

UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA
Máster Oficial en Sistemas Inteligentes y Aplicaciones Numéricas en
Ingeniería



Trabajo Final de Máster

**Modelado mediante simulación del efecto de la
detonación de sustancias explosivas y su aproximación
mediante el uso de Redes Neuronales**

ANDRÉS CACEREÑO IBÁÑEZ

TUTOR: BLAS JOSÉ GALVÁN GONZÁLEZ

Diciembre 2017

A mi padre

Agradecimientos

A profesores y compañeros del Máster Oficial en Sistemas Inteligentes y Aplicaciones Numéricas en Ingeniería (Ediciones 2016 – 2017 y 2017 - 2018). A mis compañeros de la División CEANI del Instituto Universitario SIANI, por su apoyo a la consecución del presente Trabajo Fin de Máster.

Resumen

En el Ordenamiento Jurídico Español, mediante el Real Decreto 840/2015, de 21 de septiembre, aprueba medidas de control de los riesgos inherentes a los accidentes graves en los que intervengan sustancias peligrosas. Este incide en la necesidad de analizar el riesgo derivado de la presencia de sustancias peligrosas en establecimientos industriales, y planificar las posibles emergencias. El Real Decreto 1196/2003, de 19 de septiembre, por el que se aprueba la Directriz básica de protección civil para el control y planificación ante el riesgo de accidentes graves en los que intervienen sustancias peligrosas, establece el modo de calcular las consecuencias derivadas de este tipo de accidentes. Para el modelado de las citadas consecuencias, la literatura científica aporta métodos de cálculo que permiten establecer las zonas objeto de planificación.

Por otra parte, los Sistemas Inteligentes basados en el aprendizaje automatizado, son capaces de emular el comportamiento de esperado de la ejecución de los citados métodos matemáticos. El presente trabajo muestra como el correcto ajuste de un sistema en base a redes neuronales artificiales es capaz de predecir una respuesta esperada con un margen de error que satisface las necesidades del problema que se plantea.

Abstract

In the Spanish Legal Framework, the Real Decreto 840/2015, september 21, approves measures to control the risks inherent to serious accidents involving dangerous substances. It establishes the need to analyze the risk derived from the presence of hazardous substances in industrial establishments, and to plan possible emergencies. The Real Decreto 1196/2003, september 19, approves the Basic Civil Protection Directive for the control and planning of the risk of serious accidents involving dangerous substances. It establishes the way for calculating the consequences from serious accidents. To model the consequences, the scientific literature provides calculation methods that allow to establish the areas under planning.

On the other hand, Intelligent Systems based on machine learning are capables to emule the expected behavior for the calculate methods. This work shows How with the correct asjustment, a intelligent system based on artificial neural network can predict an expected response with a margin of error that meets the needs of the problem that arises.

INDICE GENERAL.

1. INTRODUCCIÓN.	1
2. CONTEXTUALIZACIÓN (ANTECEDENTES Y ESTADO ACTUAL).	2
2.1. Preámbulo.	2
2.2. Detonaciones en la industria.....	6
2.3. Cálculo de Consecuencias: Planificación de Emergencias.	8
2.4. Redes Neuronales: Aproximación de funciones.	9
3. FUNDAMENTOS TEÓRICOS.	11
3.1. Método del TNT equivalente.....	11
3.2. Implementación del modelo del TNT equivalente.....	14
3.3. Redes Neuronales.....	18
3.3.1. Redes Neuronales Biológicas.	18
3.3.2. Redes Neuronales Artificiales.	19
3.4. Entorno de trabajo para la solución propuesta.	22
3.5. Ajustes propuestos y conjunto de experimentos.....	25
4. RESULTADOS.....	28
4.1. Caso ID1: Opt – SGD, Loss – MSE, Lay 1 – 16, Epoch 10000.	29
4.2. Caso ID2: Opt – SGD, Loss – MSE, Lay 1 – 16, Epoch 20000.	31
4.3. Caso ID3: Opt – SGD, Loss – MSE, Lay 1 – 32, Epoch 10000.	33
4.4. Caso ID4: Opt – SGD, Loss – MSE, Lay 1 – 32, Epoch 20000.	35
4.5. Caso ID5: Opt – SGD, Loss – MSE, Lay 2 – 16, Epoch 10000.	37
4.6. Caso ID6: Opt – SGD, Loss – MSE, Lay 2 – 16, Epoch 20000.	39
4.7. Caso ID7: Opt – SGD, Loss – MSE, Lay 2 – 32, Epoch 10000.	41
4.8. Caso ID8: Opt – SGD, Loss – MSE, Lay 2 – 32, Epoch 20000.	43
4.9. Caso ID9: Opt – SGD, Loss – MAE, Lay 1 – 16, Epoch 10000.	45
4.10. Caso ID10: Opt – SGD, Loss – MAE, Lay 1 – 16, Epoch 20000.	47
4.11. Caso ID11: Opt – SGD, Loss – MAE, Lay 1 – 32, Epoch 10000.	49
4.12. Caso ID12: Opt – SGD, Loss – MAE, Lay 1 – 32, Epoch 20000.	51
4.13. Caso ID13: Opt – SGD, Loss – MAE, Lay 2 – 16, Epoch 10000.	53
4.14. Caso ID14: Opt – SGD, Loss – MAE, Lay 2 – 16, Epoch 20000.	55
4.15. Caso ID15: Opt – SGD, Loss – MAE, Lay 2 – 32, Epoch 10000.	57

4.16. Caso ID16: Opt – SGD, Loss – MAE, Lay 2 – 32, Epoch 20000.	59
4.17. Caso ID17: Opt – Adam, Loss – MSE, Lay 1 – 16, Epoch 10000.....	61
4.18. Caso ID18: Opt – Adam, Loss – MSE, Lay 1 – 16, Epoch 20000.....	63
4.19. Caso ID19: Opt – Adam, Loss – MSE, Lay 1 – 32, Epoch 10000.....	65
4.20. Caso ID20: Opt – Adam, Loss – MSE, Lay 1 – 32, Epoch 20000.....	67
4.21. Caso ID21: Opt – Adam, Loss – MSE, Lay 2 – 16, Epoch 10000.....	69
4.22. Caso ID22: Opt – Adam, Loss – MSE, Lay 2 – 16, Epoch 20000.....	71
4.23. Caso ID23: Opt – Adam, Loss – MSE, Lay 2 – 32, Epoch 10000.....	73
4.24. Caso ID24: Opt – Adam, Loss – MSE, Lay 2 – 32, Epoch 20000.....	75
4.25. Caso ID25: Opt – Adam, Loss – MAE, Lay 1 – 16, Epoch 10000.....	77
4.26. Caso ID26: Opt – Adam, Loss – MAPE, Lay 1 – 16, Epoch 20000.	79
4.27. Caso ID27: Opt – Adam, Loss – MAE, Lay 1 – 32, Epoch 10000.....	81
4.28. Caso ID28: Opt – Adam, Loss – MAPE, Lay 1 – 32, Epoch 20000.	83
4.29. Caso ID29: Opt – Adam, Loss – MAE, Lay 2 – 16, Epoch 10000.....	85
4.30. Caso ID30: Opt – Adam, Loss – MAE