían el buen desarrollo de los modelos de Bosques Aleatorios y así eliminarlos.

Resulta inapropiado y poco técnico realizar la limpieza de los datos de forma mecánica o manual. El lenguaje de programación R, mediante la librería “mixtools”, hace posible identificar los datos anómalos de cada una de las variables X de forma independiente para cada variable de respuesta, lo que quiere decir que, permite construir un conjunto de datos para la deformación pos-fisuración y otro para la capacidad de absorción de energía (Sánchez, 2020). Por ende, se eliminan los datos que no representan el comportamiento el comportamiento a tracción directa del UHPFRC y se lleva a cabo la elaboración de los modelos de Bosques Aleatorios.

5.2.1 Análisis de la base de datos mediante diagramas *bagplot*

Para la detección de los datos anómalos, se realizaron diagramas de caja bivariado o diagrama de bolsas (*bagplot* en inglés), los cuales permiten visualizar la localización, la dispersión, la asimetría y los datos anómalos existe entre las variables de entrada y salida (Kabacoff, 2011). Para el presente caso, en el eje vertical de los diagramas se ubican las variables independientes desde $X1$ hasta $X35$, mientras que en eje horizontal se localizan las dos variables dependientes en estudio, $Y1$ y $Y2$. A continuación, se exponen los diversos diagramas de caja bivariado en dos dimensiones con el fin de establecer la

influencia de cada una de las variables independientes en la deformación pos-fisuración y la capacidad de absorción de energía.

Contenido de cemento en kg/m^3 ($X1$): Tal como se evidencia en la Figura 5-1, la mayor cantidad de los datos para esta variable se encuentran acumulados en un rango de 600 a 900 kg/m^3 , con valores de $Y1$ que varían entre 0 y 1.0% y valores de $Y2$ que varían entre 0 y 100 kJ/m^3 . Se evidencian que varios de los datos recolectados en la base de datos se encuentran por fuera la elipse exterior o mayor, los cuales representan datos anómalos y poco comunes. Se observa por ejemplo que, para un contenido de 600 kg/m^3 de $X1$ se obtiene un valor de casi 14% para $Y1$ y 1300 kJ/m^3 para $Y2$, lo que resulta poco coherente con los resultados obtenidos en otras investigaciones y ensayos de laboratorio.




Figura 5-1. Influencia de la variable $X1$ frente al comportamiento a tracción del UHPFRC

Contenido de humo de sílice en kg/m^3 ($X2$): en este caso, se evidencia en al Figura 5-2 cómo la mayor cantidad de datos se concentran en dosificaciones entre aproximadamente 40 kg/m^3 y 240 kg/m^3 de $X2$. Este rango de cantidades de la variable $X2$ se identifican valores de 0 a 1.5% de $Y1$ y de 0 a 100 kJ/m^3 $Y2$.




Figura 5-2. Influencia de la variable X2 frente al comportamiento a tracción del UHPFRC

Contenido de materiales cementantes suplementarios en kg/m^3 (X3): para esta variable de entrada se identifica en la Figura 5-3 que los valores de Y1 y Y2 aumentan con el incremento de la cantidad del contenido de X3, sin embargo, se evidencia una gran dispersión de los datos, y una gran cantidad de los de Y1 y Y2 se encuentran distribuidos en la zona donde el contenido de X3 es cero. La elipse agrupa la mayor cantidad de los datos en dosificaciones de X3 entre 0 y 600 kg/m^3 .




Figura 5-3. Influencia de la variable X3 frente al comportamiento a tracción del UHPFRC

Contenido de harina de cuarzo en kg/m^3 (X4): con respecto al contenido de X4, para un valor de 0 kg/m^3 se presentan los mayores valores de Y1 y Y2, lo que indica que es posible obtener buenos comportamientos de ductilidad sin tener que recurrir a este costoso componente. Sin embargo, varios de estos valores se encuentran por fuera de las elipses

de los diagramas, lo que indica que corresponden a datos anómalos. Cabe mencionar que, para dosificaciones de $X4$ entre 200 y 300kg/m³ se obtienen valores elevados de $Y1$ y $Y2$, los cuales llegan hasta 3% y 200kJ/m³ respectivamente (ver Figura 5-4).




Figura 5-4. Influencia de la variable $X4$ frente al comportamiento a tracción del UHPFRC

Contenido de agua en kg/m³($X5$): se observa en la Figura 5-5, que no existe una tendencia clara de la influencia del contenido de $X5$ en el comportamiento a tracción del UHPFRC, dado a que existe una gran dispersión de los datos. En algunos casos se obtienen contenidos de $X5$ aislados que dan como resultado valores de $Y1$ de hasta 13.5% y de $Y2$ de hasta 1300kJ/m³. No obstante, la mayor cantidad de los datos recolectados se agrupan en dosificaciones de $X5$ entre 100 y 400kg/m³ para $Y1$ y entre 100 y 450kg/m³ para $Y2$. Los valores más comunes de $Y1$ varían entre 0 a 1.80% y de $Y2$ varían entre 0 y 180kg/m³.




Figura 5-5. Influencia de la variable $X5$ frente al comportamiento a tracción del UHPFRC

Contenido de superplastificante en kg/m^3 ($X6$): la Figura 5-6 expone el comportamiento de las variables $Y1$ y $Y2$ frente al superplastificante. Se evidencia una gran concentración de datos hacia la zona izquierda de los diagramas. Para contenidos de $X6$ entre 0 y 40kg/m^3 aproximadamente, se obtienen altos valores de $Y1$, mientras que, contenidos entre 0 y 20kg/m^3 se identifican altos valores de $Y2$. Sin embargo, los altos valores de $Y1$ y $Y2$ corresponden a datos anómalos, ya que se encuentran por fuera de la elipse.




Figura 5-6. Influencia de la variable $X6$ frente al comportamiento a tracción del UHPFRC

Contenido de arena en kg/m^3 ($X7$): se evidencia en los diagramas de la Figura 5-7 una gran cantidad de valores atípicos o anómalos de $Y1$ y $Y2$ cuando el contenido de arena es cercano a los 500kg/m^3 . La elipse encierra la mayoría de los datos en contenidos de arena

entre 450 y 1100 kg/m³, en donde se obtienen valores de $Y1$ cercanos a 1.8% y de $Y2$ cercano a 180kJ/m³. Cabe mencionar que, para cantidades de arena iguales a cero, los valores de $Y1$ y $Y2$ son atípicos.




Figura 5-7. Influencia de la variable $X7$ frente al comportamiento a tracción del UHPFRC

Tamaño máximo del agregado en micrómetros ($X9$): para valores de $X9$ cercanos a cero se observa una gran concentración de datos, como también altos valores de $Y1$ y $Y2$. Las elipses en los diagramas encierran valores de $Y1$ de hasta 1.8%, y valores de $Y2$ cercanos a 200kJ/m³ (ver Figura 5-8). Esto indica que al implementar en las mezclas de UHPFRC con agregado con un tamaño máximo de hasta 1000 μ m, es posible obtener resultados de $Y1$ y $Y2$ satisfactorios. Esto se debe a que la efectividad de la fibra es inversamente proporcional al tamaño máximo del agregado, debido a que al disminuir el tamaño del agregado la mezcla es más homogénea, la porosidad disminuye, se reduce el espesor de los ITZ y de los cristales de portlandita y la fibra mejora, por tanto, su adherencia con la pasta (Abellán-García et al., n.d.; Shi et al., 2015b, 2015a).




Figura 5-8. Influencia de la variable $X9$ frente al comportamiento a tracción del UHPFRC

Relación en peso de agua/material cementante ($X10$): una gran concentración de valores se identifica para valores de $X10$ entre 0.1 y 0.4, sin embargo, en el caso de $Y1$ se observan varios valores de gran magnitud considerados como atípicos. Las elipses encierran como datos típicos, valores de $Y1$ entre 0 y 2%, y valores de $Y2$ entre 0 y 180kJ/m³.




Figura 5-9. Influencia de la variable $X10$ frente al comportamiento a tracción del UHPFRC

Fracción de volumen total de la fibra ($X11$): en la Figura 5-10 se identifica que para un valor de $X11$ igual a 2%, se obtienen los mayores valores de $Y1$ y $Y2$, llegando a resultados de hasta 14% y 1300kJ/m³ respectivamente. Así mismo, se observa que para valores de $X11$ de 0 y mayores a 3%, los datos se encuentran fuera de la elipse, considerándose atípicos o anormales.




Figura 5-10. Influencia de la variable $X11$ frente al comportamiento a tracción del UHPFRC

Factor fibra total ($X12$): para esta variable independiente se observa una gran concentración de datos para el rango de valores entre 0 y 5 (ver Figura 5-11). Se evidencia de igual forma que a medida que los valores de $X12$ aumentan, también incrementan los valores de $Y1$ y $Y2$, sin embargo, la mayoría de estos datos corresponden a valores atípicos.




Figura 5-11. Influencia de la variable $X12$ frente al comportamiento a tracción del UHPFRC

Hasta el momento se realizó un análisis de la influencia de cada uno de los componentes que conforman la mezcla de UHPFRC. Se identifica que, en su gran mayoría, valores de las variables dependientes $Y1$ y $Y2$ superiores a 2% y 180kJ/m³ se encuentran por fuera

de las elipses de los diagramas de caja bivariado. Asimismo, las tendencias a obtener altos valores de $Y1$ y $Y2$ se identifican cuando se implementan valores bajos de la variable $X9$ y valores de 2% para la variable $X11$. Lo anterior indica que dosificaciones de fibra cercana al 2% resulta un apropiado valor para obtener un comportamiento a tracción directa indicado. Por lo tanto, es posible indicar que, valores superiores a 0.30% de $Y1$ y 50kJ/m^3 de $Y2$ se pueden alcanzar si se implementan tamaños de agregado de hasta $1000\mu\text{m}$ o menores y fracciones de volumen total de fibra del 2%.

Es importante analizar la influencia que representa la resistencia a compresión ($X35$) del UHPFRC con respecto al comportamiento a tracción directa. En la Figura 5-12, se observa como existe una gran concentración de datos hacia la parte superior izquierda de los diagramas de caja bivariado, sin embargo, se observan altos valores de $Y1$ y $Y2$ cuando la resistencia a compresión es inferior a los 150MPa . De hecho, se ha observado en varias publicaciones del simposio internacional de compuestos cementantes de endurecimiento por deformación (SHCC, por sus siglas en inglés) que, a pesar de que las mezclas tengan una baja resistencia compresión, se obtienen altos valores de deformación pos-fisuración (11%) y capacidad de absorción de energía se obtienen (1500kJ/m^3). Un claro ejemplo de esta condición se observa en la investigación realizada por Yu et al. (2018) realiza ensayos de tracción directa a probetas tipo hueso de perro siguiendo las recomendaciones de la JSCE y ensayos de compresión a cubos de SHCC. En la investigación se obtienen resistencias a compresión menores a 150MPa , no obstante, logran obtener un material dúctil con deformaciones pos-fisuración de hasta 8.7% y capacidades de disipación de energía de 1500kJ/m^3 .




Figura 5-12. Influencia de la variable $X35$ frente al comportamiento a tracción del UHPFRC

Una vez detectados los datos anómalos, aquellos que se ubican por fuera de la elipse, se procedió a su eliminación, quedando la base de datos definitiva para el entrenamiento de los modelos regresivos con 502 observaciones. Como criterio de la investigación, y aunque los análisis se realizaron por separado, las observaciones anómalas en una de las variables respuesta se eliminan incluso de la base de datos de entrenamiento de la otra, de forma que la base de datos resultante puede ser utilizada indistintamente para ambos modelos.

Al realizar el tratamiento de los datos anómalos se reduce el rango de respuesta de las variables dependientes. Rangos de valores que anteriormente iban de 0 hasta 14% de la variable $Y1$ pasan a un rango de 0 a 1.0%, lo que resulta una condición común en varios de los resultados obtenidos y consultados en la literatura existente para los UHPFRC. Una condición similar ocurre con la variable $Y2$, en donde se identificaban rangos de valores entre 0 y hasta 1300kJ/m³, y una vez realizado el tratamiento de los datos, se logra reducir este rango de 0 a aproximadamente 90kJ/m³. En este sentido se determina que, el tratamiento de los datos anómalos permite que el modelo de Bosques Aleatorios se desarrolle con un grupo de datos típicos para cada variable de respuesta, y observados de investigaciones científicas que se han realizado en el estudio del comportamiento a tracción del UHPFRC.

La Figura 5-13 expone el comportamiento de varias de las variables de entrada frente a la deformación pos-fisuración luego de realizarse el tratamiento de los datos anómalos. Se observa que, en la mayoría de las variables dependientes los datos se encuentran por dentro de la elipse de los diagramas de caja bivariado, sin embargo, en algunos casos aún se alcanzan a identificar datos por fuera de la elipse, como en el caso de las variables $X3$, $X7$, $X10$ y $X12$. Al observar el comportamiento de la variable $X2$, se identifica que varios de los datos se encuentran fuera de la elipse, debido a que se encuentra un mejor comportamiento de la variable $Y1$ cuando las dosificaciones de $X2$ son cercanas a los 200kg/m³. Sin embargo, hay que tener en cuenta que en los últimos años se han desarrollado diferentes investigaciones para reducir el contenido de humo de sílice en el UHPC/UHPFRC (Abellán-García, Núñez-López, et al., 2020; Abellán, Fernández, Torres, et al., 2020), por lo que se encuentran dosificaciones con contenidos inferiores a los 200 kg/m³, y por tanto sería absurdo eliminar estas dosificaciones de la base de datos. Cabe

mencionar que, es posible continuar con el tratamiento de los datos y eliminar aún más datos anómalos, no obstante, resulta ser peligroso, ya que esto implica menos datos a ser incluidos en el momento de realizar los modelos de Bosques Aleatorios.

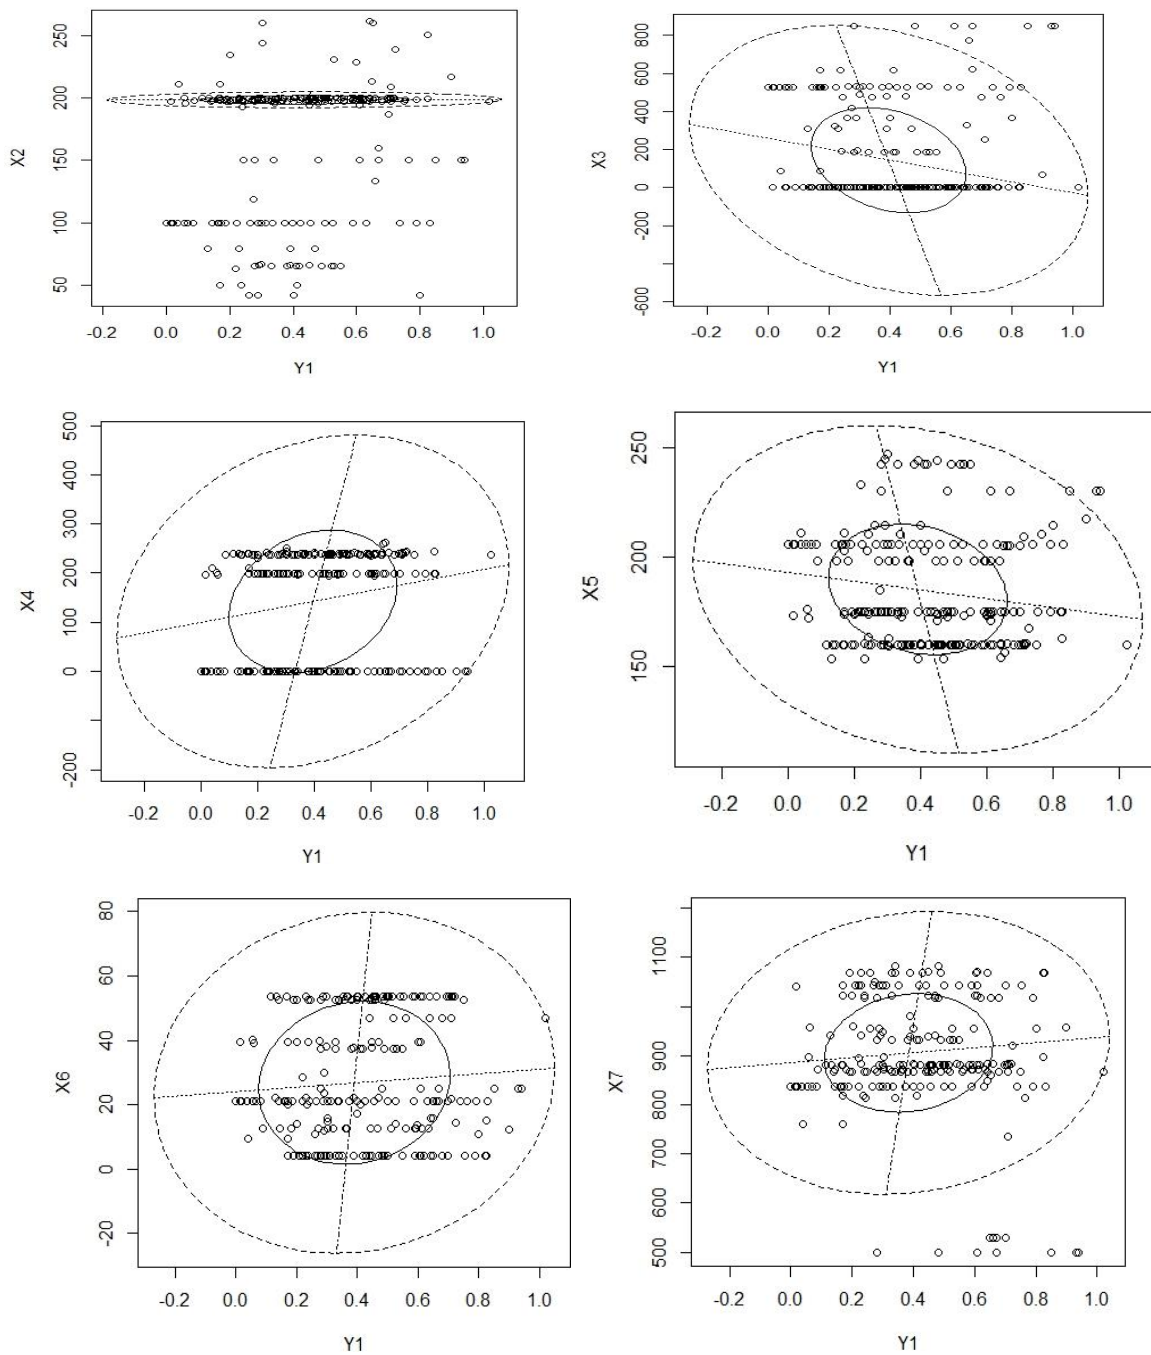


Figura 5-13. Comportamiento de las variables de entrada frente a Y1 posterior al tratamiento de los datos anómalos (Parte 1)

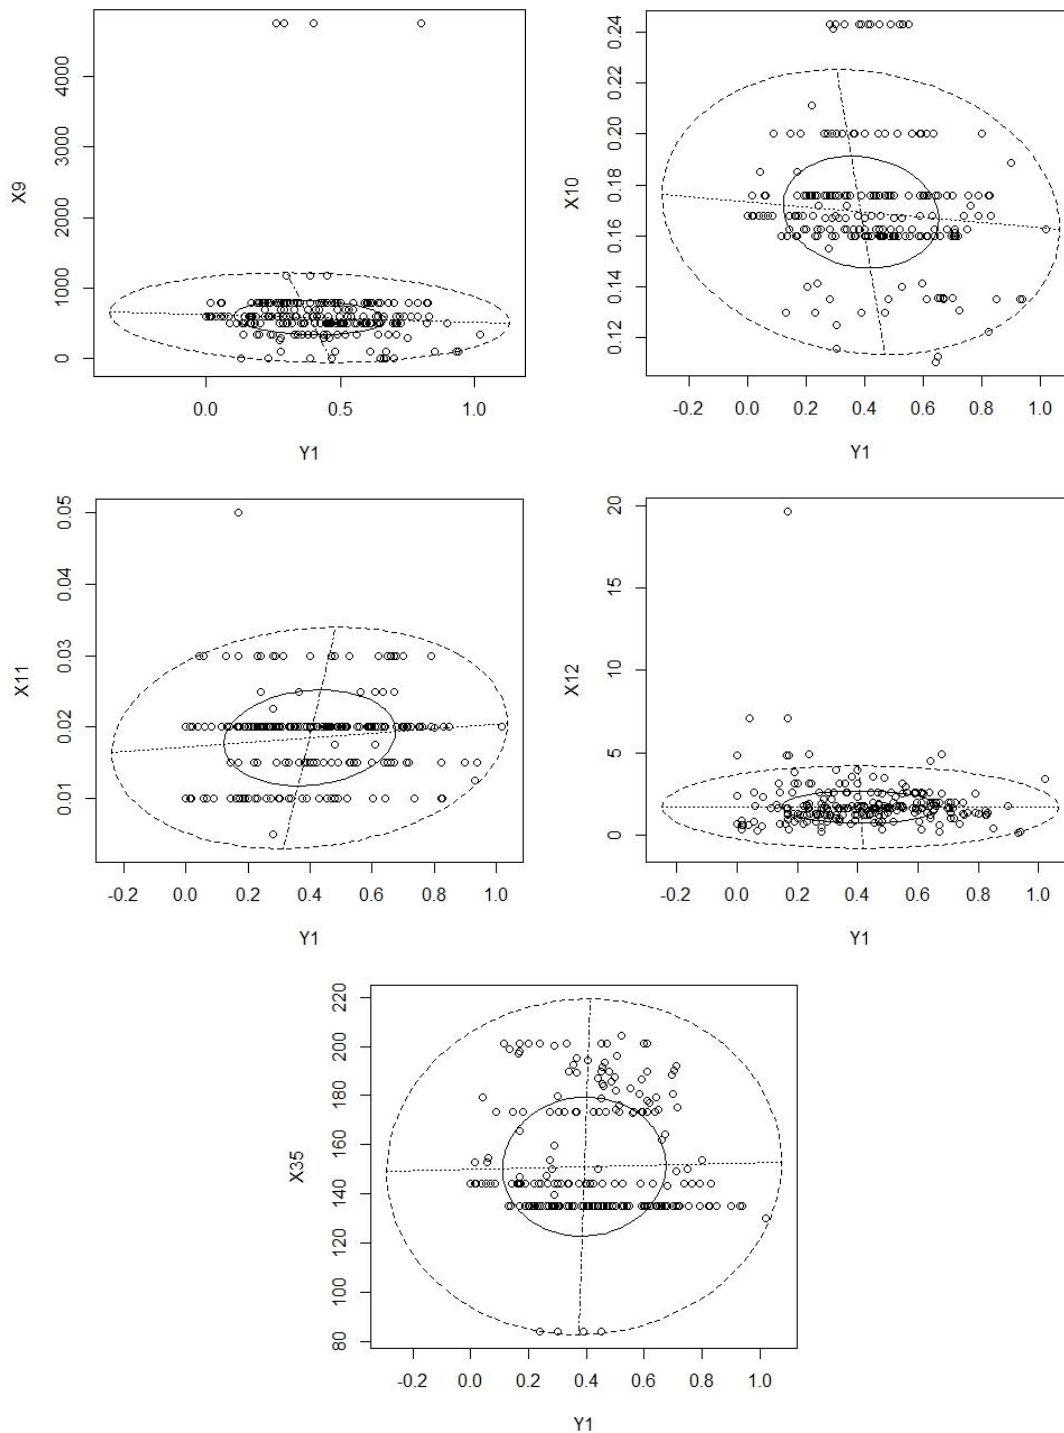


Figura 5-13. Comportamiento de las variables de entrada frente a Y1 posterior al tratamiento de los datos anómalos (parte 2)

Por otro lado, en la Figura 5-14 ilustra el comportamiento de varias de las variables de entrada frente a la deformación pos-fisuración luego de realizarse el tratamiento de los datos anómalos. Se evidencia en los diagramas que, las variables con la mayor cantidad de datos por fuera de las elipses son $X1$ y $X2$, presentándose una tendencia similar a la observada en el paso de la variable $Y1$. Para el restante de las variables, se identifica un buen comportamiento y tratamiento de los datos, en donde se obtienen valores de $Y2$ entre 0 y hasta 90kJ/m^3 .

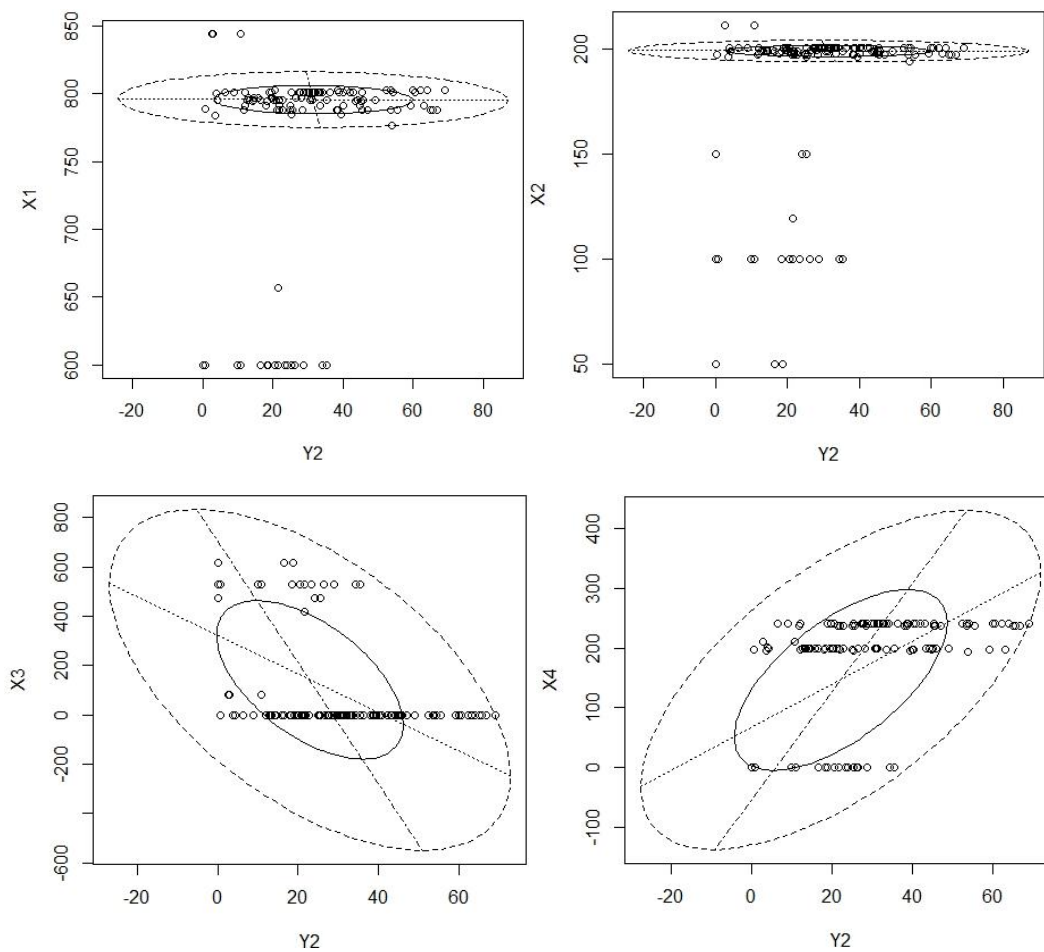


Figura 5-14. Comportamiento de las variables de entrada frente a $Y2$ posterior al tratamiento de los datos anómalos (Parte 1)

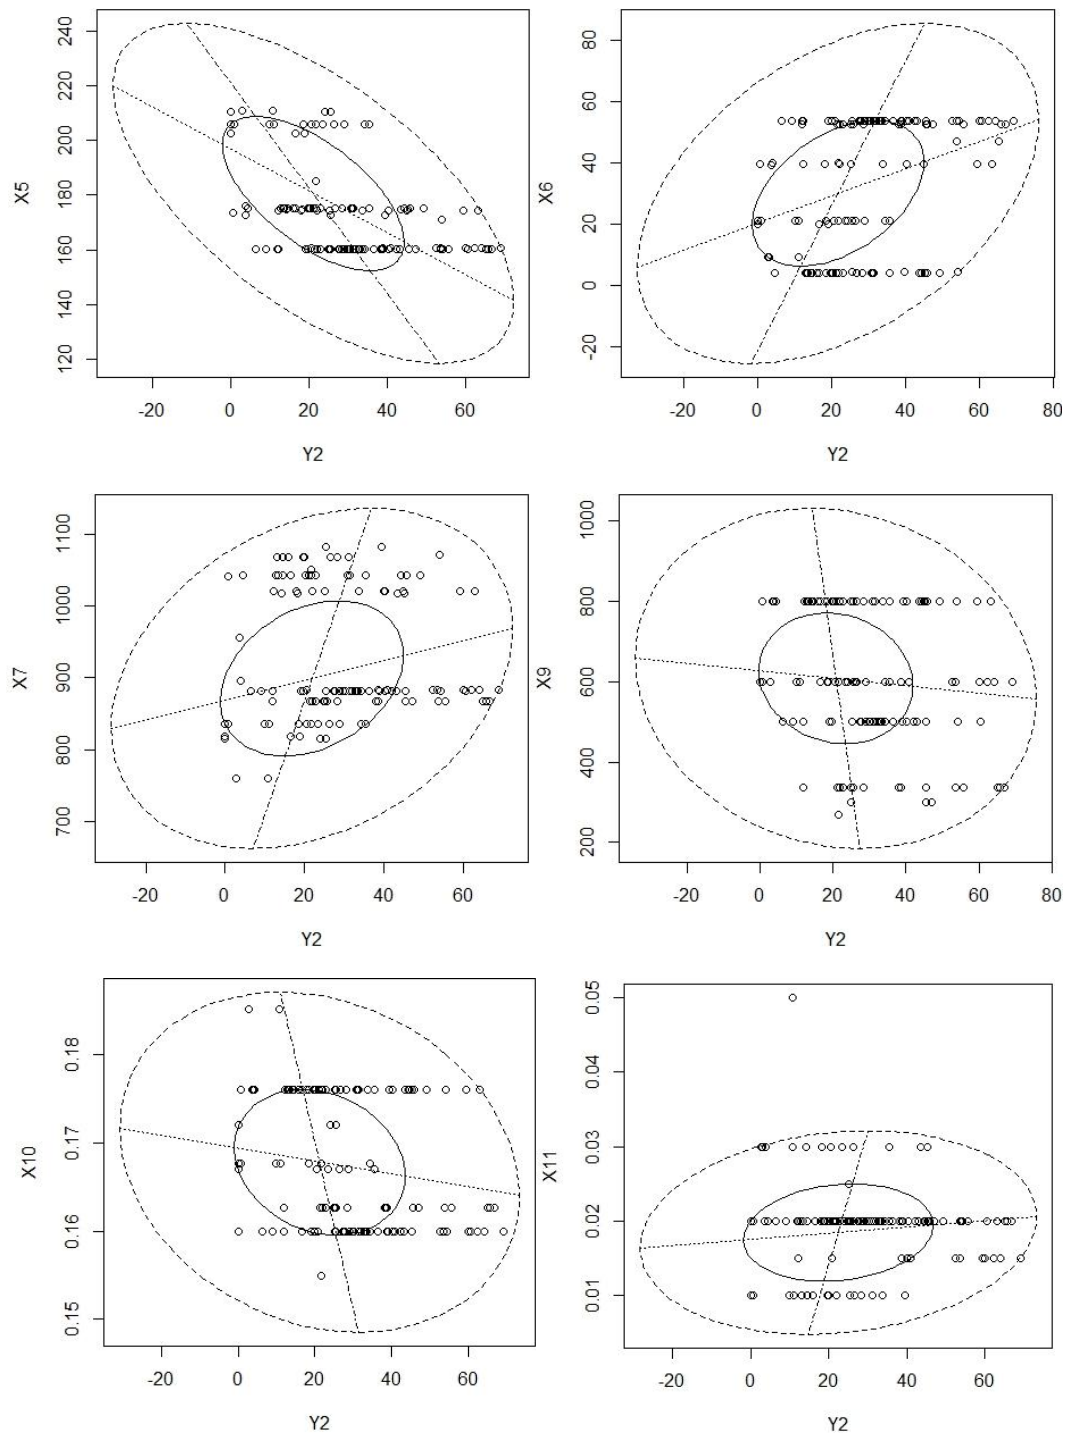


Figura 5-14. Comportamiento de las variables de entrada frente a Y2 posterior al tratamiento de los datos anómalos (Parte 2)




Figura 5-14. Comportamiento de las variables de entrada frente a Y2 posterior al tratamiento de los datos anómalos (Parte 3).

5.3 Resultados experimentales del comportamiento a tracción directa del UHPFRC

El comportamiento de 6 dosificaciones diferentes de UHPFRC se analizaron mediante los ensayos de tracción directa de 2 probetas tipo hueso de perro por dosificación (ver Tabla 4-3). La totalidad de las probetas de UHPFRC incluyen un único tipo de fibra metálica (MB y OL) en una dosificación fija de 2%. La Tabla 5-2 enlista los resultados del comportamiento a tracción directa del UHPFRC, haciendo énfasis en la deformación pos-fisuración (ϵ_{pc}) y la capacidad de absorción de energía (g), la cual corresponde al área bajo a curva de esfuerzo-deformación hasta σ_{pc} y su respectivo ϵ_{pc} . Los valores presentados en la Tabla 5-2 corresponden a todos los resultados experimentales obtenidos, donde el subíndice 1 pertenece a la primera probeta y el subíndice 2 a la segunda probeta.

Tabla 5-2. Valores promedio del comportamiento a tracción directa del UHPFRC

Mezcla	σ_{cc1} (Mpa)	σ_{cc2} (Mpa)	σ_{pc1} (Mpa)	σ_{pc2} (Mpa)	ϵ_{pc1} (%)	ϵ_{pc2} (%)	ϵ_{pcp} (%)	g_1 (kJ/m ³)	g_2 (kJ/m ³)	g_p (kJ/m ³)
MB2%-SF50	9.13	7.05	9.54	7.10	0.30	0.17	0.24	36.11	18.97	27.54
MB2%-SF100	7.59	7.76	8.15	8.77	0.42	0.25	0.33	54.37	25.79	40.08
MB2%-SF150	7.40	7.63	7.64	7.97	0.33	0.35	0.34	32.76	47.44	40.10
OL2%-SF50	9.45	10.72	9.53	10.77	0.14	0.20	0.17	37.40	44.13	40.76
OL2%-SF100	11.22	10.89	11.40	11.19	0.30	0.23	0.26	61.07	33.26	47.17
OL2%-SF150	9.89	10.30	9.96	10.41	0.29	0.20	0.24	54.27	38.48	46.38

Por otro lado, en la Figura 5-15 ilustra las gráficas de esfuerzo-deformación de las 12 probetas de UHPFRC evaluadas en el presente proyecto. Se observa que en cada una de ellas se presentó un comportamiento de pos-fisuración, obteniendo valores de deformación pos-fisuración y capacidad de absorción de energía, lo cual se atribuye a la cantidad de fibra de acero que se incluyó en las mezclas de UHPFRC.

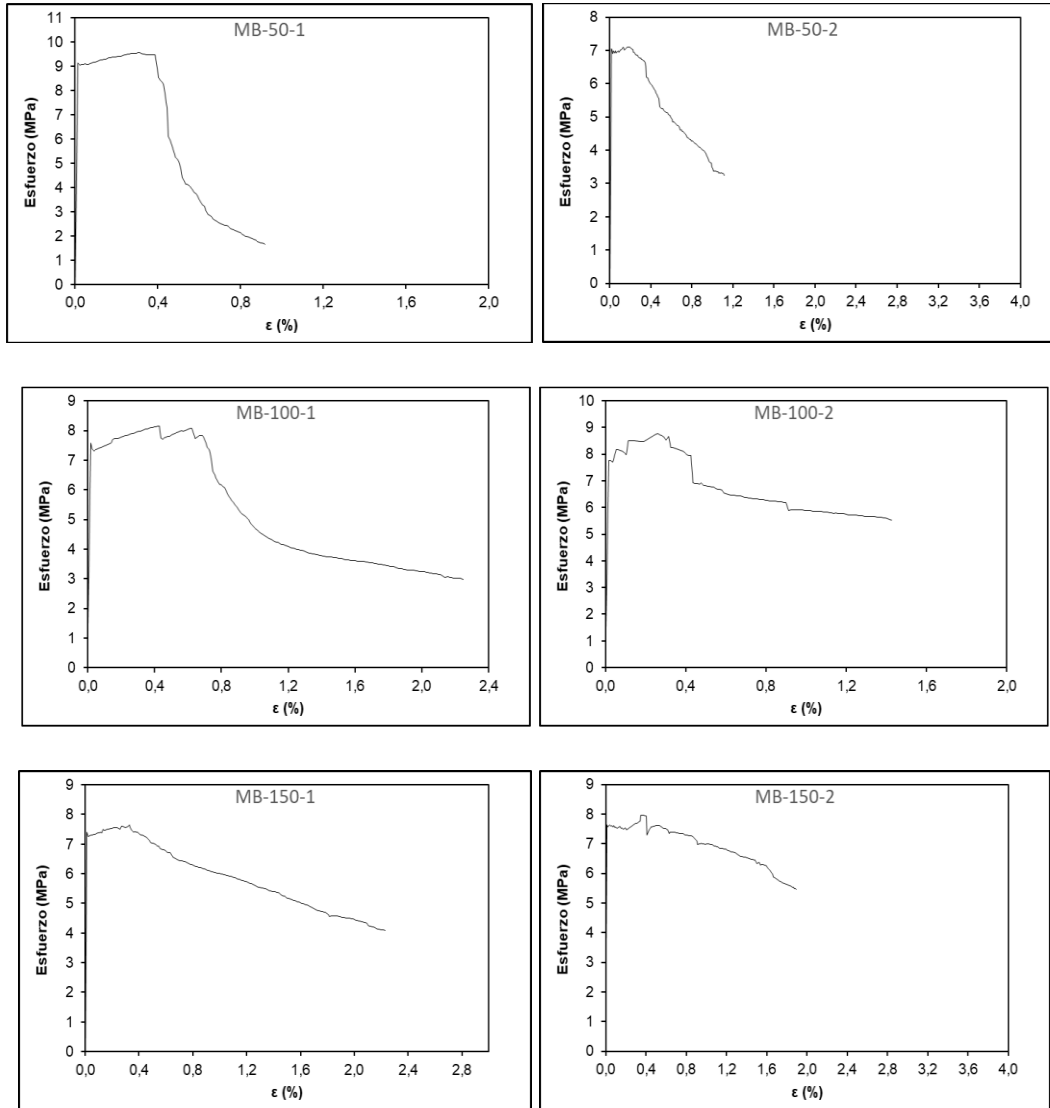


Figura 5-15. Comportamiento a tracción directa de endurecimiento por deformación del UHPFRC (parte 1)

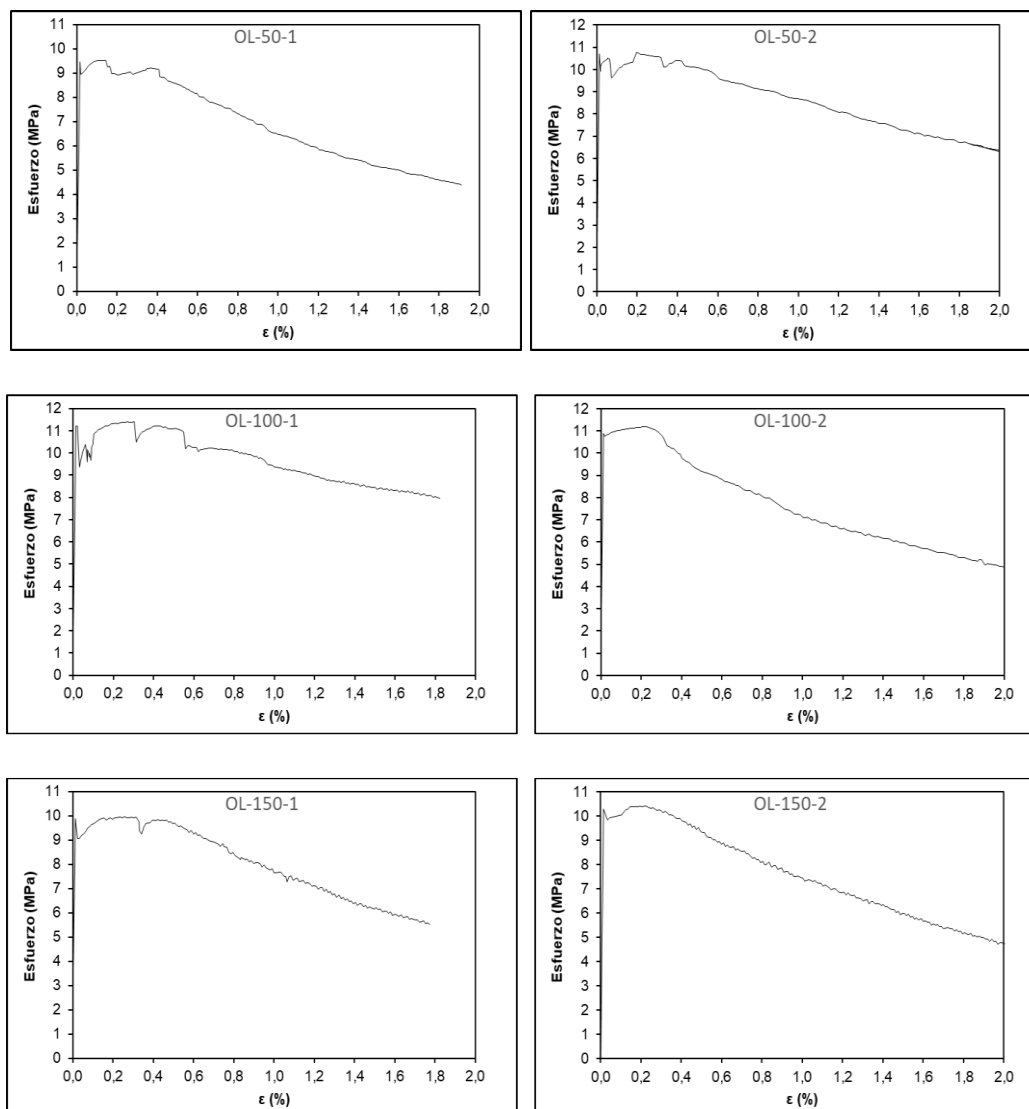


Figura 5-15. Comportamiento a tracción directa de endurecimiento por deformación del UHPFRC (parte 2)

Como es posible observar en la Tabla 5-2, la capacidad de absorción de energía promedio (g_p) aunque no alcanza a adquirir valores de 50kJ/m^3 se encuentran cercanos en el caso de la dosificación OL2%-SF100. Esto puede atribuirse a los bajos contenidos de cemento y humo de sílice que se implementaron en las mezclas de UHPFRC, siendo hasta un 50% inferior si se compara con las dosificaciones utilizadas en la mayoría de la literatura consultada (Abellán, 2020). En este sentido, la dosificación OL2%-SF100 en la que se implementó fibra metálica recta presenta la mejor capacidad de absorción de energía promedio con una dosificación de 100kg/m^3 de humo de sílice, con un valor de 47.17kJ/m^3 , tan solo 5.7% por debajo del valor buscado (50kJ/m^3).

Por otra parte, al comparar los resultados de la Tabla 2-1 y la Tabla 5-2, se evidencia que los resultados obtenidos en el presente proyecto con respecto a la deformación pos-fisuración promedio (ϵ_{pcp}) son menores en su mayoría con respecto a los consultados en la literatura. Aunque varios de los resultados de Tabla 5-2 no llegan al valor deseado de 0.30% de ϵ_{pc} , se encuentran tan solo un 13% por debajo. Asimismo, se observa que la fibra que más aportó en los valores de ϵ_{pc} fue la fibra con ganchos en los extremos, la cual, por su geometría, ayuda a obtener mayores deformaciones pos-fisuración cuando se presentan macro fisuras en las probetas de UHPFRC. De igual forma, se evidenció que en las probetas en las que se incluía fibra metálica con ganchos en los extremos se presentaban procesos de micro fisuración en el alma (ver Figura 5-16).



Figura 5-16. Microfisuración en probetas de UHPFRC con fibra metálica con gancho en los extremos (MB)

Los resultados experimentales obtenidos de los ensayos a tracción directa del UHPFRC desarrollado en el presente proyecto muestran que únicamente 2 de las dosificaciones (MB2%-SF100 y MB2%-SF150) estudiadas llegan a valores de deformación pos-fisuración de 0.3%. De igual forma, las dosificaciones desarrolladas, aunque llegan a valores cercanos a 50kJ/m^3 , ninguna alcanza al valor deseable. Sin embargo, se observa que, los mayores valores de g se obtienen cuando se hace uso de fibra recta tipo OL, mientras que, la mayor deformación pos-fisuración se presenta en los casos en los que se incorporaron fibra metálica con ganchos en los extremos tipo MB. De acuerdo con (Abellán, 2020), esto demuestra la sinergia que existe entre los tipos de fibra, y que la adecuada combinación entre fibras puede mejorar el comportamiento a tracción directa del UHPFRC.

5.4 Algoritmo de aprendizaje automático supervisado tipo Bosques Aleatorios

Los algoritmos de Bosques Aleatorios implementados en el presente proyecto se llevaron a cabo mediante el uso del lenguaje de programación R, específicamente con ayuda de la librería “*randomForest*”. Para el desarrollo de los Bosques aleatorios se utilizó el 80% de los datos tras el tratamiento de los datos anómalos como se observó en el capítulo 5.2. Asimismo, se realizó la normalización a escala lineal de todas las variables de entrada de acuerdo con la ecuación 4-1, en donde se obtiene un valor mínimo de 0 y un valor máximo de 1 para todas las variables. Aunque para los modelos de Bosques Aleatorios no es necesario realizar la normalización de las variables de entrada, se evidenciaron mejores resultados de predicción al implementar la normalización a escala lineal.

Para la elaboración de los Bosques Aleatorios se implementaron un total de 500 árboles de decisión. Cada uno de los árboles de decisión estima un resultado de predicción del comportamiento a tracción directa del UHPFRC, el cual luego es promediado para obtener un único valor de predicción de $Y1$ y $Y2$. Como se mencionó anteriormente, para el ajuste de los modelos se utilizaron el 80% de los datos de las observaciones disponibles y el 20% para la validación de los modelos predictivos.

5.4.1 Modelo predictivo para la deformación pos-fisuración ($Y1$) del UHPFRC

La Figura 5-17 representa el gráfico mostrando el efecto del número de árboles de decisión del modelo de Bosques Aleatorios versus el error (RMSE) entre los datos reales de la variable respuesta y las estimaciones del modelo. Cabe destacar que el gráfico presenta el error medido entre los valores normalizados para los datos reales y predichos por el modelo.




Figura 5-17. Gráfico de error (RMSE) en variables respuestas normalizadas versus número de árboles en el modelo.

Como se pueda apreciar en la Figura 5-17, se alcanza una asíntota a partir de los 323 árboles de decisión, siendo que a partir de ahí el RMSE no mejora significativamente. Por lo tanto, podemos afirmar que el modelo con 500 árboles es aceptable.

EL modelo de Bosque Aleatorios desarrollado para predecir la deformación unitaria bajo carga máxima del UHPFRC a tracción directa está conformado por 500 árboles. La Figura 5-18 muestra el primero de los 500 árboles desarrollados. El resultado presentado por el modelo de Bosques Aleatorios será el correspondiente a la media de los obtenidos por los 500 árboles.




Figura 5-18.Primero de los 500 árboles de decisión del modelo de Bosques Aleatorios para predecir Y_1 (ϵ_{pc})

En la Tabla 5-3 se presentan las predicciones obtenidas mediante el desarrollo de los Bosques Aleatorios para las dosificaciones de UHPFRC indicadas en la Tabla 4-3. Se identifica que, los valores de predicción del modelo resultan ser similares con respecto a los obtenidos experimentalmente para las dosificaciones de UHPFRC ensayadas en el presente proyecto. En general las predicciones obtenidas por el modelo de Bosques Aleatorios arrojan resultados de ϵ_{pc} inferiores a los obtenidos experimentalmente, con la excepción de la dosificación MB2%-SF50, la cual es un 24% superior.

Tabla 5-3. Valores experimentales y valores obtenidos de los modelos de Bosques Aleatorios para Y_1 .

Mezcla	Valor real de Y_1 (%)	Predicción de Y_1 (%)
MB2%-SF50	0.24	0.29
MB2%-SF100	0.33	0.29
MB2%-SF150	0.34	0.31
OL2%-SF50	0.17	0.17
OL2%-SF100	0.26	0.24
OL2%-SF150	0.24	0.24

De igual manera, los parámetros de evaluación del modelo para la predicción de la deformación pos-fisuración (ϵ_{pc}) se presentan en la Tabla 5-4 y la Figura 5-19. Se identifica

que, existe una gran correlación entre los valores de ε_{pc} predichos en el modelo de Bosques Aleatorios y los valores reales, con valores de RMSE, R^2 , RSR, E y MAE de 0.1254, 0.7279, 0.5298, 0.7193 y 0.0969 respectivamente, en los datos de validación. Es destacable además que el valor de R^2 sobre los datos experimentales es del 0.715. Sin embargo, como se observó en la Tabla 5-3, en la mayoría de las ocasiones se obtienen valores de predicción menores a los reales, lo cual se valida en la Figura 5-19, donde una gran cantidad de datos se encuentran por debajo de la línea de 45°.

Tabla 5-4. Medidas de desempeño del modelo de $Y1$

Conjunto de datos	RMSE	R^2	RSR	E	MAE	AE	NMBE
Entrenamiento	0.0912	0.9168	0.4121	0.8302	0.0644	0.0001	0.031%
Validación	0.1254	0.7279	0.5298	0.7193	0.0969	-0.0079	-2.079%
Experimental	0.0319	0.7148	0.5441	0.7040	0.0253	0.0061	2.300%

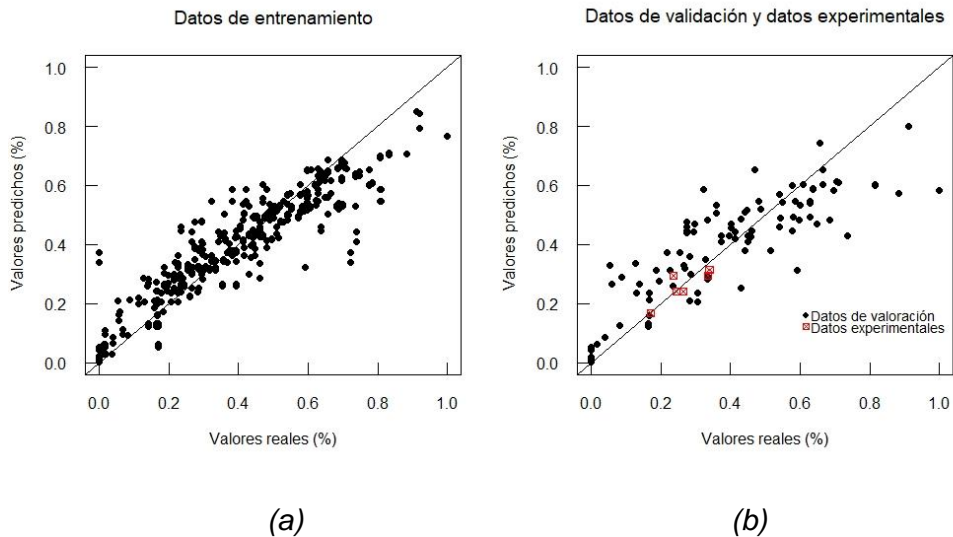


Figura 5-19. Diagrama de regresión para el modelo de $Y1$: (a) datos de entrenamiento; (b) datos experimentales y de validación

Una vez desarrollado y validado el modelo de Bosques Aleatorios, lo podemos utilizar para el análisis del efecto de las variables independientes sobre la variable respuesta (ε_{pc}) mediante el análisis de dependencias parciales (Genuer & Poggi, 2020). En la Figura 5-20

se ilustra la Dependencia parcial para cada una de las variables independientes frente a la variable $Y1$ una vez se realizan los modelos de Bosques Aleatorios en R. Mediante las gráficas obtenidas en la Figura 5-20 es posible realizar un análisis de sensibilidad de las variables independientes con respecto a la variable de salida y así determinar cuál es la variable que mayor importancia o mayor influencia tiene en el momento de predecir valores de $Y1$ con algoritmos de Bosques Aleatorios (Genuer & Poggi (2020).

Es posible evidenciar que, los gráficos de dependencia parcial de $Y1$ frente a las variables independientes concuerdan con observaciones realizadas en la literatura existente. El humo de sílice ($X2$) es un componente de menor tamaño ($d_{50} \approx 0.15 \mu\text{m}$) que, al aumentar su dosificación en el UHPFRC incrementa la densidad de empaquetamiento de la mezcla (Wang et al., 2015). Al incrementarse la densidad de empaquetamiento, los puntos de contacto con la fibra aumentan, mejorando la adherencia entre la matriz cementante y la fibra de refuerzo, permitiendo obtener valores aceptables de deformación pos-fisuración, tal y como se observa en la gráfica de dependencia parcial de $X2$. Esto ha sido reportado por diferentes investigadores en trabajos experimentales (Abellán-García et al., n.d.; K Wille et al., 2011; Kay Wille et al., 2011).

Es importante en este punto identificar cómo se comporta el contenido de fibra en la predicción de los valores de $Y1$. Se observa en la Figura 5-20 que, como se espera, al aumentar la dosificación de fibra de refuerzo en la matriz cementante, se obtienen mejores resultados de predicción de $Y1$. Sin embargo, es posible identificar que, al sobrepasar cierta dosificación de fibra de refuerzo, su contribución a mejorar la deformación pos-fisuración del UHPFRC se mantiene constante, indicando que existe una dosificación máxima, y de sobrepasarla, no se contribuye al mejoramiento de los resultados de deformación pos-fisuración.

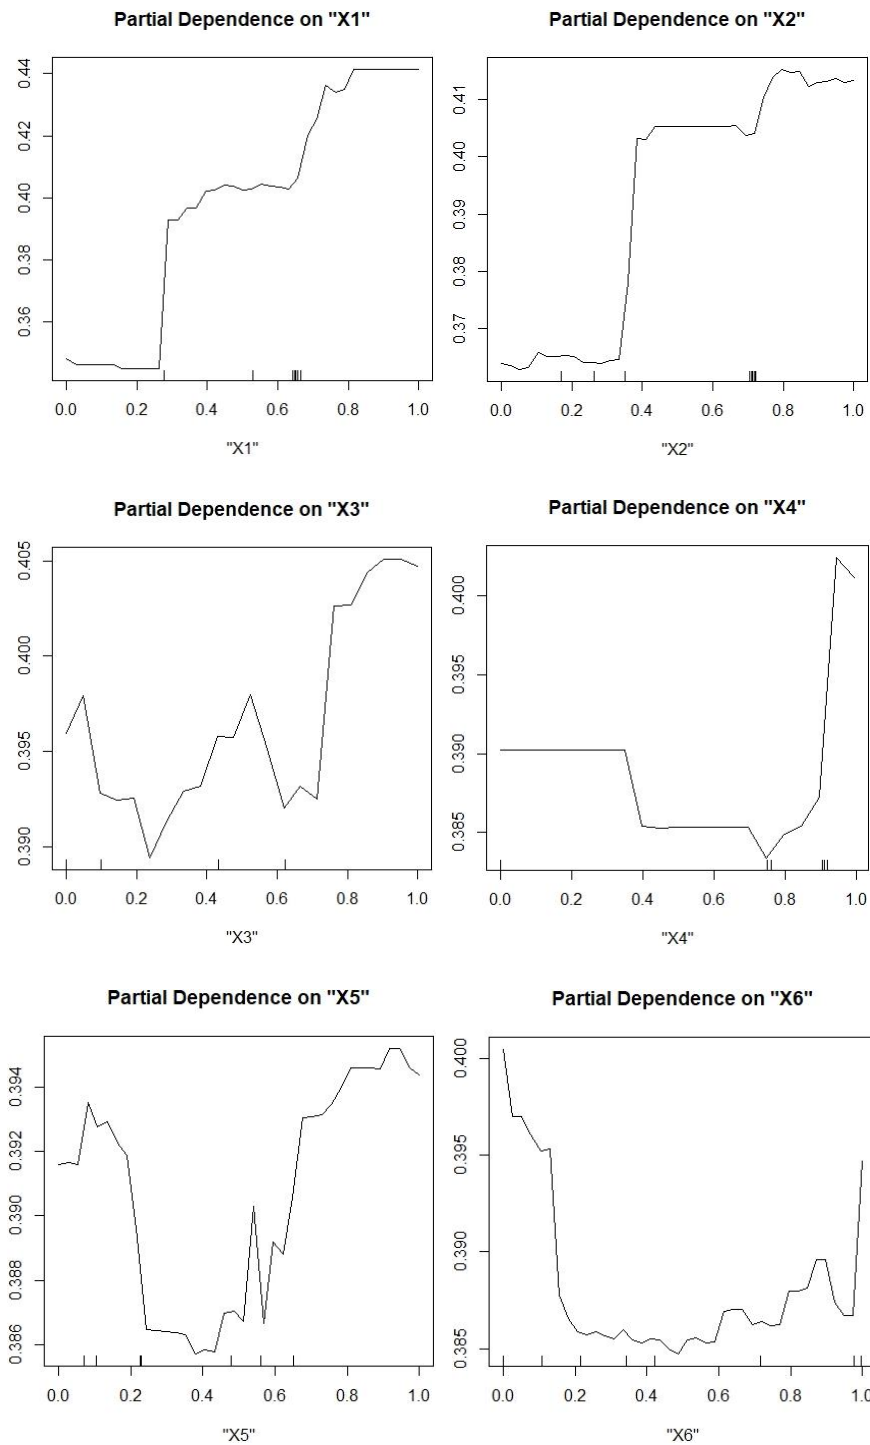


Figura 5-20. Dependencia parcial de las variables independientes para la predicción de la variable Y1 (Parte 1).

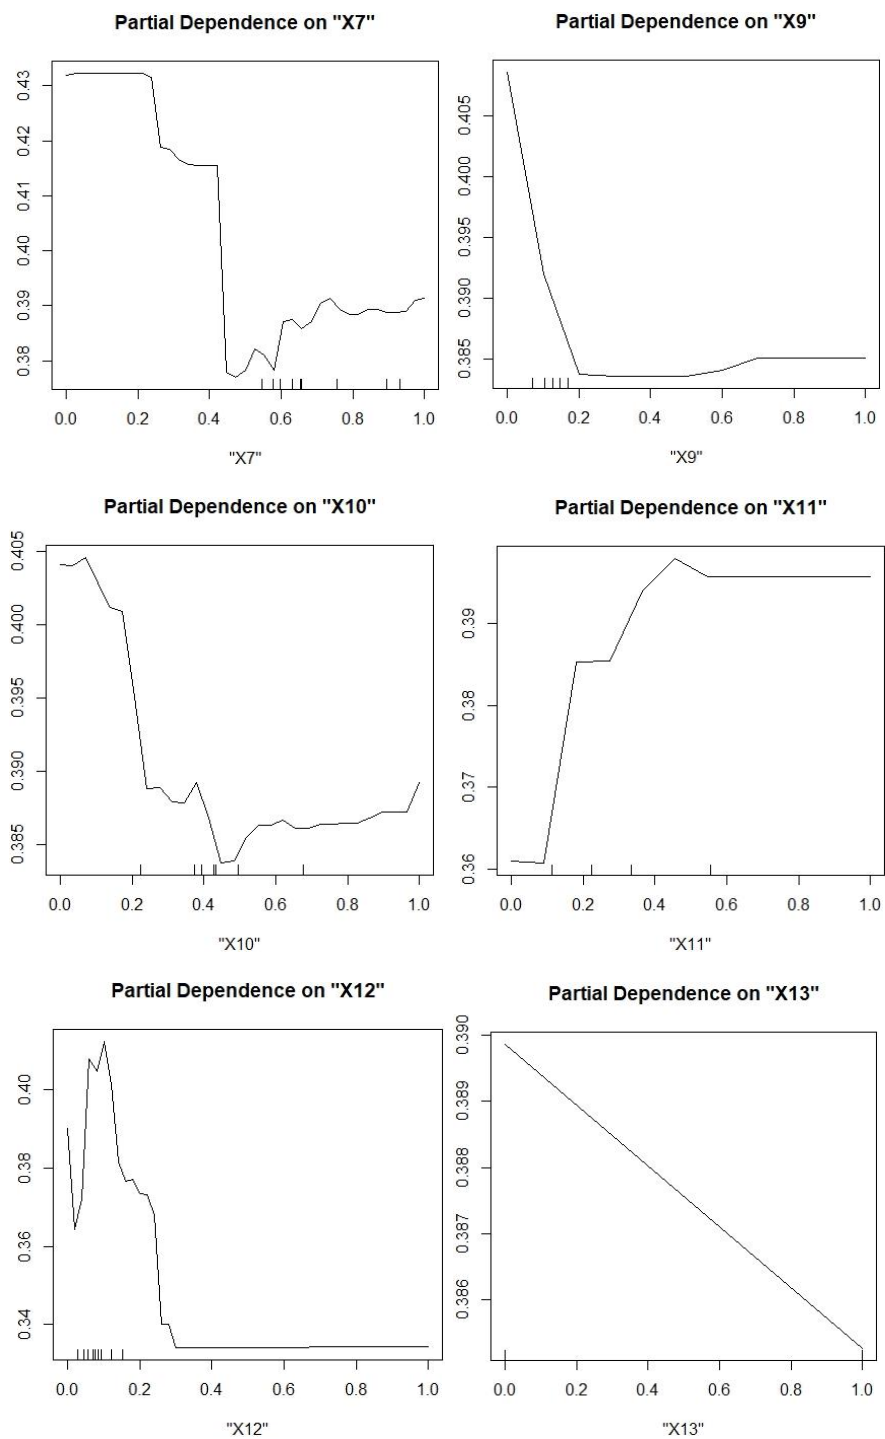


Figura 5-20. Dependencia parcial de las variables independientes para la predicción de la variable Y1 (Parte 2)

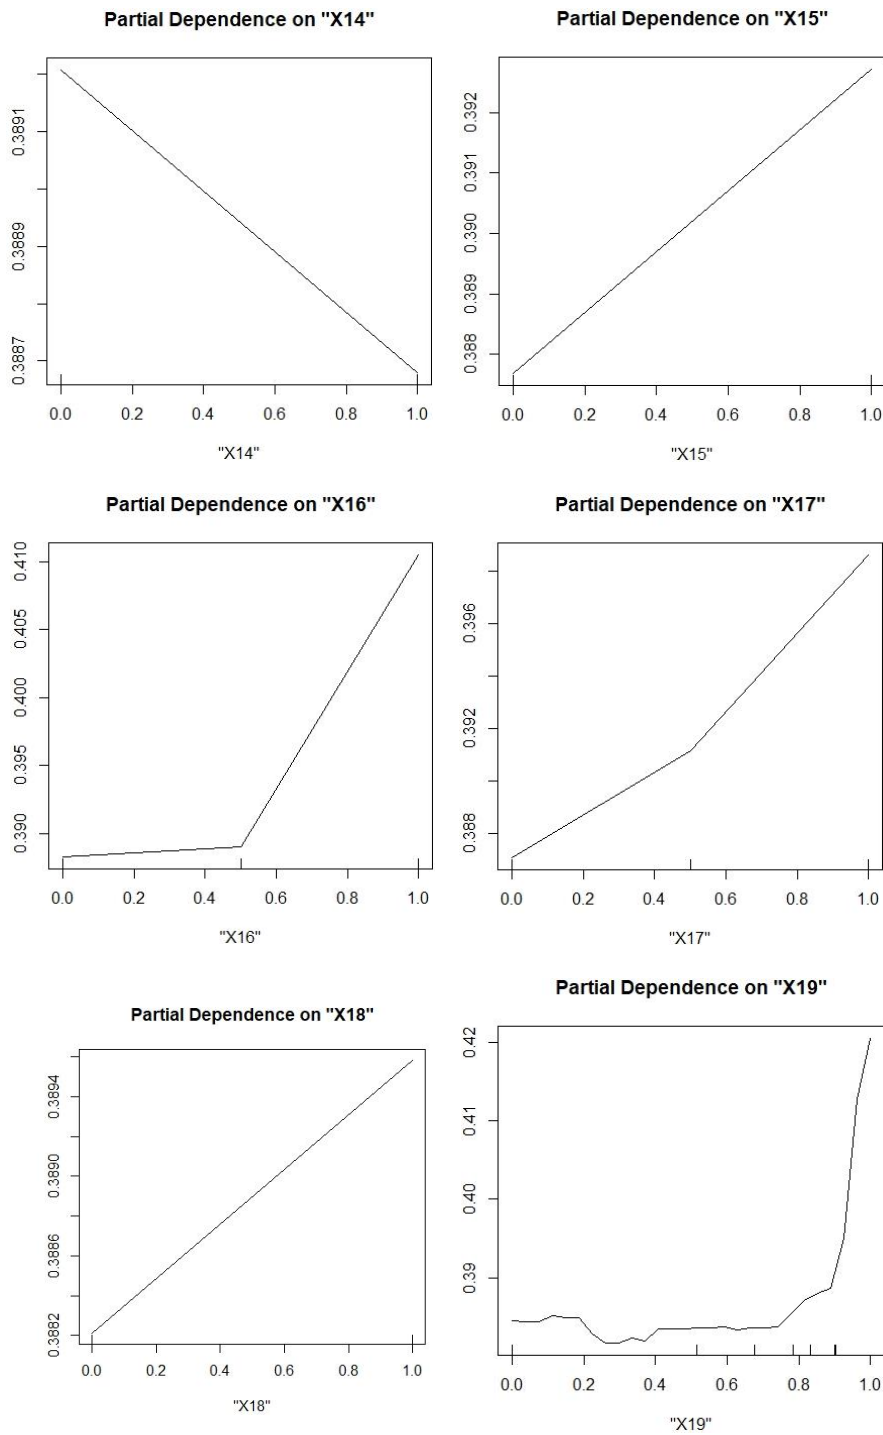


Figura 5-20. Dependencia parcial de las variables independientes para la predicción de la variable Y1 (Parte 3)

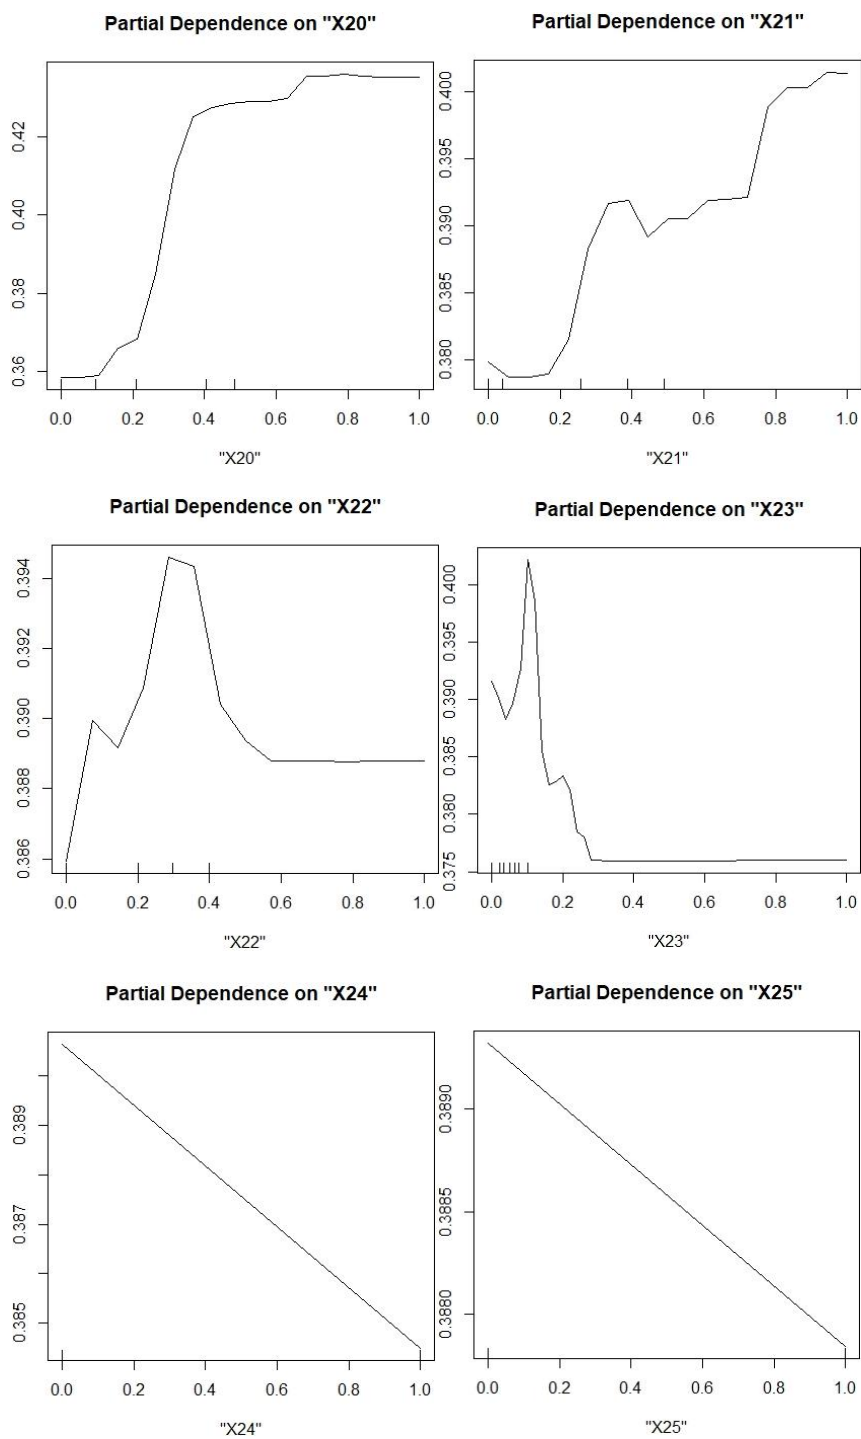


Figura 5-20. Dependencia parcial de las variables independientes para la predicción de la variable Y1 (Parte 4)

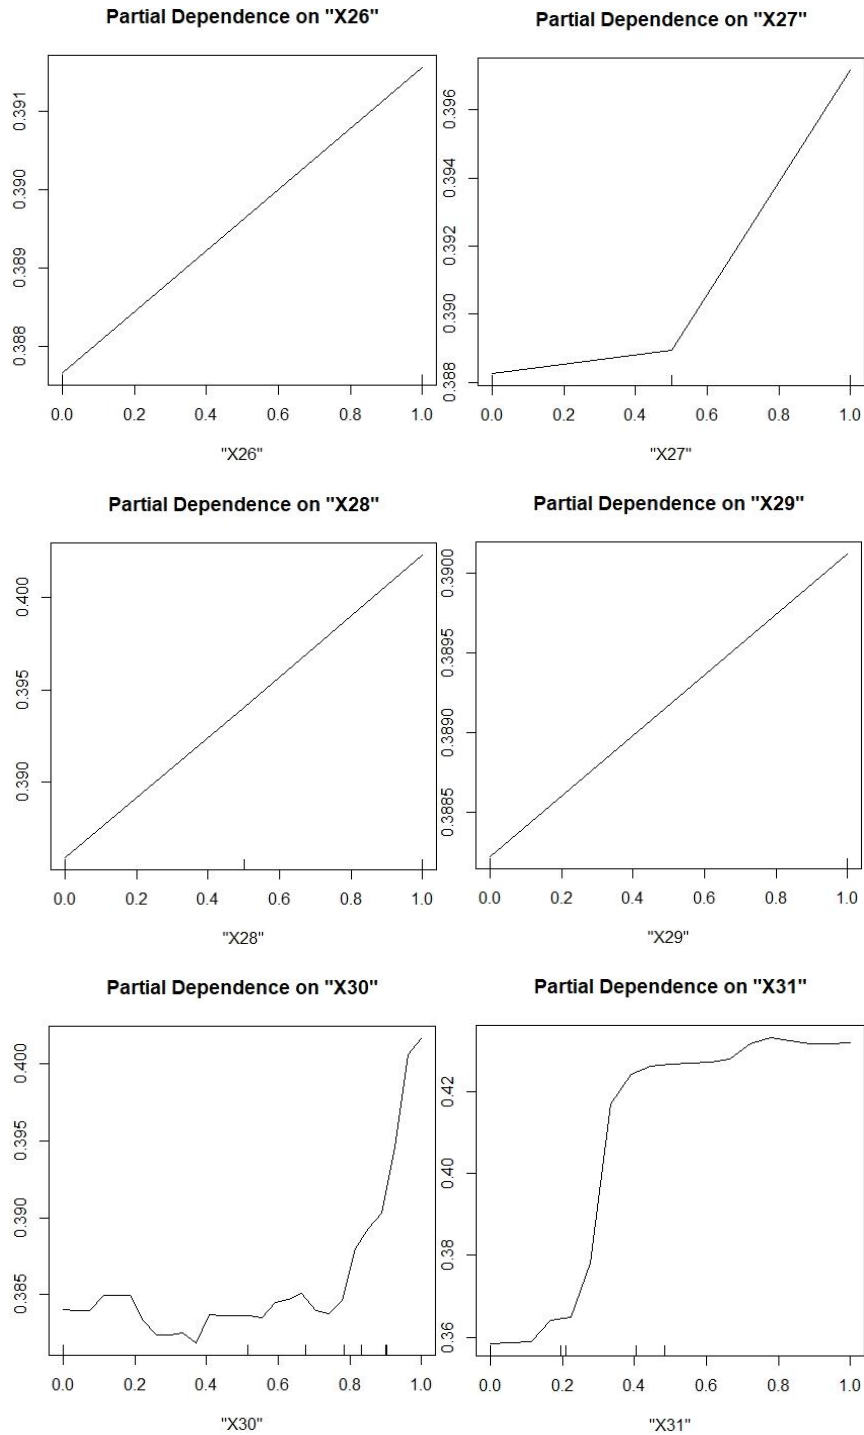


Figura 5-20. Dependencia parcial de las variables independientes para la predicción de la variable Y1 (Parte 5)

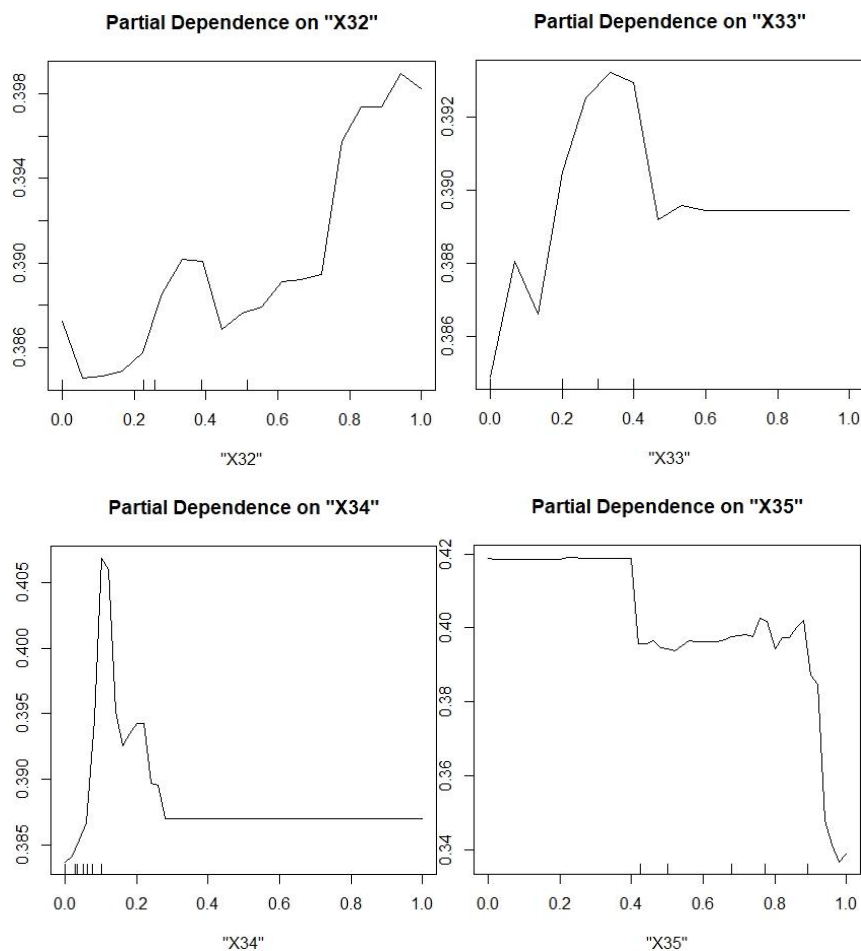


Figura 5-20. Dependencia parcial de las variables independientes para la predicción de la variable Y1 (Parte 6).

Otro aspecto destacable que se aprecia del análisis de las dependencias parciales (Figura 5-20) es que las fibras poliméricas (X16, X17, X18, X27, X28, X29) producen mayor elongación post-fisuración que las fibras metálicas, lo que, según diferentes investigadores, se debe a la diferencia en los módulos elásticos de los materiales poliméricos con el acero (Kim et al., 2009; Yu et al., 2017). De entre las poliméricas la que mejor comportamiento en la deformación unitaria es la fibra de PVA (X18 y X29), mientras que en las fibras metálicas la que presenta un mayor rendimiento para la deformación es la fibra retorcida (X15 y X26). Esto se debe al hecho de que, al estar retorcidas sobre su eje, se incrementa su adherencia con la pasta, siendo además necesario que la fibra se deforme (se “des retuerza”) para poder ser arrancada, incrementando así su contribución en la rama de endurecimiento por deformación (Pyo et al., 2015; K Wille et al., 2011; Kay

Wille & Naaman, 2012). Sin embargo, es importante destacar que las fibras metálicas retorcidas con buenas características geométricas y mecánicas no son comerciales, habiendo sido, en la mayoría de los casos reportados en la base de datos, fabricadas en laboratorios de centros de investigación (Abellán-García et al., n.d.).

En relación con la resistencia del material de la fibra (X19 y X30) cabe destacar que no es influyente salvo que se trate de fibras de acero de alta resistencia ($\geq 2,600$ MPa). En este último caso se trataría de un factor muy positivo para el desarrollo de elevados valores de ϵ_{pc} , coincidiendo esta afirmación con varias investigaciones internacionales (Abellán-García et al., n.d.; Naaman & Wille, 2010; Pyo et al., 2016; Kay Wille et al., 2011).

La noción de importancia de cada una de las variables independientes respecto a la variable $Y1$ se realiza para el desarrollo de modelos no-lineales como el de Bosques Aleatorios. Esto es posible debido a que los Bosques Aleatorios combinan un método no paramétrico, el cual no especifica algún tipo de relación entre las variables en estudio Genuer & Poggi (2020).

En la Figura 5-21 se observa la noción de importancia de cada una de las variables independientes frente a la variable $Y1$. El Factor fibra total (X12), el contenido de cemento (X1) y el humo de sílice (X2) resultan ser las variables de mayor influencia a la hora de realizar predicciones de la variable $Y1$ en un modelo de Bosques Aleatorios. Sin embargo, es la variable X12 la que representa la mayor importancia, lo cual resulta coherente, ya que esta variable tiene en cuenta el contenido en volumen de fibra de refuerzo y la esbeltez de ésta. Asimismo, es la fibra de refuerzo la que va a aportar ductilidad a la matriz cementante, en donde se busca que se presente un proceso de micro fisuración para garantizar el comportamiento de endurecimiento por deformación del UHPFRC (Pyo et al., 2015).




Figura 5-21. Noción de importancia de las variables independiente frente a Y1.

5.4.2 Modelo predictivo para la capacidad de absorción de energía (Y2) del UHPFRC

La Figura 5-22 representa el gráfico mostrando el efecto del número de árboles de decisión del modelo de Bosques Aleatorios versus el error (RMSE) entre los datos reales de la variable respuesta y las estimaciones del modelo para la capacidad de absorción de energía del UHPFRC sometido a tracción directa.




Figura 5-22. Gráfico de error (RMSE) en variables respuestas normalizadas versus número de árboles en el modelo.

Como se puede apreciar en la Figura 5-22, se alcanza una asíntota a partir de los 417 árboles de decisión, siendo que a partir de ahí el RMSE no mejora ni empeora significativamente. Por lo tanto, podemos afirmar que el modelo con 500 árboles es aceptable.

EL modelo de Bosque Aleatorios desarrollado para predecir la capacidad de absorción de energía del UHPFRC a tracción directa está conformado por 500 árboles. La Figura 5-23 muestra el primero de los 500 árboles desarrollados. El resultado presentado por el modelo de Bosques Aleatorios será, al igual que el caso anterior, es el correspondiente a la media de las predicciones realizadas por los 500 árboles que componen el modelo.




Figura 5-23. Primero de los 500 árboles de decisión del modelo de Bosques Aleatorios para predecir Y2 (g)

En la Tabla 5-5 se presentan las predicciones obtenidas mediante el desarrollo de los Bosques Aleatorios para las dosificaciones de UHPFRC indicadas en la Tabla 4-3 en el caso de la variable de respuesta Y2. Se identifica que, al igual que en el caso de las predicciones de la variable Y1 en el capítulo 5.4.1, los valores de predicción del modelo de capacidad de absorción de energía (g) resultan ser similares a los obtenidos experimentalmente. En este caso, tres de los valores de predicción son mayores que los valores reales, en donde las dosificaciones MB2%-SF50, MB2%-SF150 y OL2%-SF50 estuvieron a un 1.50%, 10.90% y 7.40%, respectivamente, por encima del valor real.

Tabla 5-5. Valores experimentales y valores obtenidos de los modelos de Bosques Aleatorios para Y2.

Mezcla	Valor real de Y2 (kJ/m ³)	Predicción de Y2 (kJ/m ³)
MB2%-SF50	27.54	27.97
MB2%-SF100	40.08	35.48
MB2%-SF150	40.10	44.99
OL2%-SF50	40.76	44.01
OL2%-SF100	47.17	42.96
OL2%-SF150	46.38	45.93

Por otro lado, la Tabla 5-6 y la Figura 5-24 exponen los parámetros de evaluación del modelo para la predicción de la capacidad de absorción de energía (g). El modelo de Bosques Aleatorios presenta una precisión acertada, de acuerdo con los valores de E y RSR en los datos de validación, los cuales corresponden a 0.7376 y 0.5123 respectivamente. Se obtuvo asimismo un valor de R^2 de 0.7417, y un valor de AE de -0.3129kJ/m^3 , indicando que, existe una predicción de la variable Y_2 por debajo del valor real. Además, los valores alcanzados sobre los datos experimentales ($R^2 = 0.7258$) reafirman la capacidad y versatilidad del modelo para predecir la capacidad de absorción de energía de nuevas dosificaciones de UHPFRC. De igual forma, en la Figura 5-24 se observa que, los resultados de predicción se encuentran cerca a los valores reales

Tabla 5-6. Medidas de desempeño del modelo de Y_2

Conjunto de datos	RMSE	R^2	RSR	E	MAE	AE	NMBE
Entrenamiento	7.0254	0.9097	0.3126	0.9023	4.9424	0.1337	0.474%
Validación	11.875	0.7417	0.5123	0.7376	8.6095	-0.3129	-1.155%
Experimental	3.5035	0.7258	0.5459	0.7020	2.9690	0.1155	0.286%

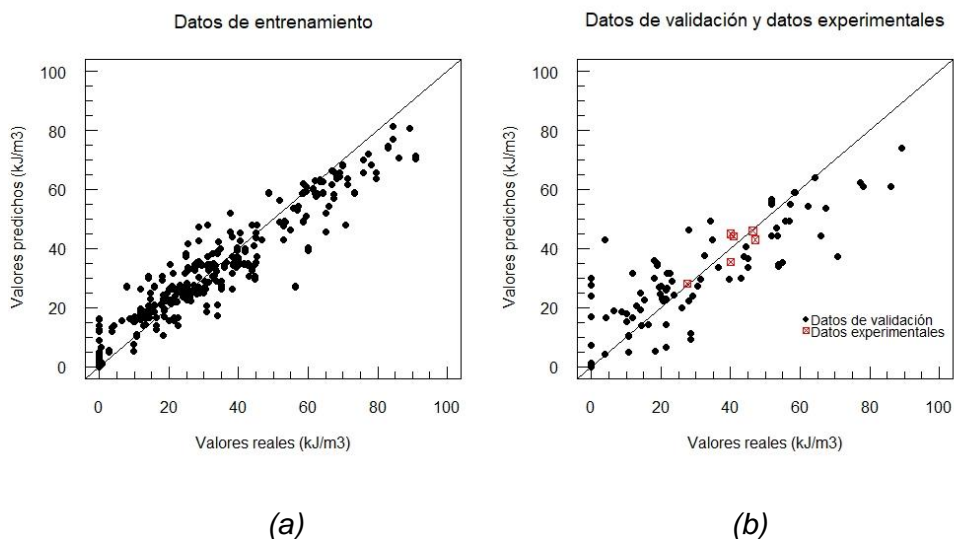


Figura 5-24. Diagrama de regresión para el modelo de Y_2 (a) datos de entrenamiento; (b) datos experimentales y de validación

Al igual que en el caso de la deformación pos-fisuración, se realizan gráficos de dependencia parcial de las variables independientes con respecto a la variable de respuesta Y_2 (capacidad de absorción de energía) utilizando el modelo desarrollado de Bosques Aleatorios. En la Figura 5-25 se expone para cada una de las variables independientes, su influencia y efecto en la capacidad de absorción de energía (g). Por lo tanto, los gráficos de dependencia parcial permiten establecer la sensibilidad de la respuesta Y_2 al incrementar el valor de cada variable independiente.

Los gráficos de dependencia parcial de las variables independientes en el caso de la variable Y_2 presenta comportamientos similares a los observados en el capítulo 5.4.1 para la variable Y_1 . En el caso del contenido de cemento (X_1) y el contenido de humo de sílice (X_2) se evidencia que, al aumentar el valor de estas dos variables incrementa el valor de capacidad de absorción de energía (g). Lo anterior se debe a que, al ser materiales finos, el empaquetamiento de partículas de la matriz cementante tiende a aumentar, lo que garantiza una mezcla de UHPFRC con mayor densidad y mejor adherencia con la fibra de refuerzo implementada (Abellán-García et al., n.d.; Pyo et al., 2015; K Wille et al., 2011).

El comportamiento de Y_2 frente al contenido de fibra y al factor fibra total se identifican en las variables independientes X_{11} y X_{12} de la Figura 5-25. Al incrementar el valor de X_{11} , los valores de Y_2 aumentan, hasta que en un punto determinado el contenido de fibra de refuerzo no afecta el valor de la capacidad de absorción de energía (g). Asimismo, para el caso de la variable X_{12} , se observa que también, aunque el efecto de este factor es positivo, llega un punto en el que su efecto se estabiliza y, a partir de ese punto, mayores valores de X_{12} no implican una mayor contribución en la capacidad de absorción de energía (g). Las fibras más positivas para el desarrollo de elevados valores de la capacidad de absorción de energía, indicadas por el análisis de dependencias parciales, serían las fibras metálicas conformadas, es decir acabadas en gancho (X_{14} y X_{25}) o retorcidas sobre su propio eje (X_{15} y X_{26}). De acuerdo con varias investigaciones (Abellán-García et al., n.d.; Kwon et al., 2014; S. H. Park et al., 2012; K Wille et al., 2011) la conformación de la fibra mejora su adherencia con el UHPC, permitiendo el desarrollo de mayores valores de g .

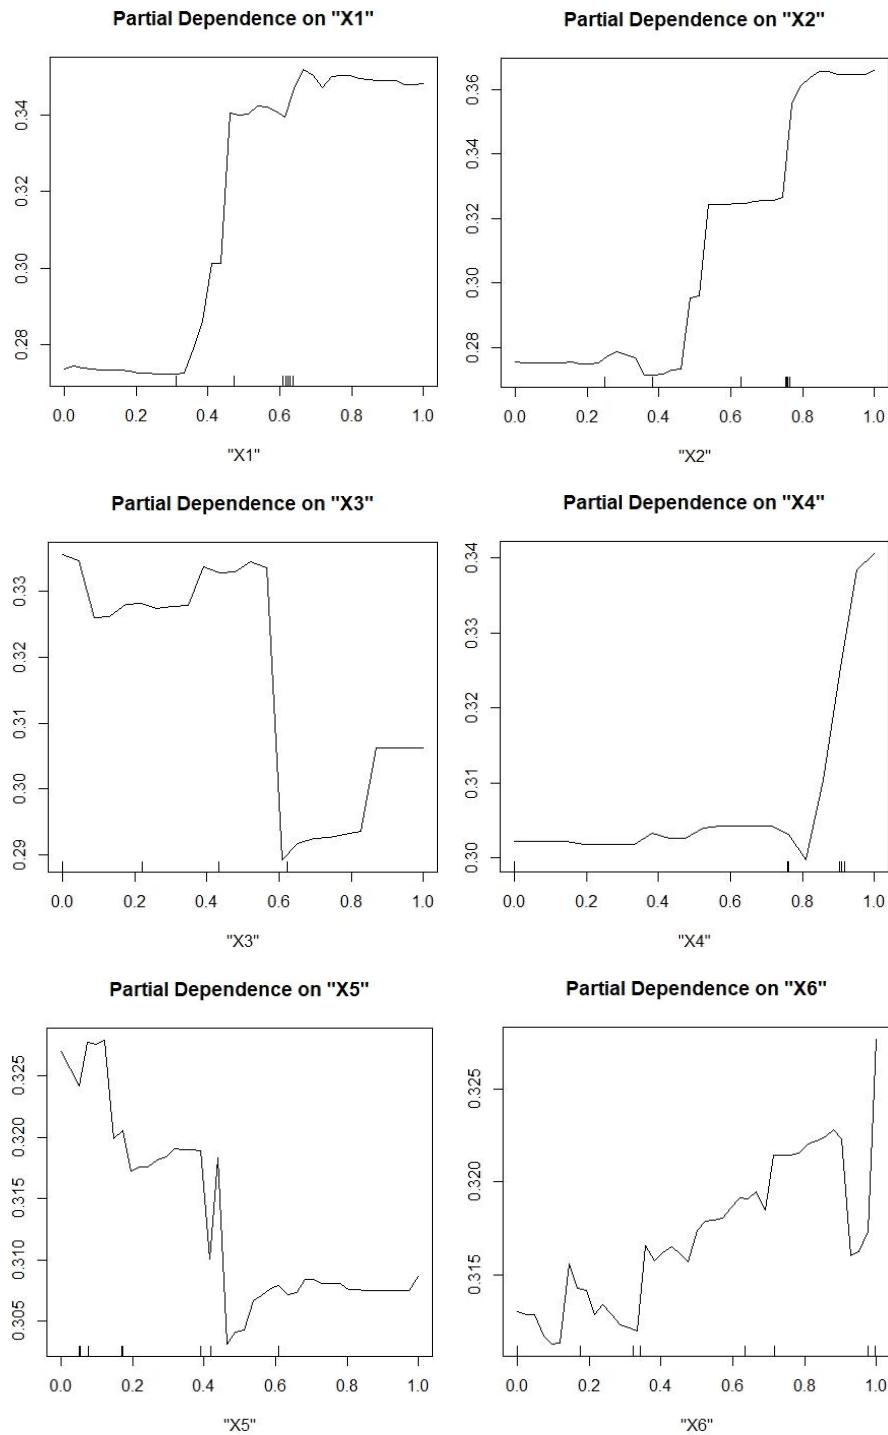


Figura 5-25. Dependencia parcial de las variables independientes para la predicción de la variable Y2 (parte 1)

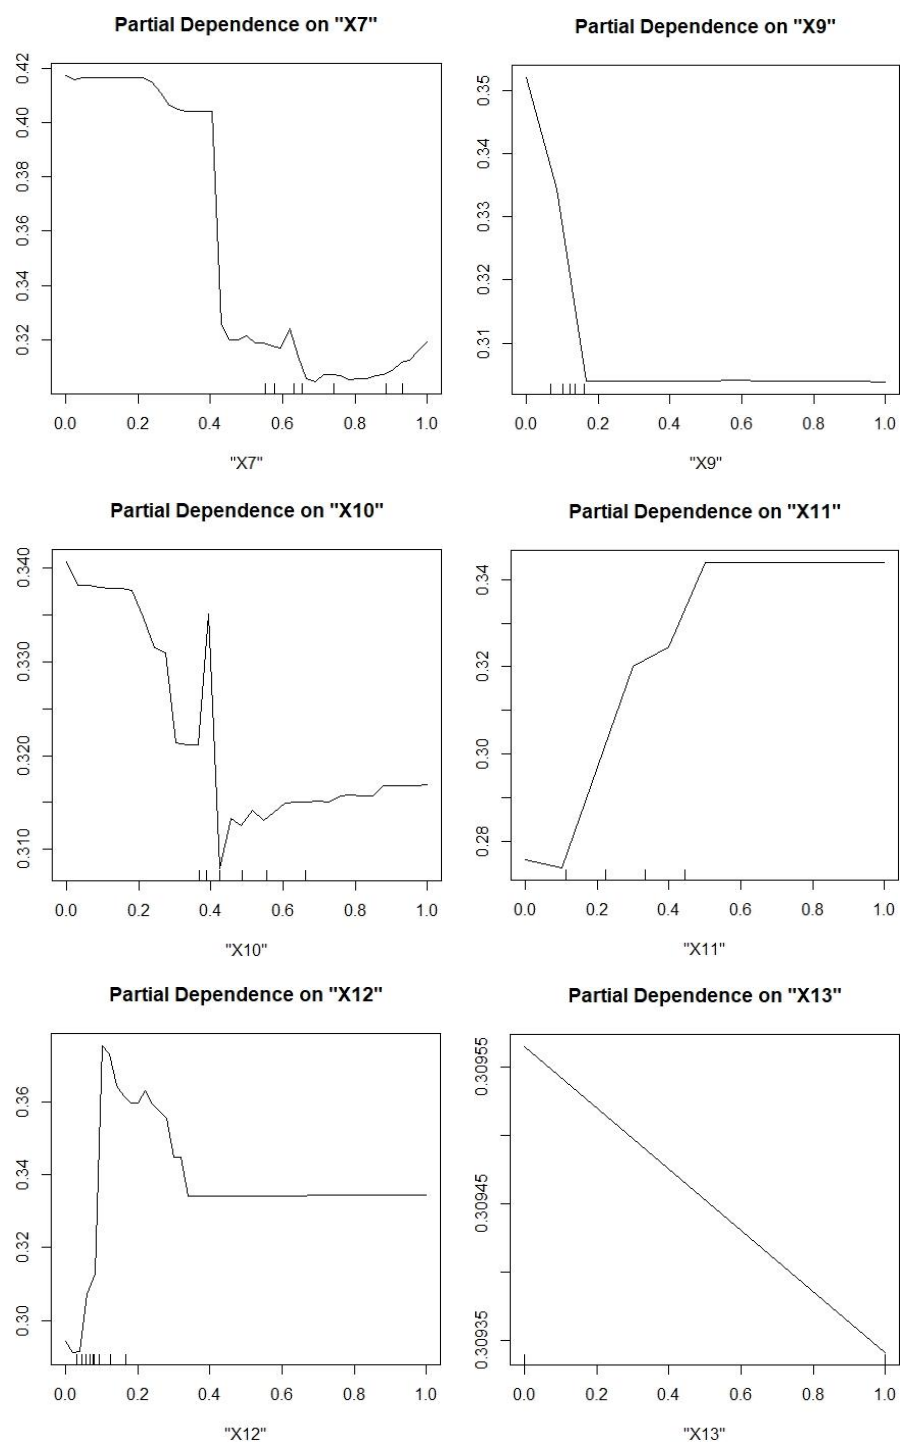


Figura 5-25. Dependencia parcial de las variables independientes para la predicción de la variable Y2 (parte 2)

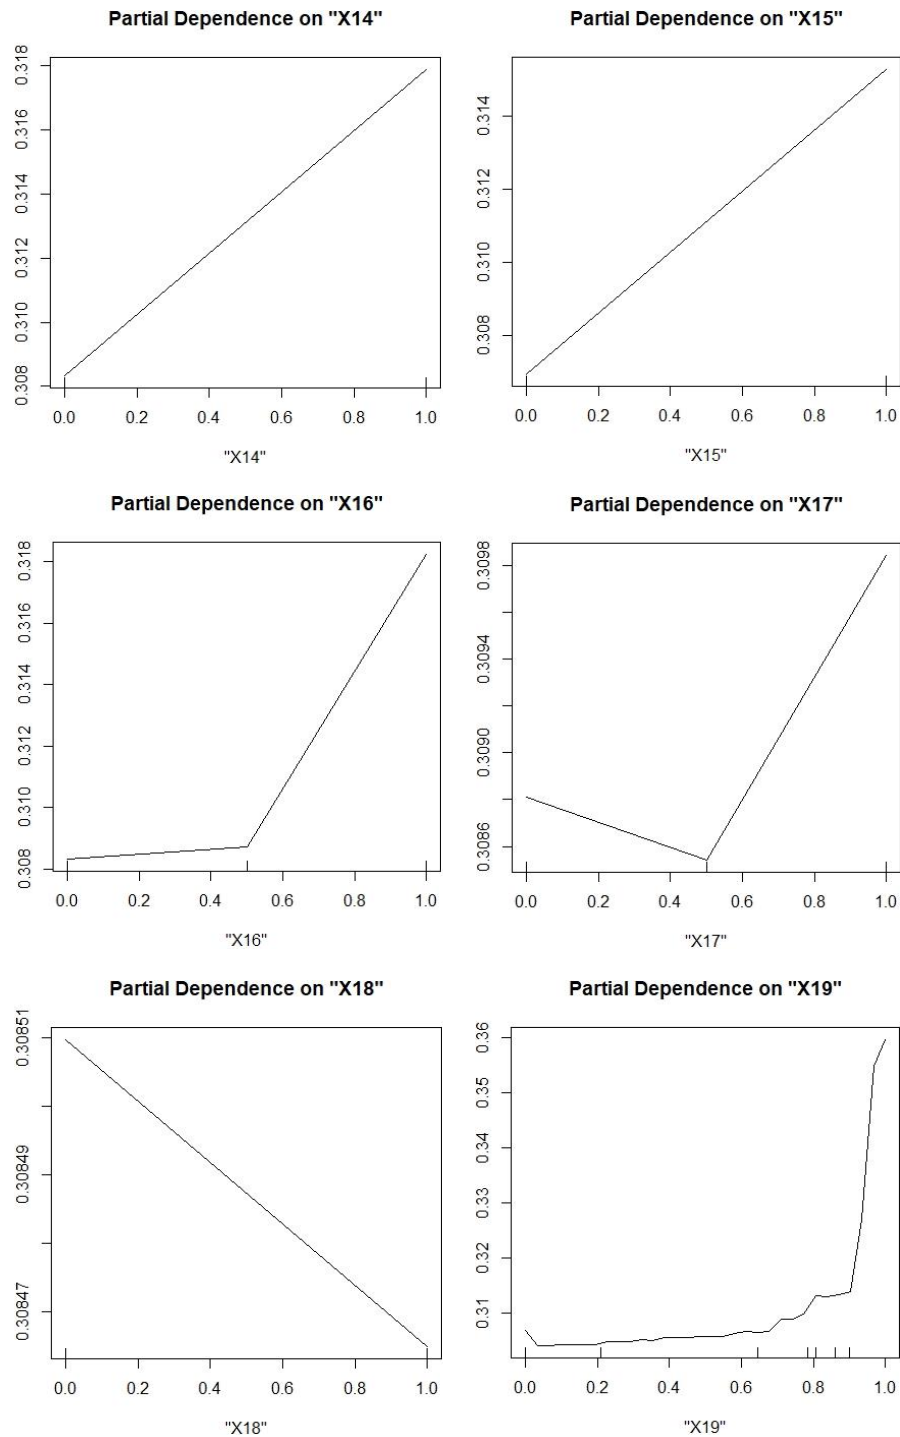


Figura 5-25. Dependencia parcial de las variables independientes para la predicción de la variable Y2 (parte 3)

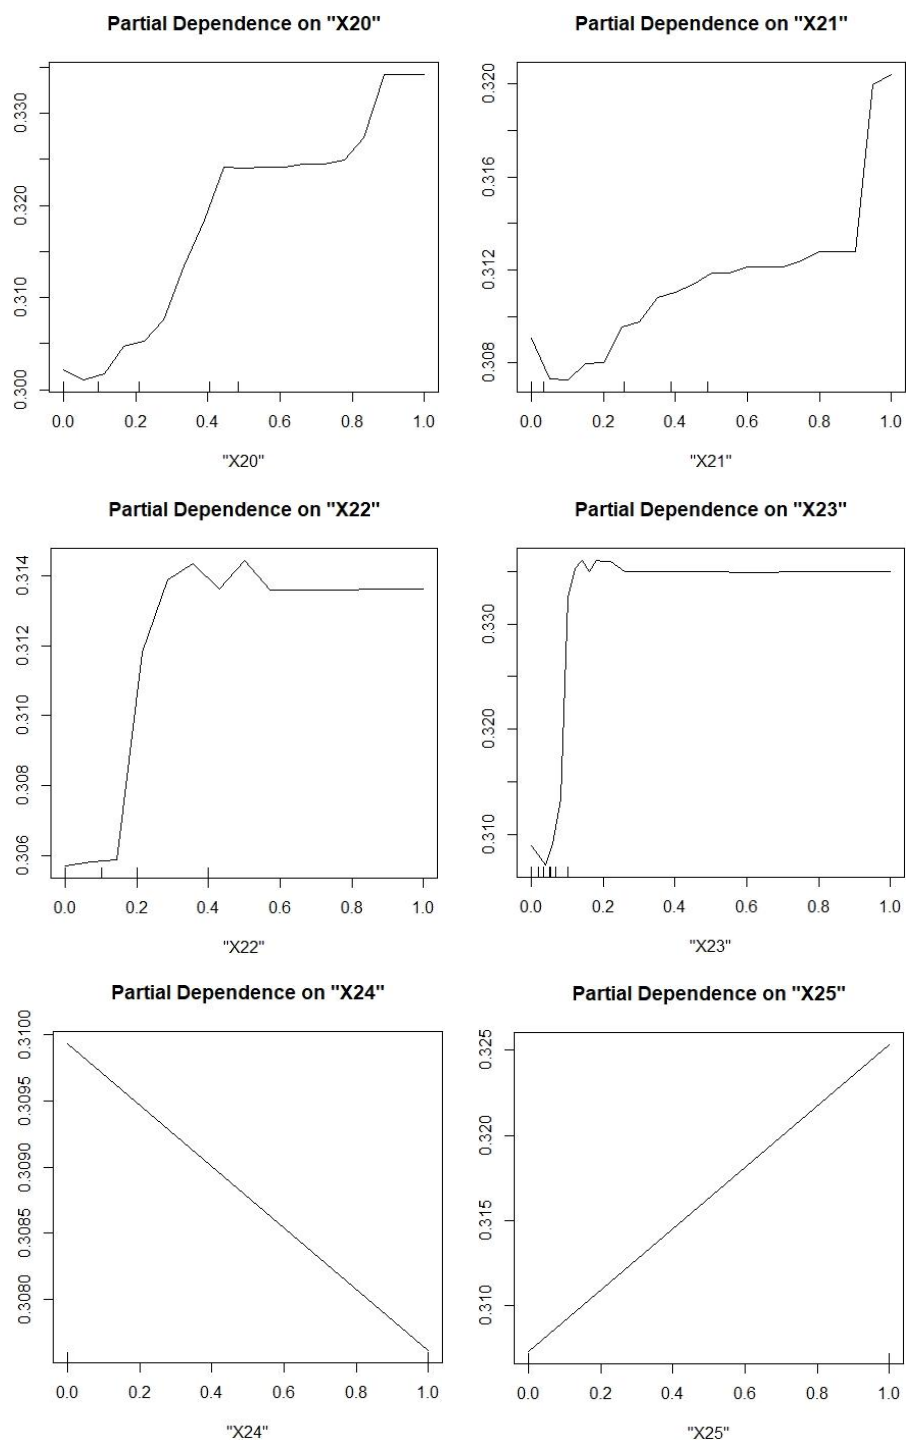


Figura 5-25. Dependencia parcial de las variables independientes para la predicción de la variable Y2 (parte 4)

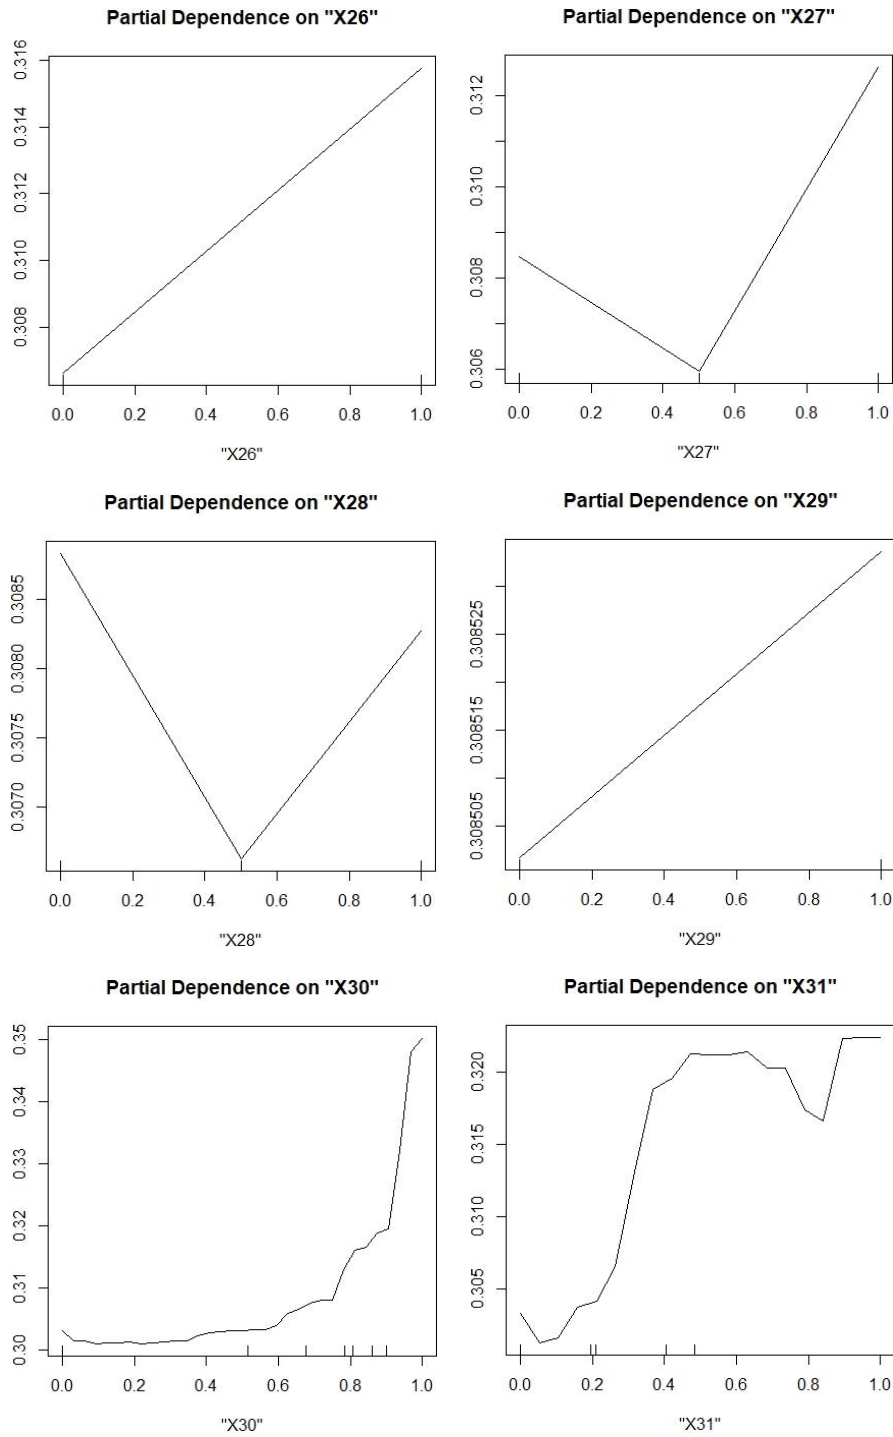


Figura 5-25. Dependencia parcial de las variables independientes para la predicción de la variable Y2 (parte 5)

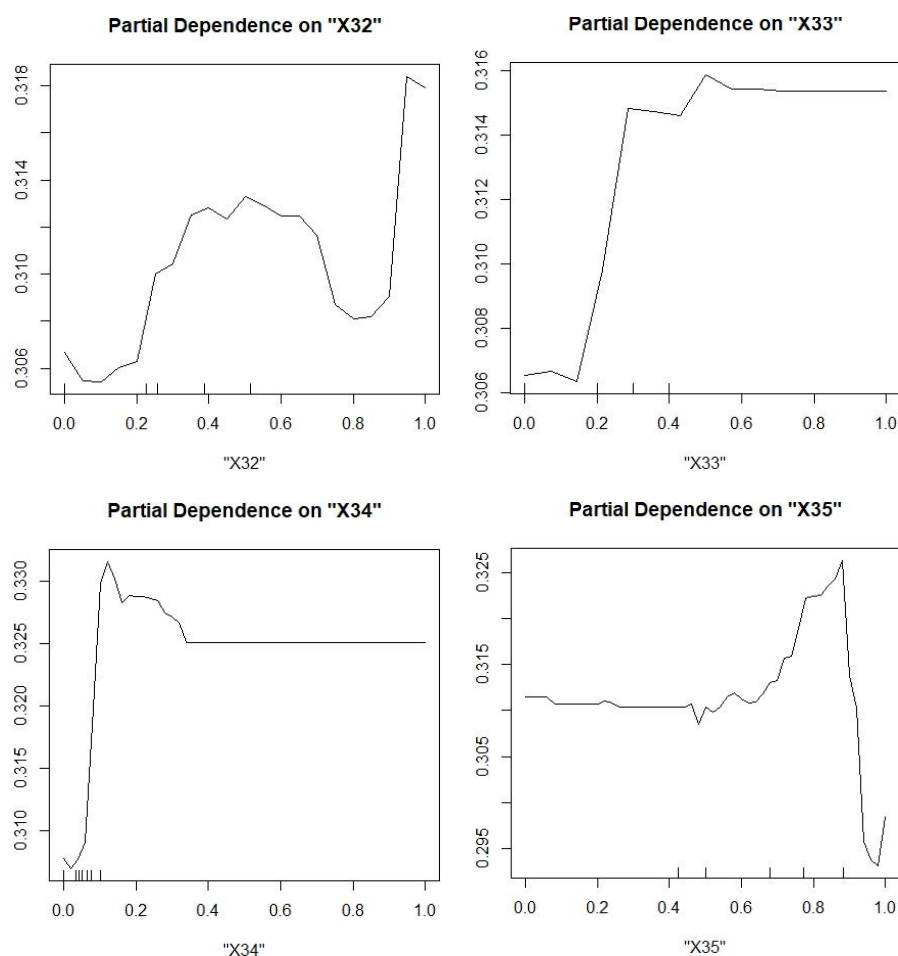


Figura 5-25. Dependencia parcial de las variables independientes para la predicción de la variable Y2 (parte 5)

Por último, y al igual que ocurría con Y1, la resistencia del material de la fibra (X19 y X30) no es influyente para el desarrollo de Y2 salvo que se trate de fibras de acero de alta resistencia ($\geq 2,600$ MPa). En este último caso se trataría de un factor muy positivo para alcanzar elevados valores de g , coincidiendo esta afirmación con varias investigaciones internacionales (Abellán-García et al., n.d.; Naaman & Wille, 2010; Pyo et al., 2016; Kay Wille et al., 2011).

En la Figura 5-26 se observa la noción de importancia de cada una de las variables independientes frente a la variable Y2. Se identifica que, al igual que en el caso de la variable Y1, el contenido de cemento (X1), el contenido de humo de sílice (X2) y factor fibra total (X12), son las variables que mayor importancia presentan al momento de realizar la predicción de la variable Y2 mediante el modelo de Bosques Aleatorios. Cabe mencionar

que, los materiales finos (X_1 , X_2 Y X_3) se encuentran en puntos altos de importancia de acuerdo con la Figura 5-26, debido a que ayudan a alcanzar un elevado empaquetamiento de partículas en la matriz cementante para obtener la máxima adherencia con la fibra de refuerzo, y, por ende, el mejor comportamiento de endurecimiento por deformación de UHPFRC.




Figura 5-26. Noción de importancia de las variables independiente frente a Y2.

5.5 Optimización del UHPFRC

Una vez se obtienen los modelos de Bosques Aleatorios validados, es posible realizar la optimización de la mezcla de UHPFRC. La optimización multiobjetivo en este caso consiste en identificar la combinación de fibras disponibles en el mercado colombiano con el objetivo de conseguir una dosificación de UHPFRC que cumpla con los parámetros deseados para el reforzamiento sísmico de estructuras ($g \geq 50 \text{ kJ/m}^3$ y $\varepsilon_{pc} \geq 0.3\%$) al menor costo posible. Para ello se contemplará una dosificación previamente optimizada con materias primas colombianas, desarrollada por (Abellán, Núñez, Torres, et al., 2020) y que definirá el valor de las variables de X_1 a X_9 y X_{35} . Dicha dosificación se presenta en la Tabla 5-7.

Tabla 5-7. Dosificación de UHPC a considerar en la optimización multiobjetivo (Abellán, Núñez, Torres, et al., 2020)

Propiedades y proporciones en peso de cemento del UHPC optimizado								
Cemento	Humo de sílice	Carbonato cálcico	Polvo de vidrio reciclado	Agua	Superplastificante	Arena silíceas	VPD*	f_c (MPa)
1.00	0.17	0.39	0.55	0.31	0.0054	1.50	0.81	156

VPD = densidad de empaquetamiento virtual (Larrard, 1994)

Además, para el caso de las fibras, se considerarán las siguientes, también disponibles en el mercado colombiano, y cuyas propiedades se observan en la Tabla 5-8.

Tabla 5-8. Fibras disponibles en el mercado colombiano a considerar en la optimización multiobjetivo (Abellán-García, 2020b)

Notación	Forma	d_f (mm)	l_f (mm)	d_f/l_f	Material	Resistencia (MPa)	Costo (COP/kg)
OL 13/.2	Recta	0.20	13	65	Acero	≈ 2,600	11,000
OL 6/0.2	Recta	0.20	6	30	Acero	≈ 2,600	10,500
3D	Con gancho	0.50	35	70	Acero	≈ 2,000	9,000
MB	Con gancho	0.75	60	80	Acero	≈ 1,600	4,855
T	Twisted	0.50	13	26	Acero	≈ 1,700	7,500
PP	Recta	0.72	48	75	Polipropileno	≈ 6,50	30,000
PE	Recta	0.67	50	67	Polietileno	≈ 550	27,000
PVA	Recta	0.025	6	240	Polivinilo de alcohol	≈ 1,600	35,000

Por lo tanto, se busca, con los materiales considerados, maximizar la respuesta de la deformación pos-fisuración (ϵ_{pc}), maximizar la respuesta de capacidad de absorción de energía (g), y minimizar el costo total por m^3 de la mezcla en COP (pesos colombianos).

El algoritmo de optimización multiobjetivo codificado en R utilizado en este proyecto se basó en el enfoque de *deseabilidades* desarrollado por Derringer & Suich (1980a), donde los valores predichos de cada variable de respuesta se transforman en valores dentro del intervalo [0.1] utilizando dos métodos de deseabilidad diferentes para los dos criterios de optimización diferentes (es decir, minimizar y maximizar). A cada valor de una variable de respuesta se le puede asignar una conveniencia específica, optimizando más de una variable de respuesta a la vez.

Derringer & Suich (1980b) definieron los casos de *deseabilidad* para minimizar y maximizar las variables respuesta como se presenta en las ecuaciones 5-1 y 5-2, respectivamente.

$$\mathbf{d} = \begin{cases} \mathbf{1} & Y_i \leq L \\ \left[\frac{U-Y_i}{U-L} \right]^{wt_i} & L < Y_i < U \\ \mathbf{0} & Y_i \geq U \end{cases} \quad (5-1)$$

$$\mathbf{d} = \begin{cases} \mathbf{0} & Y_i \leq L \\ \left[\frac{Y_i-L}{U-L} \right]^{wt_i} & L < Y_i < U \\ \mathbf{1} & Y_i \geq U \end{cases} \quad (5-2)$$

En donde U representa el límite superior, L representa el límite inferior, Y_i es la variable respuesta, wt_i es la importancia relativa de la variable respuesta considerada y d es la deseabilidad asociada al valor de la respuesta.

En la Tabla 5-9 se exponen los valores de U y L así como los criterios definidos para realizar el análisis de optimización multiobjetivo, con el fin de obtener una mezcla de UHPFRC capaz de ser implementada en escenarios de reforzamiento sísmico de estructuras.

Tabla 5-9. Objetivos de la optimización de las respuestas de la mezcla UHPFRC para aplicaciones de reforzamiento sísmico de estructuras

Variables	Límite inferior	Límite superior	Objetivo	Importancia
g (kJ/m ³)	50	75	Máximo	5
ε_{pc} (%)	0.3	0.5	Máximo	5
Costo (x1000 COP)	500	2000	Mínimo	5

Hay varias formas de dibujar la solución óptima considerando múltiples funciones de deseabilidad individuales, pero el método más utilizado es optimizar mediante la conversión de múltiples funciones de deseabilidad en una sola deseabilidad D (Derringer & Suich, 1980b; Ghafari et al., 2014; Ghafari, Costa, et al., 2015). La media geométrica de las deseabilidades específicas caracteriza la deseabilidad general como sigue en la ecuación 5-3:

$$D = (d_1^{r_1} \times d_2^{r_2} \times d_3^{r_3} \times \dots \times d_n^{r_n})^{1/\sum r_i} = [\prod_{i=1}^n d_i^{r_i}]^{1/\sum r_i} \quad (5-3)$$

Un valor de D diferente de cero en la ecuación (5-3) implica que todas las variables respuesta están en un rango deseable simultáneamente y, en consecuencia, para un valor de D cercano a 1, la combinación de los diferentes criterios es globalmente óptima, por lo

que los valores de respuesta están cerca de sus valores objetivo. Sin embargo, si alguna de las respuestas queda fuera de su rango de deseabilidad, la función general se vuelve cero. En la ecuación (5-3), r_i representa la importancia relativa asignada a la respuesta i . La importancia relativa r_i es una escala comparativa para la ponderación de cada función de deseabilidad individual (d_i) en el producto de deseabilidad general y varía desde la menos importante ($r_i = 1$) hasta la más importante ($r_i = 5$). Es importante señalar que el resultado de la deseabilidad general D depende del valor r_i que ofrece a los usuarios flexibilidad en la definición de funciones de deseabilidad. En este estudio, las constantes de forma son iguales a 5 en todos los casos.

Una vez realizada la optimización, se obtiene la mezcla de fibras para el UHPFRC que satisface los requisitos planteados. Los resultados se observan en la Tabla 5-10, identificando que, una mezcla la fibra de acero recta tipo OL 13/0.2 y MB resulta ser la apropiada por las propiedades a tracción directa del UHPFRC, su bajo costo y su facilidad de ser encontrada en el mercado colombiano.

Tabla 5-10. Mezcla de UHPFRC optimizada para aplicaciones de reforzamiento sísmico de estructuras

Mezcla	Tipo de fibra 1	V_{f1} (%)	Tipo de fibra 2	V_{f2} (%)	V_f Total (%)	g (kJ/m ³)	ϵ_{pc} (%)	Costo m ³ (COP)
UHPFRC	OL13/0.2	0.38	MB	1.52	1.90	59.23	0.37	907,428

6. Conclusiones

El uso de modelos matemáticos basados en la inteligencia artificial ha tenido un crecimiento constante durante los últimos años a nivel mundial en diferentes campos de la ingeniería. La disponibilidad de lenguajes de programación abiertos, la capacidad de las máquinas de cómputo, junto a la gran disponibilidad de datos, tanto en cantidad como accesibilidad, permiten la aplicación de estas metodologías, siendo viables para abordar problemas complejos que, de otra forma, podrían resultar difíciles de resolver debido a las necesidades de recursos y tiempo.

En este contexto se enmarca la investigación presentada, en la que se utilizaron algoritmos del tipo Bosques Aleatorios para a identificación de dosificaciones de UHPFRC de bajo costo, y desarrolladas con materias primas colombianas, capaces de cumplir con los requisitos de ductilidad necesarios para su empleo como material de refuerzo sísmico de estructuras. Con base en los resultados obtenidos pueden extraerse las siguientes conclusiones:

1. El modelo de regresión propuesto para la deformación unitaria (ϵ_{pc}) bajo carga máxima a tracción directa del UHPFRC demostró ser preciso, teniendo en cuenta la complejidad del problema modelado. Los valores obtenidos en los índices estadísticos de evaluación (RMSE, R^2 , RSR, E, MAE, AR y NMBE) en el conjunto de datos de validación fueron de 0.1254, 0.7279, 0.5298, 0.7193, 0.0969, -0.0079 y -2.079% respectivamente.

2. Por su parte, el modelo de regresión propuesto para la capacidad de absorción de energía (g) también demostró su alta precisión en las estimaciones. En este caso, los valores obtenidos en los índices estadísticos de evaluación (RMSE, R^2 , RSR, E, MAE, AR y NMBE) en el conjunto de datos de validación fueron de 11.875, 0.7417, 0.5123, 0.7376, 8.6095, -0.3129, 1.155% respectivamente.
3. Ambos modelos presentaron elevados coeficientes de correlación con los resultados experimentales resultantes de la combinación de 3 dosificaciones diferentes de concreto tipo UHPC y dos tipos distintos de fibras metálicas. Los valores de correlación (R^2) para las predicciones de ϵ_{pc} y g fueron de 0.7184 y 0.7258 respectivamente. Esto indica la versatilidad de los modelos para ser utilizados con nuevos datos y, por tanto, para ser empleados en el desarrollo de nuevas investigaciones.
4. Los resultados de los análisis de dependencia parcial de ambos modelos arrojaron conclusiones coincidentes con investigaciones internacionales, reforzando la validez de los modelos desarrollados. Entre éstas cabe destacar: a) la importancia de los contenidos de finos (cemento y humo de sílice) para el desarrollo tanto de ϵ_{pc} y g , lo que podría estar relacionado con la mejora del empaquetamiento de partículas del concreto; b) la relevancia positiva del factor fibra sobre ambas propiedades de ductilidad; c) la aportación de la fibra polimérica al desarrollo de altos valores de ϵ_{pc} ; y d) la idoneidad de las fibras metálicas retorcidas para lograr elevados parámetros de ductilidad. Cabe destacar que estas fibras metálicas retorcidas no están disponibles comercialmente, por lo que las optimizaciones se realizaron con fibras disponibles en el mercado colombiano.
5. Para una mezcla de concreto optimizada con materias primas colombianas y con una resistencia a compresión de 156 MPa, la optimización multiobjetivo presentó a la mezcla híbrida de fibras formada por fibras metálica recta (OL 13/0.2) y acabada en gancho (MB) con contenidos en volumen de 0.38% y 1.52%, respectivamente, como aquella capaz de alcanzar los objetivos de ductilidad ($g \geq 50 \text{ kJ/m}^3$ y $\epsilon_{pc} \geq 0.3\%$) a menor costo. Para este contenido total de fibras del 1.90%, los modelos de Bosques Aleatorios presentaron resultados estimados de deformación pos-

fisuración del 0.37% y una capacidad de absorción de energía de 59.23 kJ/m³, a un costo del contenido de fibra de COP 907,428.

7.Recomendaciones

1. Comprobar experimental de la dosificación optimizada en esta investigación. Cabe resaltar que, debido a la pandemia del Covid-19, esta validación no pudo ser incluida en el presente proyecto.
2. Implementar otras metodologías de inteligencia artificial y aprendizaje automático supervisado, como por ejemplo *deep-learning* y *bootstrapping* para la predicción de otras propiedades de los UHPFRC como el módulo de elasticidad y las propiedades de durabilidad.
3. Realizar un proyecto experimental en el que se evalúe el comportamiento pos-fisuración del UHPFRC, implementando no solo fibras metálicas. Estudiar el comportamiento a tracción directa del UHPFRC incorporando fibras poliméricas, como lo son la fibra de polipropileno, polietileno o polivinilo de alcohol (PVA).
4. Elaborar un análisis de costos por metro cubico a corto, mediano y largo plazo de diferentes tipos de concreto, como podría ser el concreto reforzado convencional, con respecto al UHPFRC. Se deberían tener en cuenta los costos de producción y construcción con los tipos de concreto que se tengan en cuenta en la investigación.

La finalidad de estas investigaciones junto con la presente es la de ofrecer modelos matemáticos que ayuden a la investigación y desarrollo de estos concretos especiales, reduciendo costos de la campaña experimental necesaria.

8. Anexos

8.1 Ensayos de tracción directa

A continuación, se exponen los valores de carga y deformación obtenidos de los ensayos a tracción directa de las probetas de hueso de perro de UHPFRC.

8.1.1 MB2%-SF50

Tabla 8-1. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF50-1

MB2%-SF50-1		MB2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
0	0	5.74535889	0.46875
9.13143222	0.015125	5.45073444	0.477125
9.05196111	0.023375	5.25587889	0.485375
9.06420778	0.031625	5.14566444	0.493625
9.07555333	0.039875	5.05436	0.501875
9.08455778	0.048125	4.75109111	0.5105
9.06816889	0.056375	4.40027889	0.519375
9.06600778	0.064625	4.32068	0.525125
9.09428222	0.072875	4.14239222	0.534125
9.12003444	0.081	4.12708556	0.54325
9.14560778	0.08925	4.06747556	0.5515
9.16739889	0.097625	4.01957222	0.55975
9.19171111	0.105875	3.89819222	0.568
9.21242	0.114125	3.78689778	0.57625
9.23511111	0.122375	3.74223667	0.584375

MB2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)
9.24825778	0.130625
9.26734778	0.138875
9.28643556	0.147
9.30588556	0.15525
9.32749667	0.163375
9.34424444	0.171625
9.35955222	0.179875
9.37215889	0.188125
9.38602444	0.196375
9.39286889	0.204625
9.39719	0.212875
9.41357778	0.221125
9.43248778	0.2295
9.45391889	0.23775
9.47048667	0.246125
9.48561444	0.254375
9.50218333	0.262625
9.50848556	0.270875
9.51929111	0.279125
9.52919556	0.287375
9.53441778	0.295625
9.53964111	0.30375
9.53856111	0.312
9.51821	0.32025
9.48723556	0.3285
9.47769	0.33675
9.45319889	0.345
9.44905556	0.35325
9.46508444	0.3615
9.45644111	0.36975
9.44887667	0.378
9.44761556	0.38625
9.09986556	0.394875
8.51187556	0.402875
8.43173778	0.411
8.33611	0.41925

MB2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)
3.63256222	0.59275
3.46454	0.600875
3.36405111	0.609125
3.29039444	0.617375
3.20971556	0.625625
3.04655444	0.634
2.88807667	0.64225
2.84323556	0.6505
2.78632778	0.65875
2.70600778	0.667
2.65324222	0.675125
2.60912	0.683375
2.56085667	0.691625
2.52609889	0.699875
2.50160778	0.708125
2.47351333	0.716375
2.4465	0.724625
2.42164889	0.732875
2.40237889	0.741125
2.29990889	0.7495
2.28208	0.75775
2.26479111	0.766
2.22751333	0.774375
2.19887889	0.782625
2.17042444	0.79075
2.12414222	0.799
2.07659889	0.807125
2.04562333	0.815125
1.98061222	0.823875
1.97088667	0.832
1.94153222	0.84025
1.91289889	0.8485
1.88498444	0.85675
1.85779111	0.865
1.81817222	0.87325
1.77927333	0.8815

MB2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)
8.23904333	0.4275
7.89993667	0.435875
7.28007222	0.444375
6.09905222	0.452375
5.92580778	0.4605

MB2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)
1.73947333	0.88975
1.71696222	0.898
1.69841333	0.90625
1.68598667	0.9145
1.63862444	0.916875

Tabla 8-2. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF50-2

MB2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
0	0
7.04811778	0.01298125
6.99823333	0.02185625
6.90326889	0.02973125
6.97674444	0.03773125
6.93095222	0.04610625
6.98083667	0.05435625
6.92081556	0.06260625
6.95017	0.07085625
6.99249111	0.07898125
6.93463222	0.08735625
6.96686778	0.09523125
7.00792778	0.10335625
7.02539667	0.11198125
7.05799222	0.12010625
7.09130889	0.12835625
7.08500556	0.13673125
7.01062889	0.14485625
7.04520556	0.15310625
7.07546111	0.16148125
7.10121333	0.16973125
7.09311	0.17810625
7.09256889	0.18635625
7.08842667	0.19460625
7.06789778	0.20285625

MB2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
5.10727556	0.56585625
5.07954222	0.57410625
5.03812111	0.58235625
5.00354444	0.59060625
4.96194444	0.59885625
4.94141444	0.60698125
4.84920889	0.61535625
4.85101	0.62348125
4.83354111	0.63173125
4.80526778	0.63998125
4.77195111	0.64823125
4.72909	0.65648125
4.73863444	0.66460625
4.70856	0.67298125
4.66876	0.68123125
4.59762556	0.68960625
4.59564444	0.69785625
4.56340889	0.70610625
4.55674556	0.71448125
4.53189333	0.72273125
4.49443444	0.73098125
4.47498556	0.73923125
4.43392444	0.74735625
4.38386	0.75560625
4.36711222	0.76385625

MB2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
7.04178444	0.21098125
7.01963333	0.21935625
6.95264111	0.22760625
6.93859333	0.23573125
6.91590222	0.24398125
6.86619889	0.25223125
6.85755444	0.26048125
6.84602889	0.26873125
6.81037	0.27698125
6.78623889	0.28523125
6.77417333	0.29348125
6.75688444	0.30173125
6.72933111	0.31010625
6.72158778	0.31835625
6.70916111	0.32660625
6.68575	0.33473125
6.64469	0.34298125
6.51952778	0.35135625
6.18618444	0.35948125
6.16079222	0.36773125
6.10388444	0.37598125
6.07092778	0.38423125
6.01960333	0.39248125
5.97872333	0.40073125
5.94918889	0.40898125
5.91173	0.41723125
5.88111556	0.42560625
5.83105111	0.43385625
5.76387778	0.44223125
5.71777444	0.45048125
5.68914	0.45873125
5.61602444	0.46698125
5.54831222	0.47523125
5.31725889	0.48335625
5.29780889	0.49160625
5.26701333	0.49985625

MB2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
4.3419	0.77210625
4.32947333	0.78035625
4.31056444	0.78860625
4.28247	0.79685625
4.26536222	0.80510625
4.24483222	0.81335625
4.22304111	0.82160625
4.20413222	0.82985625
4.18828444	0.83810625
4.16667333	0.84635625
4.14380222	0.85460625
4.12705444	0.86285625
4.10544333	0.87110625
4.08221222	0.87935625
4.06096222	0.88748125
4.03989111	0.89573125
4.00981667	0.90398125
3.98118333	0.91223125
3.96065222	0.92048125
3.94138333	0.92873125
3.89041778	0.93698125
3.81604222	0.94535625
3.76237556	0.95360625
3.71141	0.96198125
3.66836889	0.97023125
3.64243667	0.97848125
3.61956556	0.98673125
3.49260333	0.99498125
3.45478444	1.00323125
3.37752667	1.01148125
3.37302444	1.01960625
3.38022778	1.02785625
3.37842778	1.03610625
3.35987778	1.04435625
3.35537556	1.05260625
3.31539556	1.06085625

MB2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
5.25278667	0.50810625
5.23477778	0.51635625
5.21136667	0.52460625
5.18777444	0.53285625
5.15445778	0.54098125
5.14149222	0.54923125
5.13627	0.55748125

MB2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
3.31971778	1.06910625
3.31629667	1.07735625
3.31773667	1.08560625
3.31467556	1.09385625
3.30621111	1.10210625
3.27919778	1.11035625
3.24876333	1.11498125

8.1.2 MB2%-SF100

Tabla 8-3. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF100-1

MB2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
0	0.01687625
7.58948444	0.027345
7.36962333	0.03765625
7.31919889	0.04796875
7.3626	0.05812625
7.38979333	0.068595
7.41770667	0.0790625
7.44129889	0.089375
7.46255	0.0996875
7.48307889	0.11000125
7.50270889	0.1203125
7.5245	0.13046875
7.55061222	0.1407825

MB2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
4.24148889	1.12988125
4.22185889	1.14019375
4.19124444	1.15050625
4.16495111	1.16081875
4.14892333	1.17128125
4.12299111	1.18144375
4.09849889	1.19175625
4.07634778	1.20206875
4.06176	1.21238125
4.04051	1.22269375
4.02304111	1.23300625
4.00593333	1.24315625
3.98684333	1.25346875

MB2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
7.57420333	0.143095
7.59743556	0.14540625
7.66695	0.14771875
7.67343222	0.1500325
7.69792444	0.160345
7.72187667	0.17065625
7.73700333	0.18096875
7.72763889	0.1912825
7.75681333	0.201595
7.77914444	0.21190625
7.80021444	0.22221875
7.82038444	0.2325325
7.83965333	0.242845
7.85496111	0.253
7.87855333	0.2633125
7.89368111	0.27362625
7.91060889	0.28393875
7.92789667	0.29425
7.95239	0.3045625
7.96895778	0.31487625
7.98912778	0.325345
8.00839667	0.33565625
8.02478556	0.34628125
8.04135222	0.3564375
8.06152222	0.36675125
8.07701111	0.37706375
8.09141778	0.387375
8.10456444	0.3976875
8.11681	0.40800125
8.13013667	0.41831375
8.14706444	0.42846875
8.14256333	0.43878125
7.76203667	0.449095
7.70638889	0.45940625
7.74708889	0.46971875
7.77446222	0.48003125

MB2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
3.98054111	1.26378125
3.96811444	1.27409375
3.96163111	1.28440625
3.92345222	1.29471875
3.90958556	1.30519375
3.89139667	1.31550625
3.86996667	1.32596875
3.86186222	1.33628125
3.84259333	1.34659375
3.83070667	1.35690625
3.81558	1.36721875
3.80603556	1.37753125
3.79414889	1.38784375
3.77884111	1.39815625
3.76659556	1.40846875
3.76263333	1.41863125
3.74786667	1.42894375
3.74048222	1.43925625
3.73093778	1.44738125
3.72751667	1.46003125
3.72157333	1.47034375
3.70950778	1.48065625
3.70050333	1.49096875
3.68771667	1.50128125
3.68393444	1.51159375
3.67727111	1.52190625
3.67240889	1.53221875
3.64665667	1.54253125
3.63549111	1.55269375
3.62702667	1.56300625
3.62090444	1.57331875
3.62090444	1.58363125
3.6119	1.59394375
3.60325556	1.60425625
3.59821333	1.61456875
3.59335111	1.62488125

MB2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
7.79193111	0.490345
7.81300111	0.50065625
7.84577667	0.51096875
7.86900889	0.52128125
7.89782333	0.531595
7.92339556	0.54206375
7.95004778	0.55221875
7.97075889	0.56222
7.99092778	0.57237625
7.98732667	0.58315625
8.00911778	0.59346875
8.03559	0.60378125
8.05666	0.61425125
8.06944667	0.6244075
8.07557	0.63471875
7.86630778	0.64534375
7.72781889	0.65550125
7.77320111	0.66581375
7.82488667	0.67628125
7.83119	0.68675
7.83317111	0.6970625
7.75825444	0.70737625
7.58428889	0.71753125
7.43859778	0.72784375
7.35791778	0.7383125
7.04366333	0.74847
6.63630333	0.75878125
6.51582444	0.76909375
6.39120333	0.77925125
6.25505667	0.78956375
6.20121	0.799875
6.16681333	0.8101875
6.12359222	0.82050125
6.07280778	0.83097
5.91955222	0.84128125
5.82464444	0.85159375
5.72451667	0.8619075

MB2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
3.58218444	1.63519375
3.58182556	1.64550625
3.57696222	1.65596875
3.57138	1.66628125
3.56633778	1.67675625
3.54778778	1.68706875
3.53590222	1.69706875
3.53014	1.70721875
3.51897444	1.71784375
3.50961	1.72815625
3.50186556	1.73846875
3.49412222	1.74863125
3.48169556	1.75909375
3.46782889	1.76940625
3.45612333	1.77971875
3.42875	1.78988125
3.42911	1.80034375
3.42352778	1.81065625
3.41452333	1.82096875
3.40912	1.83128125
3.39327222	1.84159375
3.35833556	1.85190625
3.35113222	1.86221875
3.34356778	1.87253125
3.33510444	1.88269375
3.32483889	1.89300625
3.31295333	1.90331875
3.30160778	1.91363125
3.29890667	1.92394375
3.28954111	1.93425625
3.2863	1.94456875
3.28143778	1.95488125
3.27027222	1.96519375
3.26468889	1.97550625
3.25370333	1.98596875
3.24974222	1.99628125
3.24307889	2.00659375

MB2%-SF100-1		MB2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
5.63969444	0.87222	3.23605556	2.01706875
5.56387778	0.882375	3.22507	2.02721875
5.49706444	0.8926875	3.21138333	2.03721875
5.42611	0.902845	3.19661556	2.04815625
5.34020778	0.9131575	3.18527	2.05815625
5.25214444	0.92346875	3.17770667	2.06846875
5.2009889	0.93378125	3.16474	2.07878125
5.15723778	0.944095	3.15501556	2.08909375
5.10753333	0.9544075	3.14295	2.09940625
5.05098556	0.96471875	3.13160333	2.10971875
4.97588889	0.9751875	3.11953778	2.11988125
4.88584444	0.98550125	3.08027889	2.13034375
4.80012222	0.99597	3.04894333	2.14065625
4.74285444	1.00628125	3.07721778	2.15096875
4.68126444	1.01659375	3.06173	2.16128125
4.6321	1.02690625	3.04948333	2.16909375
4.58851889	1.03722	3.04102	2.16909375
4.53971444	1.04753125	3.03093444	2.17940625
4.49649333	1.05784375	3.02301111	2.18971875
4.45237222	1.06815625	3.01382667	2.19988125
4.42193667	1.07846875	3.01292556	2.21034375
4.39438333	1.08878125	3.00734333	2.22065625
4.35584444	1.09909375	3.00986444	2.23096875
4.32360889	1.10940625	3.00500222	2.24128125
4.29515556	1.11956875	2.97582778	2.24909375
4.26814222	0.01687625		

Tabla 8-4. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF100-2

MB2%-SF100-2		MB2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
0	0	6.29525667	0.766875
7.75865444	0.015625	6.29291556	0.7771875
7.75613333	0.026875	6.28283111	0.78742188
7.70192667	0.03703125	6.27364667	0.79765625

MB2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
8.17275333	0.05234375
8.15492333	0.06265625
8.13871556	0.07296875
8.09963667	0.08328125
8.06614111	0.09359375
7.98221889	0.10421875
8.51229444	0.11421875
8.51049333	0.1246875
8.49410556	0.135
8.48546111	0.1453125
8.4824	0.175625
8.47879778	0.19078125
8.75195556	0.25109375
8.76728222	0.26140625
8.72098889	0.27171875
8.68785333	0.28203125
8.64802222	0.29234375
8.53094556	0.30265625
8.66113333	0.31296875
8.25188667	0.32328125
8.23765889	0.33359375
8.21839	0.34390625
8.19155667	0.354375
8.16400333	0.3646875
8.14275222	0.37507813
8.10799556	0.38546875
8.06099222	0.39578125
7.98499556	0.40609375
7.95257889	0.41632813
7.93727222	0.4265625
6.92538556	0.436875
6.90773778	0.4471875
6.89783222	0.4575
6.88468667	0.4678125
6.91764222	0.47734375
6.82759778	0.4884375

MB2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
6.26302111	0.80796875
6.24879444	0.8184375
6.24249111	0.82875
6.23780889	0.8390625
6.22664333	0.849375
6.21799889	0.8596875
6.20629333	0.87
6.20197111	0.8803125
6.18558333	0.890625
6.18126111	0.9009375
5.88051333	0.91117188
5.89852222	0.92140625
5.89798222	0.93171875
5.89762222	0.94203125
5.90104333	0.95234375
5.89690111	0.96265625
5.91779222	0.97203125
5.90428556	0.9834375
5.89402	0.99367188
5.87943333	1.00390625
5.87331	1.014375
5.86844778	1.02484375
5.86718667	1.03515625
5.86160444	1.04546875
5.86052333	1.05578125
5.84845778	1.06609375
5.84341556	1.07640625
5.83207	1.0865625
5.82396556	1.096875
5.81928333	1.1071875
5.80847778	1.1175
5.80001444	1.1278125
5.77318111	1.1371875
5.78740778	1.14828125
5.78434667	1.15867188
5.78056444	1.1690625

MB2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
6.81463111	0.49859375
6.79536222	0.5090625
6.78851889	0.51921875
6.77465222	0.5296875
6.75736333	0.54
6.72044556	0.5503125
6.69361222	0.560625
6.67452333	0.57078125
6.66281667	0.58109375
6.55152222	0.5915625
6.50488	0.60171875
6.49821667	0.61203125
6.46922222	0.62234375
6.47084333	0.63265625
6.46670111	0.64296875
6.44635111	0.65328125
6.43320444	0.66359375
6.42077889	0.67390625
6.40511111	0.684375
6.38205889	0.6946875
6.36459111	0.70515625
6.35594667	0.71546875
6.34045889	0.72578125
6.33451667	0.73609375
6.32983444	0.74640625
6.32677222	0.7565625

MB2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
5.77552222	1.179375
5.75805333	1.18984375
5.73662333	1.20015625
5.7296	1.2103125
5.72401667	1.220625
5.71771333	1.2309375
5.71267111	1.24125
5.70546778	1.2515625
5.69592333	1.26171875
5.69268111	1.27203125
5.67989444	1.28234375
5.67125111	1.29265625
5.66080556	1.30296875
5.65360222	1.31328125
5.65360222	1.32359375
5.65018	1.3340625
5.64801889	1.344375
5.63559333	1.3546875
5.63019111	1.36515625
5.62100667	1.37546875
5.60822	1.38578125
5.59993556	1.39609375
5.58642889	1.40640625
5.56427778	1.41671875
5.53330333	1.426875
6.29525667	0.766875

8.1.3 MB2%-SF150

Tabla 8-5. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF150-1

MB2%-SF150-1		MB2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
0	0	5.83702444	1.12453125
7.39675646	7.39675646	5.82135667	1.13484375
7.26278333	7.26278333	5.80442778	1.14515625
7.27719111	7.27719111	5.79362333	1.15546875
7.29249778	7.29249778	5.77831444	1.165625
7.30474444	7.30474444	5.76264667	1.17593875
7.32077111	7.32077111	5.74608	1.18625
7.33734	7.33734	5.73131222	1.1965625
7.35138667	7.35138667	5.71240333	1.206875
7.37011667	7.37011667	5.69007111	1.2171875
7.37624	7.37624	5.66395889	1.2275
7.39298667	7.39298667	5.65567444	1.2378125
7.37497778	7.37497778	5.64090778	1.248125
7.49509778	7.49509778	5.62830222	1.25859375
7.45241667	7.45241667	5.60254889	1.26875
7.46718444	7.46718444	5.55878778	1.2790625
7.48897444	7.48897444	5.55374556	1.289375
7.51184556	7.51184556	5.53645667	1.2996875
7.52229111	7.52229111	5.52421111	1.31
7.53669889	7.53669889	5.51250444	1.3201575
7.54606222	7.54606222	5.50440111	1.33046875
7.55686778	7.55686778	5.49431556	1.3407825
7.55686778	7.55686778	5.47828778	1.35109375
7.55092556	7.55092556	5.45397556	1.3614075
7.52679333	7.52679333	5.42246111	1.37171875
7.50716333	7.50716333	5.41183556	1.3820325
7.59779889	7.59779889	5.40499111	1.39000625
7.59095556	7.59095556	5.4	1.4028125
7.58123	7.58123	5.38446222	1.413125
7.55727889	7.55727889	5.37779889	1.42359375
7.60217222	7.60217222	5.35744889	1.43390625

MB2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)
7.64346333	7.64346333
7.62149222	7.62149222
7.51086778	7.51086778
7.45330333	7.45330333
7.40528444	7.40528444
7.43690556	7.43690556
7.39600556	7.39600556
7.39425556	7.39425556
7.34744444	7.34744444
7.30582444	7.30582444
7.30168222	7.30168222
7.28637444	7.28637444
7.26440444	7.26440444
7.23919222	7.23919222
7.18606667	7.18606667
7.12969889	7.12969889
7.0519	7.0519
7.03497222	7.03497222
7.02848889	7.02848889
7.00993889	7.00993889
6.98796889	6.98796889
6.93880444	6.93880444
6.92133556	6.92133556
6.86605	6.86605
6.83813556	6.83813556
6.81760556	6.81760556
6.79923667	6.79923667
6.77672556	6.77672556
6.74268778	6.74268778
6.71171333	6.71171333
6.69640556	6.69640556
6.63949778	6.63949778
6.56998333	6.56998333
6.54207	6.54207
6.51721778	6.51721778
6.47381667	6.47381667

MB2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)
5.34718333	1.44421875
5.28883556	1.45453125
5.27821	1.4646875
5.2566	1.475
5.23823	1.4853125
5.20293222	1.495625
5.17862111	1.5059375
5.15899111	1.51625
5.14512444	1.5265625
5.12513444	1.536875
5.10658556	1.5471875
5.08641556	1.5575
5.06822667	1.5678125
5.05237889	1.578125
5.03797111	1.5884375
5.01996333	1.59875
5.00933778	1.6090625
4.99060889	1.619375
4.98304444	1.6296875
4.95765222	1.64
4.94486667	1.65015625
4.91821333	1.66046875
4.89066	1.67078125
4.87085	1.68109375
4.8514	1.69140625
4.82276667	1.70171875
4.80385778	1.71203125
4.77738444	1.72234375
4.75433333	1.7328125
4.73830444	1.743125
4.72966	1.75359375
4.72101556	1.7639075
4.71021111	1.77421875
4.69706444	1.7845325
4.68409778	1.791875
4.61782556	1.8051575

MB2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)
6.45490778	6.45490778
6.44662222	6.44662222
6.44320111	6.44320111
6.43707889	6.43707889
6.41961	6.41961
6.41096556	6.41096556
6.38935444	6.38935444
6.36792444	6.36792444
6.33713	6.33713
6.32362333	6.32362333
6.30309222	6.30309222
6.27878111	6.27878111
6.26131222	6.26131222
6.24528444	6.24528444
6.23213778	6.23213778
6.20908667	6.20908667
6.20026222	6.20026222
6.18801667	6.18801667
6.17396889	6.17396889
6.15848222	6.15848222
6.14083333	6.14083333
6.12048333	6.12048333
6.10697667	6.10697667
6.09058889	6.09058889
6.07059778	6.07059778
6.06159444	6.06159444
6.04016333	6.04016333
6.03061889	6.03061889
6.02539667	6.02539667
6.01585111	6.01585111
6.00576667	6.00576667
5.99640222	5.99640222
5.98127444	5.98127444
5.96542667	5.96542667
5.95642333	5.95642333
5.94795889	5.94795889
5.93553222	5.93553222

MB2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)
4.54164889	1.81546875
4.56794111	1.825625
4.58649	1.8359375
4.58126778	1.84625
4.58685111	1.8565625
4.57712556	1.866875
4.57064222	1.8771875
4.56037778	1.8875
4.53948778	1.8978125
4.52886222	1.908125
4.53084333	1.9184375
4.52273889	1.92875
4.51229444	1.9390625
4.50473	1.949375
4.50166889	1.9596875
4.49356444	1.96984375
4.47681667	1.98015625
4.46439	1.99046875
4.44152	2.00078125
4.43503667	2.01109375
4.42279	2.02140625
4.41072444	2.03171875
4.40388111	2.04203125
4.38839333	2.05250125
4.37794778	2.0628125
4.35993889	2.0732825
4.34895444	2.08359375
4.33004444	2.09421875
4.25566778	2.10453125
4.23117556	2.1146875
4.22793444	2.125
4.20956556	2.1353125
4.19209667	2.145625
4.16904556	2.15578125
4.14455333	2.16609375
4.13284778	2.17640625
4.12312333	2.18671875

MB2%-SF150-1		MB2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
5.92076444	5.92076444	4.11213778	2.19703125
5.91374222	5.91374222	4.10403333	2.20734375
5.89339111	5.89339111	4.09557	2.21765625
5.8707	5.8707	4.08962667	2.22796875
5.85611333	5.85611333	4.08170222	2.23047

Tabla 8-6. Valores de carga y deformación para los ensayos a tracción directa de la dosificación MB2%-SF150-2

MB2%-SF150-2		MB2%-SF150-2	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
0	0	7.00509	0.95703125
7.62901889	0.01459375	7.00797222	0.96734375
7.57296	0.01890625	6.98600111	0.9778125
7.61582111	0.029375	6.98384	0.988125
7.64607667	0.0396875	6.98942222	0.99859375
7.591209	0.0525	6.98672111	1.00875
7.61318889	0.06078125	6.98816222	1.0190625
7.57417	0.07046875	6.98636111	1.029375
7.62261333	0.0809375	6.98185889	1.03953125
7.54080222	0.09125	6.97411556	1.05
7.57159667	0.1015625	6.96042889	1.0603125
7.51085667	0.111875	6.94872333	1.070625
7.54291222	0.12203125	6.93161444	1.0809375
7.56920556	0.13234375	6.92441111	1.09125
7.59333778	0.1425	6.90784222	1.1015625
7.52035	0.15296875	6.89289556	1.111875
7.55132556	0.16328125	6.86750333	1.12203125
7.48284111	0.17359375	6.85579778	1.13234375
7.51417667	0.18390625	6.85075444	1.14265625
7.53524667	0.19421875	6.84355111	1.153125
7.46658222	0.204375	6.83616778	1.1634375
7.49413556	0.2146875	6.82968444	1.17375
7.52042889	0.225	6.82086	1.1840625
7.55176444	0.23546875	6.81113556	1.19421875

MB2%-SF150-2	
Esfuerzo (Mpa)	Deformación (%)
7.57175444	0.2459375
7.59498556	0.25625
7.61281444	0.2665625
7.64036778	0.276875
7.66089778	0.2871875
7.68268889	0.2975
7.70267778	0.3078125
7.72302889	0.318125
7.73995667	0.3284375
7.75742556	0.33875
7.96866889	0.34875
7.96668778	0.3590625
7.96254556	0.369375
7.95498222	0.3796875
7.94489778	0.38984375
7.92868889	0.4015625
7.30313667	0.41046875
7.40020444	0.42078125
7.46863778	0.43125
7.52176333	0.44140625
7.55778222	0.45171875
7.57921222	0.46203125
7.59199889	0.4721875
7.60388444	0.48265625
7.60928667	0.49296875
7.61523	0.50328125
7.61559	0.51359375
7.61775111	0.52390625
7.61306889	0.53421875
7.60028222	0.54453125
7.56318444	0.55421875
7.53184889	0.56453125
7.52860778	0.575
7.52500556	0.58578125
7.50663667	0.59609375
7.49511111	0.60609375
7.45549111	0.61671875

MB2%-SF150-2	
Esfuerzo (Mpa)	Deformación (%)
6.78772333	1.20453125
6.78142111	1.2146875
6.76719444	1.22515625
6.75602778	1.23546875
6.72793444	1.24578125
6.72631333	1.25609375
6.71658889	1.26640625
6.70596333	1.27671875
6.69677889	1.28703125
6.68237222	1.29734375
6.65499889	1.3078125
6.62816556	1.318125
6.60367333	1.32859375
6.58620556	1.33875
6.57918111	1.3490625
6.57035778	1.359375
6.56081222	1.3696875
6.55036778	1.38
6.54406444	1.3903125
6.53488	1.400625
6.52191333	1.4109375
6.51200778	1.42125
6.50426444	1.4315625
6.48733667	1.44171875
6.47563111	1.45203125
6.46716667	1.46234375
6.45276	1.47265625
6.44105444	1.483125
6.40071333	1.48984375
6.32723778	1.5046875
6.36361556	1.5140625
6.37946333	1.52671875
6.27789333	1.53515625
6.30364667	1.54453125
6.29824333	1.55515625
6.29770333	1.56546875
6.28923889	1.57578125

MB2%-SF150-2	
Esfuerzo (Mpa)	Deformación (%)
7.33159	0.631875
7.38201556	0.638125
7.39048	0.64796875
7.38831889	0.65796875
7.38093444	0.668125
7.38129556	0.6784375
7.38237556	0.68890625
7.37391111	0.699375
7.36400667	0.70953125
7.35878444	0.7196875
7.35086	0.73
7.35158	0.74046875
7.34707889	0.75078125
7.34095444	0.76109375
7.33681333	0.77140625
7.32834889	0.7815625
7.30475778	0.791875
7.29269222	0.8021875
7.28566778	0.81265625
7.28152556	0.82296875
7.27666333	0.8334375
7.27648333	0.84359375
7.26459778	0.85390625
7.24568889	0.86421875
7.21363333	0.874375
7.17419444	0.8846875
7.13403333	0.895
7.09261333	0.90703125
6.97591556	0.915625
6.99698667	0.92609375
7.00761222	0.93640625
7.01283444	0.9465625

MB2%-SF150-2	
Esfuerzo (Mpa)	Deformación (%)
6.27159111	1.58609375
6.24673889	1.59640625
6.20513778	1.60671875
6.16425778	1.61703125
6.12806	1.62734375
6.07835556	1.6378125
6.02613	1.648125
5.97066222	1.65859375
5.87125444	1.66875
5.84568111	1.6790625
5.82371111	1.68921875
5.80048	1.69953125
5.77706778	1.70984375
5.76032	1.72015625
5.73888889	1.73046875
5.72196111	1.7409375
5.69314667	1.75125
5.68054111	1.76140625
5.66739444	1.77171875
5.65748889	1.78203125
5.63425778	1.79234375
5.62381333	1.80265625
5.60940556	1.813125
5.59193667	1.8234375
5.57464889	1.83375
5.55862111	1.8440625
5.54151222	1.85421875
5.52584444	1.86453125
5.49631	1.87484375
5.47704111	1.88515625
5.44984778	1.893125

8.1.4 OL2%-SF50

Tabla 8-7. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF50-1

OL2%-SF50-1		OL2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
0	0	6.71513444	0.93890625
9.45211889	0.0153125	6.63589667	0.9490625
8.92643667	0.020625	6.58943333	0.959375
8.99433333	0.03078125	6.56061889	0.9696875
9.12939889	0.04109375	6.52136	0.98
9.24375556	0.05140625	6.50299111	0.99015625
9.32947889	0.06171875	6.47111444	1.00046875
9.39719	0.07203125	6.44968444	1.01078125
9.44959556	0.08234375	6.42213111	1.02109375
9.47761222	0.09265625	6.39043556	1.03140625
9.50436667	0.10296875	6.38107111	1.04171875
9.50688889	0.11328125	6.36018111	1.05203125
9.52579778	0.12359375	6.32848556	1.0625
9.51607344	0.13390625	6.31011667	1.07296875
9.51983733	0.14421875	6.28058111	1.08328125
9.23637111	0.15453125	6.23826111	1.09359375
9.27238889	0.16484375	6.19612	1.10390625
8.98460778	0.17515485	6.16766667	1.11421875
8.96389889	0.18546652	6.12066333	1.124375
8.93490444	0.19577733	6.06951778	1.1346875
8.92049667	0.20608715	6.05385	1.145
8.94318778	0.21639498	6.01170889	1.1553125
8.95867556	0.22669968	5.98343556	1.16562625
8.96263778	0.23699898	5.97353111	1.1759375
9.00748	0.24728927	5.94021444	1.18625125
9.01720333	0.25756443	5.90239556	1.1965625
9.03773444	0.26781425	5.83090111	1.20687625
8.93274222	0.27817779	5.80677	1.2171875
8.96461889	0.28831435	5.78804	1.22750125
9.00585889	0.29833277	5.77381222	1.2378125
9.03107111	0.30815447	5.75454333	1.24812625

OL2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)
9.05754444	0.31764931
9.08401778	0.32660247
9.10274556	0.33450779
9.11625222	0.34110069
9.13192111	0.34530672
9.14290556	0.34568299
9.18468667	0.34724137
9.19567111	0.35728129
9.20251556	0.36714297
9.19459111	0.37671063
9.18360667	0.38579402
9.16325556	0.3940818
9.15443222	0.40106721
9.13966444	0.40593283
9.12849889	0.40737917
8.85008222	0.4128125
8.83441556	0.423125
8.80722222	0.4334375
8.76129889	0.44375
8.68115889	0.4540625
8.64676333	0.464375
8.60660222	0.4746875
8.57760889	0.485
8.54753333	0.49515625
8.53060556	0.505625
8.48054111	0.5159375
8.41552889	0.52609375
8.39662	0.5365625
8.33449	0.54671875
8.29685111	0.55703125
8.25200889	0.5675
8.21257	0.5778125
8.16790778	0.588125
8.13891444	0.5984375
8.04454778	0.60875
8.00024556	0.6190625

OL2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)
5.73815556	1.2584375
5.71600444	1.26875
5.69187333	1.2790625
5.66558	1.289375
5.61677556	1.2996875
5.58147889	1.30984375
5.53303444	1.32015625
5.52204889	1.33046875
5.48567111	1.34078125
5.47594667	1.35109375
5.45001444	1.36140625
5.44263111	1.37171875
5.41309556	1.38203125
5.41471667	1.3925
5.38662333	1.4028125
5.38140111	1.41328125
5.34196111	1.42359375
5.32413222	1.43390625
5.26146222	1.44421875
5.22994556	1.454375
5.18744556	1.4646875
5.1761	1.475
5.14890667	1.4853125
5.13990222	1.495625
5.11847111	1.50578125
5.10352444	1.51625
5.08731667	1.52640625
5.08443556	1.53672
5.06570556	1.5471875
5.05472	1.5575
5.02914778	1.5678125
5.02752667	1.578125
5.01312	1.58859375
4.99619222	1.59890625
4.97926333	1.6090625
4.93874333	1.619375

OL2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)
7.99178111	0.629375
7.91668444	0.6396875
7.84609	0.64984375
7.79980778	0.66015625
7.77711556	0.67046875
7.75028333	0.68078125
7.72291	0.69109375
7.70165889	0.70140625
7.68329	0.71171875
7.64619222	0.72203125
7.58334111	0.73234375
7.55290556	0.7428125
7.53309556	0.75328125
7.50446222	0.76359375
7.43855	0.77390625
7.38632444	0.78421875
7.34796556	0.79453125
7.29483889	0.8046875
7.23703111	0.815
7.20317444	0.8253125
7.17039889	0.835625
7.12627667	0.8459375
7.08107444	0.85625
7.05928333	0.8665625
7.01678333	0.876875
6.93502222	0.8871875
6.89054111	0.8975
6.8891	0.9078125
6.86622889	0.918125
6.81166222	0.9284375

OL2%-SF50-1	
Esfuerzo (Mpa)	Deformación (%)
4.90992889	1.6296875
4.85968444	1.64
4.84653778	1.65015625
4.83483222	1.66046875
4.81898444	1.67078125
4.8089	1.68109375
4.79953556	1.69140625
4.79431222	1.70171875
4.77900556	1.7121875
4.76405778	1.7225
4.72065667	1.7328125
4.71759444	1.74328125
4.67707556	1.75359375
4.66663	1.76390625
4.63349333	1.77421875
4.61584556	1.784375
4.61458444	1.7946875
4.56361889	1.805
4.55605556	1.8153125
4.56127778	1.825625
4.52598111	1.8359375
4.52093778	1.84625
4.49032333	1.85640625
4.47897778	1.86671875
4.45484556	1.87703125
4.43161444	1.8875
4.41126444	1.8978125
4.39145444	1.908125
4.35039444	1.9109375

Tabla 8-8. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF50-2

OL2%-SF50-2		OL2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
0	0	8.16250444	1.1751575
10.7208444	0.01248763	8.13819333	1.185625
9.89765556	0.01953125	8.10073444	1.1959375
10.0213778	0.01984375	8.07138111	1.20625
10.1461789	0.02	8.08074444	1.2165625
10.2589133	0.0203125	8.0703	1.226875
10.3522	0.030625	8.05229111	1.2370325
10.4227944	0.0409375	8.01969556	1.24734375
10.4744789	0.05125	7.97989556	1.2576575
10.49555	0.0515625	7.92875	1.26796875
10.4676356	0.0625	7.88498889	1.2782825
9.60843444	0.0721875	7.85581444	1.28859375
9.72459	0.0825	7.82970222	1.2989075
9.84795222	0.0928125	7.80629111	1.30921875
9.96501	0.103125	7.77531556	1.3195325
10.0737822	0.11359375	7.75568556	1.32984375
10.1211456	0.12390625	7.73317444	1.3401575
10.2074089	0.13421875	7.70904222	1.35046875
10.2585533	0.1446875	7.69409556	1.3607825
10.2911489	0.15484375	7.67086333	1.37109375
10.3073578	0.16515625	7.65429556	1.3814075
10.3219444	0.17546875	7.61305556	1.39171875
10.7665833	0.19546875	7.55614778	1.4020325
10.7334478	0.20578125	7.56911444	1.41234375
10.65997	0.21609375	7.56677333	1.42250125
10.6624922	0.22640625	7.55092556	1.4328125
10.6626722	0.23671875	7.52427111	1.44312625
10.6534867	0.24703125	7.49401667	1.4534375
10.638	0.25734375	7.45835889	1.46375125
10.5996411	0.26765625	7.43404778	1.47421875
10.6019811	0.2778125	7.40073111	1.48453125
10.5776711	0.288125	7.33175778	1.49484375
10.5780311	0.2984375	7.29970111	1.50515625

OL2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
10.5636222	0.30875
10.5556989	0.3190625
10.1218667	0.32953125
10.1099811	0.33968875
10.1767933	0.35
10.2625156	0.36031375
10.29205	0.370625
10.3307689	0.38093875
10.39452	0.39140625
10.4184722	0.40156375
10.4163111	0.411875
10.37561	0.42218875
10.2191144	0.4325
10.1337522	0.44281375
10.1312311	0.453125
10.1229467	0.46343875
10.1081789	0.47375
10.0982756	0.48406375
10.08891	0.494375
10.0770244	0.50484375
10.0426278	0.51515625
10.0174144	0.525625
9.99472333	0.5359375
9.97527444	0.54625
9.94934111	0.5565625
9.90432	0.56671875
9.84399	0.57703125
9.77753667	0.58734375
9.69325556	0.59765625
9.58538333	0.60796875
9.54504444	0.61828125
9.52109111	0.62859375
9.49281778	0.63890625
9.46832667	0.64921875
9.44617444	0.65953125
9.42528444	0.66984375
9.40061333	0.68015625

OL2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
7.27647	1.515625
7.27737111	1.5259375
7.27521	1.53640625
7.23721111	1.5465625
7.21524	1.556875
7.17346	1.5671875
7.11691222	1.5775
7.13636111	1.5878125
7.14050333	1.59796875
7.11222889	1.60828125
7.05460111	1.61859375
7.00849889	1.62890625
7.03587222	1.63921875
7.05046	1.64953125
6.99121	1.65984375
6.95465333	1.67015625
6.95069	1.68046875
6.97968444	1.6909375
6.94528778	1.70125
6.91377222	1.71140625
6.88477778	1.72171875
6.84245778	1.73187625
6.82624889	1.7421875
6.84714	1.75250125
6.84353778	1.7628125
6.83543444	1.77328125
6.80229778	1.78359375
6.74503	1.79375125
6.71171333	1.8040625
6.71981667	1.81453125
6.73980667	1.82484375
6.71243333	1.8353125
6.67155333	1.845625
6.64111778	1.8559375
6.61032333	1.86625125
6.58853333	1.8765625
6.60059778	1.88687625

OL2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
9.38386444	0.69046875
9.37251889	0.70078125
9.35685111	0.71109375
9.34118333	0.72140625
9.30390444	0.73171875
9.26824778	0.74203125
9.24987889	0.7521875
9.23439111	0.7625
9.19351111	0.7728125
9.16379556	0.783125
9.13570222	0.7934375
9.10742889	0.80375
9.09140111	0.8140625
9.07789444	0.824375
9.06907	0.83484375
9.06294667	0.84515625
9.04655889	0.855625
9.02314778	0.86593875
9.01216222	0.87625
8.98947111	0.88656375
8.96714	0.896875
8.91455333	0.90703125
8.86124778	0.91734375
8.82559111	0.92765625
8.77822778	0.93796875
8.75373556	0.94828125
8.73320556	0.95859375
8.72618111	0.96890625
8.70151	0.9790625
8.68962333	0.989375
8.67467667	0.99984375
8.66603222	1.01015625
8.64442111	1.02046875
8.62479222	1.03078125
8.61884889	1.04125
8.58715333	1.05156375

OL2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
6.57970889	1.8971875
6.56656222	1.90734375
6.53468667	1.91765625
6.48444111	1.92796875
6.46661333	1.93828125
6.45274556	1.94859375
6.44626333	1.95890625
6.41853	1.9690625
6.39511778	1.979375
6.37494778	1.9896875
6.36396333	2.00015625
6.33496889	2.01046875
6.31101667	2.02078125
6.28706556	2.03125125
6.26041222	2.0415625
6.22907667	2.05171875
6.19125778	2.06203125
6.15938222	2.07234375
6.11868222	2.0825
6.07131889	2.09296875
6.06195444	2.09390625
6.67155333	1.845625
6.64111778	1.8559375
6.61032333	1.86625125
6.58853333	1.8765625
6.60059778	1.88687625
6.57970889	1.8971875
6.56656222	1.90734375
6.53468667	1.91765625
6.48444111	1.92796875
6.46661333	1.93828125
6.45274556	1.94859375
6.44626333	1.95890625
6.41853	1.9690625
6.39511778	1.979375
6.37494778	1.9896875

OL2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
8.56518333	1.06171875
8.52718333	1.07203125
8.50071111	1.08234375
8.45334778	1.0926575
8.42093222	1.10296875
8.38617444	1.1132825
8.37032778	1.12359375
8.31143889	1.1339075
8.25200889	1.1440625
8.21437	1.1545325
8.19708222	1.16484375

OL2%-SF50-2	
Esfuerzo (Mpa)	Deformación (%)
6.36396333	2.00015625
6.33496889	2.01046875
6.31101667	2.02078125
6.28706556	2.03125125
6.26041222	2.0415625
6.22907667	2.05171875
6.19125778	2.06203125
6.15938222	2.07234375
6.11868222	2.0825
6.07131889	2.09296875
6.06195444	2.09390625

8.1.5 OL2%-SF100

Tabla 8-9. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF100-1

OL2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
0	0
11.2173444	0.0153125
11.2160889	0.020625
9.35084667	0.0326556
9.82033667	0.04093627
10.1354911	0.05124744
10.3877956	0.06171381
9.60336111	0.07202314
9.80920222	0.07232646
9.98550889	0.072626
10.1582144	0.07291213
9.82335556	0.08318172
9.98399333	0.08357193
9.64193	0.08750496
9.79860778	0.08831728

OL2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
10.0555944	0.808125
10.04587	0.81859375
9.99292333	0.82890625
10.00877	0.83922
9.95654556	0.84953125
9.97959556	0.85984375
9.91404444	0.87000125
9.92178778	0.88047
9.88757222	0.890625
9.82255889	0.9009375
9.84525111	0.91125125
9.75628778	0.92156375
9.78005889	0.931875
9.71054444	0.9421875
9.65777889	0.95250125

OL2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
9.94826111	0.09271631
10.0989944	0.09322474
10.2477489	0.09382439
10.3891167	0.09807376
10.5328278	0.10077656
10.6628522	0.10261258
10.78135	0.10396983
10.88418	0.10671875
10.9317244	0.1170325
11.04536	0.12734375
11.0806556	0.13765625
11.1577333	0.148125
11.1973556	0.1584375
11.2099556	0.1689075
11.2431	0.17921875
11.2953222	0.1895325
11.3088333	0.19984375
11.3306222	0.21
11.3207111	0.2203125
11.3371	0.230625
11.3635778	0.2409375
11.3661	0.25125
11.3673556	0.2615625
11.3909444	0.27171875
11.3837444	0.28203125
11.3848222	0.29234375
11.4010333	0.30265625
10.4692567	0.3132825
10.6799611	0.32328125
10.8346567	0.33359375
10.94271	0.3440625
10.9834089	0.35421875
11.0278911	0.36453125
11.0790367	0.37484375
11.1132556	0.38515625
11.1642222	0.39546875

OL2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
9.51767	0.96281375
9.46040222	0.973125
9.44311333	0.98359375
9.40745556	0.99390625
9.36387444	1.00422
9.36963778	1.01453125
9.30804667	1.0246875
9.32803667	1.03500125
9.25690222	1.04531375
9.29616	1.055625
9.20971889	1.06578125
9.26266444	1.076095
9.20665778	1.08656375
9.21368111	1.09671875
9.20467667	1.10703125
9.16451667	1.117345
9.15713333	1.12781375
9.13426222	1.138125
9.08365667	1.14859375
9.10364667	1.15890625
9.03161111	1.16922
9.05250222	1.17953125
8.98100667	1.18984375
8.95687444	1.20015625
8.93022222	1.21031375
8.91077222	1.220625
8.87007222	1.2309375
8.85224444	1.24125
8.82343	1.25156375
8.77210444	1.261875
8.78921222	1.2721875
8.72708222	1.2825
8.75193444	1.29281375
8.72798222	1.303125
8.70745222	1.3134375
8.73734667	1.32390625

OL2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
11.2081556	0.40578125
11.1917667	0.41609375
11.2121222	0.42640625
11.2241889	0.43671875
11.1577333	0.44703125
11.1865444	0.45734375
11.1219	0.46765625
11.0916422	0.47812625
11.08516	0.4884375
11.0902022	0.4989075
11.0947033	0.50921875
11.0691311	0.51953125
11.04716	0.52984375
11.0235689	0.54000125
10.9540544	0.55031375
10.1960633	0.5609375
10.3087989	0.5709375
10.3080767	0.58125125
10.2589133	0.59156375
10.2542311	0.601875
10.2376622	0.6121875
10.0673	0.62250125
10.15104	0.63281375
10.1643667	0.643125
10.1937222	0.6534375
10.19012	0.66375125
10.2079489	0.67422
10.20903	0.684375
10.2016456	0.6946875
10.1683289	0.70500125
10.1993056	0.71531375
10.1368133	0.72546875
10.1915611	0.73578125
10.1477989	0.746095
10.1586044	0.7564075
10.14978	0.76671875
10.1125011	0.77703125

OL2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)
8.66783333	1.33406375
8.71285444	1.3445325
8.62245111	1.3546875
8.66261	1.364845
8.60066	1.3751575
8.61596778	1.38546875
8.62533222	1.39578125
8.55923889	1.406095
8.60102	1.41656375
8.50575333	1.426875
8.52736444	1.43703125
8.56446222	1.4475
8.46379222	1.45781375
8.50863556	1.468125
8.45010667	1.47859375
8.43029667	1.48890625
8.47513889	1.49937625
8.36708556	1.5095325
8.38617444	1.51984375
8.42489444	1.53015625
8.36222222	1.54047
8.36924667	1.55062625
8.39788111	1.5609375
8.30639556	1.57125
8.35664111	1.58156375
8.29018778	1.59187625
8.28964778	1.60203125
8.33413	1.6125
8.24246444	1.62281375
8.28676667	1.63296875
8.27325889	1.6434375
8.24120333	1.65375
8.28298444	1.66406375
8.21401	1.67437625
8.25182889	1.6846875
8.16988889	1.695
8.17727222	1.7051575

OL2%-SF100-1		OL2%-SF100-1	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
10.1420367	0.787345	8.21257	1.71562625
10.0736022	0.79781375	8.10325667	1.7259375

Tabla 8-10. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF100-2

OL2%-SF100-2		OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
0	0	4.53678556	2.20735
10.8888567	0.0143125	4.51031333	2.2176625
10.7552378	0.020625	4.47645667	2.228125
10.8207889	0.0309375	4.42171	2.2382875
10.8701344	0.04125	4.38785333	2.2507875
10.9297433	0.0515625	4.37794778	2.259225
10.9419889	0.061875	4.34139	2.2689125
10.98431	0.0721875	4.31978	2.279375
11.0116833	0.0825	4.30339111	2.2896875
11.02663	0.0928125	4.27727889	2.3
11.0457189	0.103125	4.26107111	2.3103125
11.06535	0.1134375	4.24108111	2.320625
11.0801156	0.1236	4.21748889	2.3309375
11.08804	0.1339125	4.20488333	2.34125
11.1260444	0.144375	4.18255222	2.351725
11.1301778	0.1545375	4.15355778	2.3620375
11.1330667	0.16485	4.12996667	2.37235
11.1548556	0.1751625	4.10673444	2.3826625
11.1485556	0.185475	4.08152222	2.3928125
11.1456667	0.1959375	4.05396889	2.403125
11.1750222	0.20625	4.01777111	2.4134375
11.1741222	0.216725	3.97329	2.42375
11.1876333	0.2270375	3.92988778	2.4340625
11.1591778	0.2375	3.87820333	2.444225
11.1366667	0.2478125	3.83588222	2.4545375
11.0977656	0.257975	3.81445222	2.46485
11.0648089	0.2682875	3.78887889	2.4753125
11.0030389	0.2786	3.76240556	2.485625

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
10.9243411	0.2889125
10.8314156	0.299225
10.7235411	0.3095375
10.5391311	0.32
10.3349111	0.3301625
10.2816044	0.340475
10.2392844	0.3507875
10.1834556	0.3611
10.0831478	0.3714125
10.0105711	0.381725
9.95492444	0.3921875
9.77213444	0.4025
9.69775778	0.4128125
9.64607444	0.422975
9.59348667	0.4332875
9.52883556	0.4436
9.42546556	0.45375
9.36027333	0.4640625
9.31219	0.474375
9.26212444	0.4846875
9.21836222	0.495
9.18180556	0.5053125
9.15029	0.515625
9.11427222	0.5259375
9.08041556	0.5364125
9.03647444	0.546725
9.00838	0.5571875
8.97380333	0.5675
8.92968111	0.5778125
8.88736111	0.588125
8.83747667	0.5984375
8.78020889	0.6086
8.70997333	0.6189125
8.69448556	0.629225
8.66639222	0.6395375
8.63451667	0.64985
8.59453667	0.6601625

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
3.73485222	2.4959375
3.71702333	2.50625
3.69433333	2.5165625
3.67578333	2.5270375
3.66011556	2.53735
3.64390778	2.5476625
3.62211667	2.557975
3.60158778	2.5682875
3.58519889	2.5784375
3.56773	2.5889125
3.59258333	2.5996875
3.57025222	2.6090625
3.48146889	2.617975
3.39826778	2.6365625
3.40168889	2.640625
3.42618111	2.650475
3.42167889	2.6609375
3.39808778	2.6714125
3.37989889	2.681725
3.36297	2.6920375
3.34460111	2.70235
3.32821333	2.7126625
3.31632778	2.722975
3.29831889	2.7332875
3.28337111	2.7436
3.27526667	2.7539125
3.25437667	2.764225
3.24375111	2.7745375
3.23060556	2.78485
3.22142111	2.7951625
3.20683333	2.805475
3.19224667	2.8157875
3.16775444	2.8261
3.15136667	2.8365625
3.12921556	2.846875
3.11751	2.8571875
3.0986	2.8676625

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
8.55653889	0.670475
8.53636889	0.6807875
8.47639889	0.6911
8.40652444	0.7014125
8.36114222	0.711725
8.31251889	0.7221875
8.31215778	0.7325
8.29991222	0.7428125
8.24642667	0.752975
8.17475111	0.7632875
8.13585222	0.7736
8.16430556	0.7839125
8.12198444	0.794225
8.04490778	0.804375
7.98187556	0.81485
7.99340111	0.8251625
7.99106111	0.835475
7.92100667	0.8457875
7.83906667	0.8561
7.78233889	0.8665625
7.72813222	0.876875
7.65825778	0.88735
7.58910333	0.8976625
7.51634778	0.907975
7.44917556	0.9182875
7.46484222	0.9286
7.40739444	0.93875
7.34490333	0.9490625
7.26512444	0.959375
7.25179889	0.9696875
7.26278333	0.98
7.21398	0.9901625
7.13222	1.000475
7.07801333	1.0107875
7.11078889	1.02125
7.07981333	1.0315625

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
3.08653444	2.8778125
3.07554889	2.888125
3.05195778	2.8984375
3.03791111	2.90875
3.02026222	2.9190625
3.00477444	2.929375
2.98280333	2.9395375
2.96875667	2.94985
2.95741111	2.9601625
2.94210333	2.970475
2.92841667	2.9807875
2.91166889	2.9911
2.89654111	3.0015625
2.88915778	3.011875
2.87565111	3.0221875
2.85944333	3.0325
2.84611667	3.0428125
2.83171	3.053125
2.81622111	3.0632875
2.80055444	3.0736
2.78434667	3.0839125
2.76813778	3.094225
2.75085	3.1045375
2.73104	3.11485
2.71915444	3.1251625
2.70114556	3.135475
2.68439667	3.1459375
2.67287111	3.15625
2.65936444	3.1665625
2.64009556	3.1770375
2.62496778	3.18735
2.60822	3.1976625
2.59885556	3.207975
2.57760444	3.218125
2.55797556	3.2284375
2.54464889	3.23875

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
7.0103	1.041875
6.97698333	1.0521875
7.01534222	1.0626625
6.96131556	1.0728125
6.92277667	1.082975
6.85974556	1.0932875
6.85578444	1.1036
6.85686444	1.1139125
6.82282778	1.124225
6.76736	1.1345375
6.69028222	1.14485
6.68181889	1.1551625
6.71639556	1.165475
6.65912778	1.1757875
6.59933778	1.1861
6.59015333	1.1965625
6.62815222	1.2070375
6.57088333	1.21735
6.53324556	1.2275
6.49506667	1.2378125
6.47273667	1.248125
6.49542667	1.2584375
6.46247111	1.26875
6.44266111	1.2790625
6.41582778	1.289375
6.35351778	1.2995375
6.30669444	1.30985
6.34109111	1.3201625
6.35171667	1.330625
6.29048556	1.3407875
6.24906667	1.3511
6.24186222	1.3614125
6.27572	1.371875
6.22511444	1.3821875
6.18981778	1.3925
6.15091778	1.4028125
6.16640556	1.413125

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
2.51709444	3.2490625
2.49710556	3.259375
2.47693556	3.2696875
2.45730556	3.27985
2.43497444	3.2901625
2.41786667	3.300475
2.38509	3.3107875
2.3633	3.32125
2.25254556	3.3314125
2.23543667	3.341725
2.21778778	3.3520375
2.20356111	3.36235
2.18789333	3.3726625
2.17186556	3.382975
2.15781889	3.3932875
2.14827444	3.4034375
2.13981	3.41375
2.12396222	3.4240625
2.11513778	3.434375
2.09929	3.4446875
2.09118667	3.455
2.07876	3.4653125
2.06993556	3.4757875
2.06093111	3.4861
2.05246667	3.4965625
2.04040111	3.506875
2.02761444	3.51735
2.02113222	3.5276625
2.00996667	3.537975
1.99934111	3.548125
1.98979667	3.5584375
1.98151222	3.56875
1.97016667	3.5790625
1.95936111	3.589375
1.94675556	3.5996875
1.93667	3.61
1.92874667	3.6201625

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
6.15956222	1.4234375
6.11526111	1.4336
6.05403	1.4439125
6.04196444	1.454225
6.06699667	1.4645375
6.02755778	1.47485
5.95624222	1.4851625
5.95678333	1.495475
5.97821333	1.5059375
5.93445111	1.51625
5.87286222	1.5265625
5.84692889	1.536875
5.83108111	1.54735
5.84927	1.5576625
5.80821	1.567975
5.77507444	1.578125
5.72518889	1.5884375
5.69475444	1.59875
5.70862111	1.6090625
5.69745556	1.619375
5.68142778	1.6296875
5.64973222	1.63985
5.60921222	1.6501625
5.55464556	1.660475
5.53303444	1.6707875
5.53051333	1.6811
5.52151	1.6914125
5.52511111	1.701875
5.50710222	1.7121875
5.46928333	1.7225
5.44983333	1.7328125
5.42822333	1.743125
5.39364667	1.7532875
5.35943	1.7636
5.31008556	1.7739125
5.31080556	1.784225

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
1.91668	3.630475
1.90731556	3.6407875
1.89543	3.6511
1.88516444	3.6615625
1.87291889	3.671875
1.86049333	3.6821875
1.85112778	3.6925
1.83888222	3.7028125
1.82375444	3.713125
1.81565111	3.7232875
1.80664667	3.7336
1.79458111	3.7439125
1.78395556	3.754225
1.77945333	3.7645375
1.76990889	3.77485
1.76018333	3.7851625
1.75009889	3.795475
1.73641222	3.8057875
1.72848778	3.8161
1.71768333	3.8265625
1.70327556	3.836875
1.69319111	3.8471875
1.68346556	3.8576625
1.6714	3.867975
1.66347667	3.878125
1.65231111	3.8884375
1.64780889	3.89875
1.64510667	3.9090625
1.63358111	3.919375
1.62853889	3.9296875
1.62097556	3.93985
1.61449222	3.9501625
1.60782889	3.960475
1.60242667	3.9707875
1.59450222	3.9811
1.58351667	3.9915625

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
5.31873	1.7945375
5.30162111	1.80485
5.28055111	1.8151625
5.24525333	1.825475
5.21824111	1.8357875
5.18384333	1.8461
5.16025222	1.8565625
5.14422444	1.866875
5.19861111	1.875
5.19500889	1.8886
5.02032333	1.9001625
4.97926333	1.9082875
5.03509	1.9182875
5.01005778	1.92875
5.00033333	1.9390625
4.98916778	1.949375
4.96521667	1.9596875
4.93982333	1.96985
4.92073444	1.9801625
4.90110556	1.990475
4.88741778	2.0007875
4.87157	2.0111
4.85464222	2.0215625
4.83573333	2.031875
4.81880444	2.0421875
4.80565778	2.0526625
4.79107111	2.0628125
4.78062556	2.073125
4.77018111	2.0834375
4.74604889	2.0936
4.72335778	2.1039125
4.69436333	2.114225
4.66392889	2.1245375
4.63925667	2.13485
4.62430889	2.1451625
4.60684	2.155475
4.59963667	2.1657875

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
1.57685333	4.001875
1.56875	4.0121875
1.55974556	4.0225
1.55596333	4.0328125
1.54461778	4.043125
1.53435333	4.0532875
1.52282778	4.0636
1.51238222	4.0739125
1.50427778	4.084225
1.49311222	4.0945375
1.48843	4.10485
1.47906556	4.1151625
1.47348333	4.125475
1.46501889	4.1357875
1.45529444	4.1461
1.44178778	4.1565625
1.43602444	4.166875
1.42413889	4.17735
1.40288778	4.1876625
1.39316333	4.1978125
1.38181778	4.208125
1.37317333	4.2184375
1.36344889	4.22875
1.35660556	4.2390625
1.35030222	4.249375
1.34363889	4.2595375
1.33787667	4.26985
1.32040778	4.28
1.31626556	4.290475
1.31356444	4.3007875
1.30546	4.3111
1.29933778	4.3214125
1.29177444	4.331875
1.28240889	4.3421875
1.27628667	4.3525
1.26512111	4.3626625
1.25737667	4.372975

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
4.58288889	2.17625
4.56614111	2.186725
4.55425444	2.1970375

OL2%-SF100-2	
Esfuerzo (Mpa)	Deformación (%)
1.24945333	4.3832875
1.24080889	4.3936
0.35555556	125.991625

8.1.6 OL2%-SF150

Tabla 8-11. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF150-1

OL2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)
1.78647667	0
9.88505	0.012
9.06816889	0.022625
9.06060556	0.032625
9.18540667	0.0429375
9.24483556	0.05325
9.33578111	0.0635625
9.47426889	0.07371875
9.55585	0.08434375
9.62590333	0.0948125
9.67830889	0.10465625
9.72693333	0.1148125
9.77951889	0.12528125
9.84327	0.135125
9.87784667	0.14590625
9.91098222	0.1560625
9.80653222	0.16934375
9.86848222	0.17684375
9.90035778	0.18746875
9.84453	0.19778125
9.92034667	0.20809375
9.9072	0.21840625
9.92827111	0.22871875

OL2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)
8.03464222	0.898875
8.04850889	0.9091875
8.05373111	0.92090625
8.04472778	0.92996875
7.89111222	0.9398125
7.98061556	0.9504375
7.84374889	0.96075
7.81205333	0.96825
7.75226333	0.9816875
7.80719111	0.9923125
7.64006889	1.00246875
7.63520556	1.01278125
7.67986889	1.0229375
7.65303444	1.03340625
7.47510778	1.05325
7.47636778	1.0573125
7.27845111	1.06371875
7.49023556	1.07403125
7.50212111	1.08465625
7.34022111	1.0948125
7.39821	1.105125
7.42828444	1.11559375
7.27430889	1.12590625

OL2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)
9.92917222	0.23903125
9.92250889	0.24934375
9.95942667	0.25965625
9.90143778	0.270125
9.91926778	0.28028125
9.95186333	0.29090625
9.89999778	0.30121875
9.94159778	0.31575
9.76619111	0.32965625
9.37269889	0.333875
9.24267444	0.34153125
9.52433333	0.3523125
9.67614778	0.362625
9.69613778	0.37309375
9.71198556	0.38325
9.77951889	0.3935625
9.80761333	0.403875
9.79392444	0.4141875
9.84903222	0.4245
9.79446667	0.4348125
9.81499556	0.445125
9.79428556	0.4554375
9.81625667	0.46575
9.72423111	0.47621875
9.77375556	0.48653125
9.67416667	0.49684375
9.69469778	0.50715625
9.6205	0.51746875
9.53225667	0.527625
9.58358222	0.53809375
9.50344333	0.54825
9.47048667	0.55871875
9.42204222	0.568875
9.30984778	0.5791875
9.38656556	0.5895
9.25149889	0.5998125
9.29436	0.61028125

OL2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)
7.31969111	1.13621875
7.33031667	1.1466875
7.20623556	1.15684375
7.23469	1.16715625
7.22028222	1.17746875
7.08935778	1.18778125
7.13780222	1.1979375
7.10682667	1.20840625
6.97860444	1.21871875
7.04613667	1.228875
7.02524667	1.23934375
6.89270111	1.24965625
6.97662333	1.2598125
6.82372889	1.27028125
6.88675889	1.28075
6.73206333	1.2910625
6.79455333	1.30153125
6.64958333	1.3116875
6.71711667	1.32215625
6.58673222	1.3323125
6.64093778	1.34278125
6.50641222	1.3529375
6.57232444	1.36325
6.44572333	1.3735625
6.49164556	1.38371875
6.36288222	1.3941875
6.42195111	1.40434375
6.30795556	1.4148125
6.35009556	1.42496875
6.35621889	1.4354375
6.25681	1.44559375
6.30849556	1.4560625
6.18819667	1.466375
6.24996556	1.4766875
6.18513444	1.487
6.16568444	1.4973125
6.21016778	1.507625

OL2%-SF150-1		OL2%-SF150-1	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
9.19567111	0.6204375	6.11436	1.51778125
9.20917778	0.63090625	6.13867222	1.52809375
9.11877444	0.64121875	6.04070333	1.53840625
9.06348667	0.6516875	6.05475111	1.54871875
9.05250222	0.662	6.07708111	1.55903125
8.99235111	0.6723125	5.97965444	1.56934375
8.95255222	0.68371875	6.03494111	1.57965625
8.95579444	0.69184375	5.88690778	1.58996875
8.90645	0.70278125	5.93967444	1.60028125
8.84558	0.71903125	5.92310556	1.61075
8.82901222	0.725125	5.84170667	1.6210625
8.72834333	0.733875	5.91194	1.63153125
8.83729556	0.7445	5.78011556	1.64184375
8.73482556	0.75090625	5.80893	1.65215625
8.70619222	0.7648125	5.84891	1.66246875
8.48378333	0.7754375	5.72194778	1.67278125
8.44002111	0.78575	5.75850556	1.6829375
8.47315778	0.7960625	5.73689556	1.69340625
8.36816556	0.80621875	5.68773111	1.7035625
8.25182889	0.827625	5.70483889	1.713875
8.18069444	0.83309375	5.61083333	1.7241875
8.25993333	0.83715625	5.63208333	1.7345
8.25777222	0.847	5.65351333	1.7448125
8.18177444	0.857625	5.54239889	1.755125
8.21581111	0.8679375	5.59012333	1.7654375
8.08866889	0.87825	5.52042889	1.77575
8.14215444	0.8885625	8.03464222	0.898875

Tabla 8-12. Valores de carga y deformación para los ensayos a tracción directa de la dosificación OL2%-SF150-2

OL2%-SF150-2		OL2%-SF150-2	
Esfuerzo (Mpa)	Deformación (%)	Esfuerzo (Mpa)	Deformación (%)
0	0	7.22550556	1.08315625
10.3005411	0.013625	7.22514556	1.09346875
9.82526111	0.033625	7.10646667	1.10378125

9.92124778	0.0439375
10.0500111	0.10425
10.1598656	0.1145625
10.2454078	0.124875
10.2943911	0.1351875
10.3676867	0.1455
10.3781333	0.18596875
10.4128889	0.19628125
10.39326	0.20659375
10.3979422	0.2170625
10.4026233	0.227375
10.3628244	0.2376875
10.33311	0.248
10.3421144	0.25815625
10.2956511	0.26846875
10.2219956	0.27878125
10.2565733	0.28909375
10.2245167	0.29940625
10.1404167	0.30971875
10.1832756	0.32003125
10.13033	0.33034375
10.0563133	0.34065625
10.0447889	0.35096875
10.0147133	0.36128125
9.91530444	0.37159375
9.89567556	0.3820625
9.88739111	0.39221875
9.80797222	0.40253125
9.77735778	0.41284375
9.74332111	0.42315625
9.63022444	0.43346875
9.67939	0.44378125
9.53982	0.4539375
9.60105	0.46425
9.45373889	0.4745625
9.51947111	0.484875
9.3736	0.49534375
9.32767667	0.50565625
9.32029333	0.51596875

7.17129889	1.11409375
7.10556667	1.12425
7.04469667	1.13471875
6.95267111	1.144875
7.02452667	1.15534375
6.98310667	1.16565625
6.88261667	1.176125
6.82588889	1.1864375
6.83327222	1.19675
6.87667444	1.2070625
6.74484889	1.217375
6.81994667	1.2276875
6.72900222	1.238
6.71225333	1.24846875
6.72936222	1.258625
6.62455	1.2689375
6.62563111	1.27925
6.60366	1.2895625
6.50389111	1.29971875
6.52712222	1.3101875
6.55503667	1.3205
6.39349667	1.33065625
6.45941	1.341125
6.47633778	1.3514375
6.36846556	1.36175
6.39295667	1.3720625
6.36936556	1.382375
6.32830444	1.3926875
6.34415333	1.40284375
6.24420333	1.41315625
6.26959667	1.42346875
6.20080222	1.43378125
6.13471	1.44409375
6.14101333	1.45440625
6.01189	1.4645625
6.08986778	1.47503125
5.93229	1.48534375
5.98307556	1.49565625
5.98019444	1.50596875

9.17262	0.5264375
9.09878444	0.53675
9.11391222	0.5470625
9.00441778	0.557375
9.02674889	0.5676875
8.91725556	0.578
8.96281778	0.5883125
8.84413889	0.598625
8.89078222	0.6089375
8.75427556	0.61909375
8.79983778	0.6295625
8.71951778	0.63971875
8.71519667	0.65003125
8.74203	0.66034375
8.59309667	0.67065625
8.64460222	0.681125
8.56716333	0.6914375
8.51745889	0.70175
8.56752333	0.7120625
8.4357	0.722375
8.45208667	0.73253125
8.34385333	0.74284375
8.25705111	0.75315625
8.29577	0.76346875
8.19600111	0.77378125
8.19582111	0.78409375
8.06813889	0.79440625
8.14953889	0.80471875
7.98439778	0.81503125
8.01843444	0.82534375
8.09263111	0.83565625
7.89093222	0.84596875
7.95090111	0.8564375
7.96692889	0.86675
7.81763556	0.8770625
7.82015667	0.88753125
7.865	0.89784375
7.67302444	0.908
7.71174333	0.9183125

5.88780889	1.5164375
5.94741778	1.52675
5.84224667	1.53721875
5.87898444	1.547375
5.75652444	1.5576875
5.81163222	1.568
5.69961667	1.5783125
5.76516889	1.588625
5.64000667	1.5989375
5.68466889	1.60925
5.61605556	1.6195625
5.61839667	1.629875
5.51250444	1.64003125
5.56599111	1.65034375
5.50422111	1.66065625
5.53231444	1.671125
5.45217556	1.6814375
5.44443111	1.69175
5.36123	1.7020625
5.38896444	1.712375
5.40175	1.72253125
5.34034	1.733
5.35042556	1.74315625
5.26398333	1.75346875
5.30684444	1.76378125
5.2168	1.77409375
5.24453333	1.78440625
5.12711556	1.7945625
5.21103667	1.80503125
5.13071778	1.81534375
5.09686111	1.82565625
5.17537889	1.836125
5.04319444	1.8464375
5.08245333	1.85675
5.00429556	1.8670625
5.04139333	1.87753125
4.97638222	1.8876875
4.98826778	1.898
4.91118889	1.9083125

7.71606667	0.928625
7.59144444	0.9389375
7.62728222	0.94925
7.48897444	0.95940625
7.50446222	0.96971875
7.53003444	0.98003125
7.46196111	0.99034375
7.43296667	1.0008125
7.32365333	1.01096875
7.34310333	1.0214375
7.37786	1.03175
7.34688556	1.0420625
7.28205333	1.052375
7.34292222	1.0626875
7.25287889	1.07284375

4.93640222	1.918625
4.84635778	1.9289375
4.91749333	1.93925
4.82600889	1.94940625
4.84113556	1.959875
4.70570889	1.97003125
4.78368778	1.98034375
4.76279778	1.99065625
4.73344222	2.001125
4.71255222	2.0114375
4.70156667	2.02175
4.63871556	2.0320625
4.67995667	2.04221875
4.62665	2.05253125
4.58775111	2.05628125

Bibliografía

- Abellán-García, J. (2020a). Comparison of artificial intelligence and multivariate regression in modeling the flexural behavior of UHPFRC. *Dyna*, 87(214), 239–248. <https://doi.org/http://doi.org/10.15446/dyna.v87n214.86172>
- Abellán-García, J. (2020b). *Dosage optimization and seismic retrofitting applications of Ultra-HighPerformance Fiber Reinforced Concrete (UHPFRC)*. Universidad Politécnica de Madrid.
- Abellán-García, J. (2020c). Four-layer perceptron approach for strength prediction of UHPC. *Construction and Building Materials*, 256. <https://doi.org/10.1016/j.conbuildmat.2020.119465>
- Abellán-García, J., Fernández-Gómez, J. A., Torres-Castellanos, N., & Núñez-López, A.

- M. (2020). Machine Learning Prediction of Flexural Behavior of UHPFRC. In P. Serna, A. Llano-Torre, J. R. Martí-Vargas, & J. Navarro-Gregori (Eds.), *Fibre Reinforced Concrete: Improvements and Innovations. BEFIB 2020*. (Vol. 4, Issue September, pp. 570–583). RILEM Bookseries. https://doi.org/10.1007/978-3-030-58482-5_52
- Abellán-García, J., Fernández-Gómez, J., & Torres-Castellanos, N. (2020). Properties prediction of environmentally friendly ultra-high-performance concrete using artificial neural networks. *European Journal of Environmental and Civil Engineering*, *0*(0), 1–25. <https://doi.org/10.1080/19648189.2020.1762749>
- Abellán-García, J., Fernández-Gómez, J., Torres-Castellanos, N., & Núñez-López, A. (n.d.). Tensile behavior of normal strength steel fiber green UHPFRC. *ACI Materials Journal*.
- Abellán-García, J., Nuñez-Lopez, A., & Arango-Campo, S. (2020). Pedestrian Bridge over Las Vegas Avenue in Medellín. First Latin American Infrastructure in UHPFRC. In P. Serna, A. Llano-Torre, J. R. Martí-Vargas, & J. Navarro-Gregori (Eds.), *BEFIB 2020* (Issue September, pp. 864–872). RILEM Bookseries. https://doi.org/https://doi.org/10.1007/978-3-030-58482-5_76
- Abellán-García, J., Núñez-López, A., Torres-Castellanos, N., & Fernández-Gómez, J. (2019). Effect of FC3R on the properties of ultra-high-performance concrete with recycled glass. *Dyna*, *86*(211), 84–92. <https://doi.org/10.15446/dyna.v86n211.79596>
- Abellán-García, J., Núñez-López, A., Torres-Castellanos, N., & Fernández-Gómez, J. (2020). Factorial design of reactive powder concrete containing electric arc slag furnace and recycled glass powder. *Dyna*, *87*(213), 42–51. <https://doi.org/http://doi.org/10.15446/dyna.v87n213.82655>
- Abellan-Garcia, J., Santofimo-Vargas, M. A., & Torres-Castellanos, N. (2020). Analysis of metakaolin as partial substitution of ordinary Portland cement in Reactive Powder Concrete. *Advances in Civil Engineering Materials*, *9*(1), 368–386. <https://doi.org/10.1520/ACEM20190224>
- Abellán, J. (2020). *Dosage optimization and seismic retrofitting applications of Ultra-HighPerformance Fiber Reinforced Concrete (UHPFRC)*. Universidad Politécnica de Madrid.
- Abellán, J., Fernández, J., Torres, N., & Núñez, A. (2020). Statistical optimization of ultra-high-performance glass concrete. *ACI Materials Journal*, *117*(1), 243–254.

- <https://doi.org/10.14359/51720292>
- Abellán, J., Núñez, A., & Arango, S. (2020). Pedestrian bridge of UNAL in Manizales : A new UPHFRC application in the Colombian building market. *Proceedings of Hipermat 2020 - 5th International Symposium on UHPC and Nanotechnology for Construction Materials*, July, 43–44.
- Abellán, J., Núñez, A., Torres, N., & Fernández, J. (2020). Development of cost-efficient UHPC with local materials on Colombia. *Kassel*, 97–98.
- Abellán, J., Sánchez, J., & Ospina, V. (2020). *Neural network-based optimization of fibers for seismic retrofitting applications of UHPFRC*.
- Abellán, J., Torres, N., Núñez, A., & Fernández, J. (2018). CONCRETOS DE MUY ALTAS PRESTACIONES REFORZADOS CON FIBRAS: ESTADO DEL ARTE, APLICACIONES Y POSIBILIDADES EN EL MERCADO LATINOAMERICANO. *XXXVIII Jornadas Sudamericanas de Ingeniería Estructural*. <https://doi.org/XXXVIIIJSIE-07-001>
- ACI Committee 239. (2018). *ACI 239R-18: Ultra-High-Performance-Concrete: An Emerging Technology Report*.
- ACI Committee 544. (2002). State-of-the-Art Report on Fiber Reinforced Concrete. In *ACI 544.1R-96*. <https://doi.org/10.3109/00016357.2011.654250>
- Alcaraz, J. (n.d.). *UHPC CON MULTIFISURACIÓN*. Universidad Politécnica de Cartagena.
- Alla, S., Jayaram, M., & Asadi, S. S. (2020). An experimental investigation for replacements of river sand and cement with Robosand, fly-ash and silica fume in concrete to evaluate the influence in durability properties. *Materials Today: Proceedings*, xxxx. <https://doi.org/10.1016/j.matpr.2020.07.340>
- ASTM. (2013). C1437 - Standard test method for flow of hydraulic cement mortar. In *ASTM International*.
- Auret, L., & Aldrich, C. (2012). Interpretation of nonlinear relationships between process variables by use of random forests. *Minerals Engineering*. <https://doi.org/10.1016/j.mineng.2012.05.008>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32.
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and regression trees*. Chapman and Hall.
- Brown, C., & O’Leary, D. (1995). *Introduction to artificial intelligence and expert systems*. <https://doi.org/10.2207/qjjws1943.57.490>

- Cai, R., Han, T., Liao, W., Huang, J., Li, D., Kumar, A., & Ma, H. (2020). Prediction of surface chloride concentration of marine concrete using ensemble machine learning. *Cement and Concrete Research*, 136(June), 106164. <https://doi.org/10.1016/j.cemconres.2020.106164>
- Carillo, H. (2013). *Aspectos Aprendidos Sobre Diseño Estructural Y Una Pasarela Peatonal De Hormigón De Muy Alto*. 100.
- Castellanos Torres, N. (2014). *ESTUDIO EN ESTADO FRESCO Y ENDURECIDO DE CONCRETOS ADICIONADOS CON CATALIZADOR DE CRAQUEO CATALÍTICO USADO (FCC)*. Universidad Nacional de Colombia.
- Chanvillard, G., & Rigaud, S. (2003). Complete characterization of tensile properties of Ductal® UHPFRC according to the French recommendations. *4th International Workshop High Performance Fiber Reinforced Cement Composites (HPFRCC4)*.
- Chaudhary, J., Harison, A., & Srivastava, V. (2015). Use of Silica Sand As Cement Replacement in Ppc Concrete. *International Journal of Research in Engineering and Technology*, 04(11), 55–58. <https://doi.org/10.15623/ijret.2015.0411010>
- Chollet, F., & Allaire, J. J. (2018). *Deep Learning with R*. Manning Publications Co.
- Christopher, D. J., Moustafa, M. A., & Keri, L. R. (2017). *Cost and Ecological Feasibility of Using Ultra- High Performance Concrete in Highway Bridge Piers*. 1–8.
- Dagenais, M. A., Massicotte, B., & Boucher-Proulx, G. (2018). Seismic Retrofitting of Rectangular Bridge Piers with Deficient Lap Splices Using Ultrahigh-Performance Fiber-Reinforced Concrete. *Journal of Bridge Engineering*, 23(2), 1–13. [https://doi.org/10.1061/\(ASCE\)BE.1943-5592.0001173](https://doi.org/10.1061/(ASCE)BE.1943-5592.0001173)
- De Larrard, F. (1999). Concrete mixture proportioning: a scientific approach. In *Modern concrete technology series* (E&FN SPON).
- Denarié, E., Habel, K., & Brühwiler, E. (2003). Structural behavior of hybrid elements with Advanced Cementitious Materials (HPFRCC). *4th International Workshop on High Performance Fiber Reinforced Cement Composites*, 1–12.
- Derringer, G., & Suich, R. (1980a). Simultaneous Optimization of Several Response Variables. *Journal of Quality Technology*, 21, 214–219.
- Derringer, G., & Suich, R. (1980b). “Simultaneous Optimization of Several Response Variables.” *Journal of Quality Technology*, 21(4), 214–219.
- Doiron, G., Eng, M., & Eng, P. (2018). Béton fibré à ultra-hautes performances (BFUP) et

- les ouvrages d'art en Amérique du Nord. *Lafarge Canada Inc.*, 1–20.
- Eide, M. B., & Hisdal, J.-M. (2012). *Ultra High Performance Fibre Reinforced Concrete (UHPRC) – State of the art.*
- Everitt, B., & Hothorn, T. (2015). *MVA: An Introduction to Applied Multivariate Analysis with R.*
- Fumo, D. (2017). *Types of Machine Learning Algorithms You Should Know.* Towards Data Science.
- Funk, J. E., & Dinger, D. R. (1994). "Predictive Process Control of Crowded Particulate Suspensions. Applied to Ceramic Manufacturing." Springer Science. <https://doi.org/10.1007/978-1-4615-3118-0>
- Gallo Arciniegas, L. P., González Peñuela, G., & Carrillo León, J. (2013). Comportamiento del concreto reforzado con fibras de acero ZP-306 sometido a esfuerzos de compresión. *Ciencia e Ingeniería Neogranadina*, 23(1), 117. <https://doi.org/10.18359/rcin.236>
- Genuer, R., & Poggi, J.-M. (2020). Random Forests with R. In *Use R!* Springer.
- Ghafari, E., Bandarabadi, M., Costa, H., & Júlio, E. (2015). Prediction of Fresh and Hardened State Properties of UHPC: Comparative Study of Statistical Mixture Design and an Artificial Neural Network Model. *Journal of Materials in Civil Engineering*, 27(11), 04015017. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0001270](https://doi.org/10.1061/(ASCE)MT.1943-5533.0001270)
- Ghafari, E., Costa, H., & Júlio, E. (2015). "Statistical mixture design approach for eco-efficient UHPC." *CEMENT AND CONCRETE COMPOSITES*, 55(September), 17–25. <https://doi.org/10.1016/j.cemconcomp.2014.07.016>
- Ghafari, E., Costa, H., Nuno, E., & Santos, B. (2014). "RSM-based model to predict the performance of self-compacting UHPC reinforced with hybrid steel micro-fibers." *Construction and Building Materials*, 66(September), 375–383. <https://doi.org/10.1016/j.conbuildmat.2014.05.064>
- Graybeal, B A. (2006). Material Property Characterization of Ultra-High Performance Concrete. In *U.S Department of Transportation (Federal Hi).*
- Graybeal, Benjamin A., & Baby, F. (2013). Development of direct tension test method for ultra-high-performance fiber-reinforced concrete. *ACI Materials Journal*, 110(2), 177–186. <https://doi.org/10.14359/51685532>
- Japan Society of Civil Engineers. (2008). Recommendations for Design and Construction of High Performance Fiber Reinforced Cement Composites with Multiple Fine Cracks

- (HPFRCC). *Concrete Engineereing Series*, 82, Testing Method 6-10.
<http://www.jsce.or.jp/committee/concrete/e/index.html>
- Jaramillo, D. (2020). *PROPIEDADES MECÁNICAS Y DE DURABILIDAD DE CONCRETOS DE ULTRA ALTAS PRESTACIONES (UHPC), CON DIFERENTES MATERIALES CEMENTANTES SUPLEMENTARIOS*. Escuela Colombiana de Ingeniería Julio Garavito.
- Jungwirth, J., & Muttoni, A. (2004). Structural behavior of tension members in UHPC. *Proceeding of International Symposium on UHPC*, 533–546.
- Kabacoff, R. I. (2011). R IN ACTION: Data analysis and graphics with R. In *Online*.
<https://doi.org/citeulike-article-id:10054678>
- Kang, M. C., Yoo, D. Y., & Gupta, R. (2020). Machine learning-based prediction for compressive and flexural strengths of steel fiber-reinforced concrete. *Construction and Building Materials*, 266, 121117. <https://doi.org/10.1016/j.conbuildmat.2020.121117>
- Kim, D.-J., Naaman, A. E., & El-Tawil, S. (2009). High Performance Fiber Reinforced Cement Composites with Innovative Slip Hardening Twisted Steel Fibers. *International Journal of Concrete Structures and Materials*, 3(2), 119–126.
<https://doi.org/10.4334/ijcsm.2009.3.2.119>
- Kusumawardaningsih, Y., Fehling, E., & Ismail, M. (2015). UHPC compressive strength test specimens: Cylinder or cube? *Procedia Engineering*, 125, 1076–1080.
<https://doi.org/10.1016/j.proeng.2015.11.165>
- Kwon, S., Nishiwaki, T., Kikuta, T., & Mihashi, H. (2014). Development of ultra-high-performance hybrid fiber-reinforced cement-based composites. *ACI Materials Journal*, 111(3), 309–318. <https://doi.org/10.14359/51686890>
- Larrard, F. (1994). Optimization of Ultra-High Performance Concrete by the Use of a Packing Model. *Cement and Concrete Research*, 24(6), 997–1009.
- Li, Z. (2015). *Proportioning and properties of Ultra-High Performance Concrete mixtures for application in shear keys of precast concrete bridges*. Graduate School of Clemson University.
- Malatesta, S. C., & Contreras, M. C. (2009). Comportamiento al corte de hormigones reforzado con fibras de acero. *Revista Ingeniería de Construcción*, 24(1), 79–94.
- Malhotra, V. M., Ramachandran, V. S., Feldman, R. F., & Aitcin, P.-C. (2018). *Condensed Silica Fume in Concrete*. CRC Revivals.

- Markovic, I. (2006). *High-Performance Hybrid-Fibre Concrete*.
- Maroliya, M. K. (2012). Tensile behavior of reactive powder concrete containing steel fibres and silica fume. *International Journal of Engineering Research and Development*, 4(4), 58–61.
- Martin-Sanz, H., Chatzi, E., & Brühwiler, E. (2016). *The use of Ultra High Performance Fibre Reinforced cement-based Composites in rehabilitation projects: a review*. <https://doi.org/10.21012/fc9.219>
- Meng, W., & Khayat, K. H. (2018). Effect of hybrid fibers on fresh properties, mechanical properties, and autogenous shrinkage of cost-effective UHPC. *Journal of Materials in Civil Engineering*, 30(4). [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0002212](https://doi.org/10.1061/(ASCE)MT.1943-5533.0002212)
- Muthukrishnan, N., Maleki, F., Ovens, K., Reinhold, C., Forghani, B., & Forghani, R. (2020). Brief History of Artificial Intelligence. *Neuroimaging Clinics of North America*, 30(4), 393–399. <https://doi.org/10.1016/j.nic.2020.07.004>
- Naaman, A. E., & Wille, K. (2010). Some correlation between high packing density, ultra-high performance, flow ability, and fiber reinforcement of a concrete matrix. *Bac2010, Congresso Ibérico Sobre Betão Auto-Compactável*.
- Neira, A. (2020). *Efecto de la mezcla de micro-fibras y macro-fibras poliméricas en el comportamiento a flexión y compresión del UHPFRC*. Escuela Colombiana de Ingeniería Julio Garavito.
- Nguyen, H., Vu, T., Vo, T. P., & Thai, H. T. (2020). Efficient machine learning models for prediction of concrete strengths. *Construction and Building Materials*, 266, 120950. <https://doi.org/10.1016/j.conbuildmat.2020.120950>
- Nilsen, V., Pham, L. T., Hibbard, M., Klager, A., Cramer, S. M., & Morgan, D. (2019). Prediction of concrete coefficient of thermal expansion and other properties using machine learning. *Construction and Building Materials*, 220, 587–595. <https://doi.org/10.1016/j.conbuildmat.2019.05.006>
- NMX. (2014). *NMX-C-488-ONNCCE-2014 "Industria de la construcción - Fibras de acero para refuerzo de concreto - Especificaciones y métodos de ensayo."* Organismo Nacional de Normalización y Certificación de la Construcción y la Edificación.
- NTC. (2000a). *NTC-673. CONCRETOS. ENSAYO DE RESISTENCIA A LA COMPRESIÓN DE CILINDROS NORMALES DE CONCRETO* (pp. 1–14). Instituto Colombiano de Normas Técnicas y Certificación (ICONTEC).
- NTC. (2000b). *NTC-722. Método de ensayo para determinar la resistencia a la tensión*

- indirecta de especímenes cilíndricos de concreto* (pp. 1–12). Instituto Colombiano de Normas Técnicas y Certificación (ICONTEC).
- NTC. (2014). *NTC-121. Especificación de desempeño para cemento hidráulico* (pp. 1–16). Insituto Colombiano de Normas Técnicas y Certificaciones - ICONTEC.
- Olivier, J. G. ., Janssens-Maenhout, G., Muntean, M., & Peters, J. A. H. . (2014). Trends in global CO2 emissions: 2014 Report. In *The Hague: PBL Netherlands Environmental Assessment Agency; Ispra: European Commission, Joint Research Centre*. <https://doi.org/10.1016/j.chemgeo.2004.12.011>
- Oshiro, T. M., Perez, P. S., & Baranauskas, J. A. (2012). How many trees in a random forest? *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7376 LNAI(May), 154–168. https://doi.org/10.1007/978-3-642-31537-4_13
- Park, S. H., Kim, D. J., Ryu, G. S., & Koh, K. T. (2012). Tensile behavior of ultra high performance hybrid fiber reinforced concrete. *Cement and Concrete Composites*, 34(2), 172–184. <https://doi.org/10.1016/j.cemconcomp.2011.09.009>
- Park, Y. J., Ang, A. H.-S., & Wen, Y. K. (1984). Seismic Damage Analysis and Damage-Limiting Design of R. C. Buildings. In *Structural Research Series, Report No. 516, University of Illinois*.
- Pengcheng, L., Xianguo, W., Hongyu, C., & Tiemei, Z. (2020). Prediction of compressive strength of High-Performance Concrete by Random Forest algorithm. *IOP Conference Series: Earth and Environmental Science*, 552(1). <https://doi.org/10.1088/1755-1315/552/1/012020>
- Pérez, M. A. (2014). *Aplicaciones avanzadas de los materiales compuestos en la obra civil y la edificación* (M. A. Pérez (ed.)). OmniaScience.
- Poon, C. S., Lam, L., Kou, S. C., Wong, Y. L., & Wong, R. (2001). Rate of pozzolanic reaction of metakaolin in high-performance cement pastes. *Cement and Concrete Research*, 31(9), 1301–1306. [https://doi.org/10.1016/S0008-8846\(01\)00581-6](https://doi.org/10.1016/S0008-8846(01)00581-6)
- Pyo, S., El-Tawil, S., & Naaman, A. E. (2016). Direct tensile behavior of ultra high performance fiber reinforced concrete (UHP-FRC) at high strain rates. *Cement and Concrete Research*, 88, 144–156. <https://doi.org/10.1016/j.cemconres.2016.07.003>
- Pyo, S., Wille, K., El-Tawil, S., & Naaman, A. E. (2015). Strain rate dependent properties of ultra high performance fiber reinforced concrete (UHP-FRC) under tension. *Cement*

-
- and Concrete Composites*, 56, 15–24.
<https://doi.org/10.1016/j.cemconcomp.2014.10.002>
- Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1), 81–106.
<https://doi.org/10.1007/bf00116251>
- Quiroz, M., & Salamanca, L. (2006). *Apoyo didáctico para la enseñanza y aprendizaje en la asignatura “Tecnología del hormigón.”*
- R Core Team. (2018). “*R: A Language and Environment for Statistical Computing*” (R. F. for S. Computing (ed.)).
- Rashad, A. M. (2018). Effect of quartz-powder on the properties of conventional cementitious materials and geopolymers. *Materials Science and Technology (United Kingdom)*, 34(17), 2043–2056. <https://doi.org/10.1080/02670836.2018.1471435>
- Ray, S. (2017). *Commonly used Machine Learning Algorithms (with Python and R Codes)*. <https://www.analyticsvidhya.com/blog/2017/09/common-machine-learning-algorithms/>
- Sanchez de Guzmán, D. (2001). *Tecnología del Concreto y del Mortero* (Quinta Edición). Bhandar editores LTDA.
- Sánchez, J. (2020). *Uso de Redes Neuronales en la optimización del proceso de diseño de mezclas de concretos reforzados con fibras con alto comportamiento de endurecimiento por deformación (HPFRCC)*. Escuela Colombiana de Ingeniería Julio Garavito.
- Schmidt, M., Fehling, E., Bormeman, R., & Middenhof, B. (2001). Ultra-Hochleistungsbeton: Herstellung, Eigenschaften und Anwendungsmöglichkeiten. *Beton- Und Stahlbetonbau, Jahrgang 96. Heft 7, Verlag Ernst and Sohn*, 458–467.
- Seheult, A. H., Green, P. J., Rousseeuw, P. J., & Leroy, A. M. (1989). Robust Regression and Outlier Detection. *Journal of the Royal Statistical Society. Series A (Statistics in Society)*. <https://doi.org/10.2307/2982847>
- Seif, G. (2018). *A Guide to Decision Trees for Machine Learning and Data Science*. Towards Data Science.
- Serna Ros, P., López Martínez, J. Á., & Camacho Torregosa, E. (2012). UHPFRC : De los componentes a la estructura. *Simposio Latinoamericano Sobre Concreto Autocompactante*, 1, 1–21.
- Shi, C., Wu, Z., Xiao, J., Wang, D., Huang, Z., & Fang, Z. (2015a). A review on ultra high performance concrete: Part I. Raw materials and mixture design. *Construction and*

- Building Materials*, 101(October), 741–751.
<https://doi.org/10.1016/j.conbuildmat.2015.10.088>
- Shi, C., Wu, Z., Xiao, J., Wang, D., Huang, Z., & Fang, Z. (2015b). A review on ultra high performance concrete: Part II. Hydration, microstructure and properties. *Construction and Building Materials*, 101(October), 741–751.
<https://doi.org/10.1016/j.conbuildmat.2015.10.088>
- Sohail, M. G., Ph, D., Wang, B., Jain, A., Kahraman, R., Ph, D., Ozerkan, N. G., Ph, D., Gencturk, B., Ph, D., Asce, A. M., Dawood, M., Ph, D., Asce, M., Belarbi, A., Ph, D., & Asce, F. (2018). *Advancements in Concrete Mix Designs: High-Performance and Ultrahigh-Performance Concretes from 1970 to 2016*. 30(1990).
[https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0002144](https://doi.org/10.1061/(ASCE)MT.1943-5533.0002144).
- Srinice, A., Korjakins, A., Pakrastinsh, L., Shakhmenko, G., & Bumanis, G. (2012). Early Age Creep and Shrinkage of High Performance Concrete. *Proceedings of Hipermat 2012 3rd Internacional Symposium on UHPC and Nanotechnology for High Performance Construction Materials*.
- Sujiravorakul, C. (2001). *Development of high performance reinforced cement composites using twisted polygonal steel fibers*. University of Michigan.
- Wang, D., Shi, C., Wu, Z., Xiao, J., Huang, Z., & Fang, Z. (2015). Durability of an ultra high performance fiber reinforced concrete (UHPFRC) under progressive aging. *Cement Concrete Research*, 55.
- Wille, K., El-Tawil, S., & Naaman, A. E. (2014). Properties of strain hardening ultra high performance fiber reinforced concrete (UHP-FRC) under direct tensile loading. *Cement and Concrete Composites*, 48, 53–66.
<https://doi.org/10.1016/j.cemconcomp.2013.12.015>
- Wille, K, Kim, D., & Naaman, A. E. (2011). Strain hardening UHP-FRC with low fiber contents. In *Materials and Structures* (Vol. 44, pp. 538–598).
- Wille, Kay, Kim, D. J., & Naaman, A. E. (2011). Strain-hardening UHP-FRC with low fiber contents. *Materials and Structures/Materiaux et Constructions*, 44(3), 583–598.
<https://doi.org/10.1617/s11527-010-9650-4>
- Wille, Kay, & Naaman, A. E. (2012). *Ultra-high performance concrete and fiber reinforced concrete: achieving strength and ductility without heat curing*. 309–324.
<https://doi.org/10.1617/s11527-011-9767-0>

- Yokota, H., Rokugo, K., & Sakata, N. (2008). *(JSCE-2008) Recommendations for Design and Construction of High Performance Fiber Reinforced Cement Composites with Multiple Fine Cracks (HPFRCC)*.
<https://doi.org/http://dx.doi.org/10.1016/j.dci.2010.01.003>
- Yu, K., Wang, Y., Yu, J., & Xu, S. (2017). A strain-hardening cementitious composites with the tensile capacity up to 8%. *Construction and Building Materials*, 137, 410–419.
<https://doi.org/10.1016/j.conbuildmat.2017.01.060>
- Yu, K., Yu, J., & Lu, Z. (2018). Mechanical Characterization of Ultra High Performance Strain Hardening Composites. *Proceedings of the 4th International Conference on Strain-Hardening Cement-Based Composites (SHCC4)*.
- Zambrano, J. (2018). *¿Aprendizaje supervisado o no supervisado? Conoce sus diferencias dentro del machine learning y la automatización inteligente*. Medium.
- Zhang, Jisong, & Zhao, Y. (2017a). Experimental Investigation and Prediction of Compressive Strength of Ultra-High Performance Concrete (UHPC) Containing Supplementary Cementitious Materials. *Hindawi Advances in Materials Science and Engineering*, 2017, 522–525. <https://doi.org/10.1155/2017/4563164>
- Zhang, Jisong, & Zhao, Y. (2017b). Prediction of compressive strength of ultra-high performance concrete (UHPC) containing supplementary cementitious materials. *Proceedings - 2017 International Conference on Smart Grid and Electrical Automation, ICSGEA 2017, 2017-Janua*, 522–525. <https://doi.org/10.1109/ICSGEA.2017.150>
- Zhang, Junfei, Ma, G., Huang, Y., sun, J., Aslani, F., & Nener, B. (2019). Modelling uniaxial compressive strength of lightweight self-compacting concrete using random forest regression. *Construction and Building Materials*.
<https://doi.org/10.1016/j.conbuildmat.2019.03.189>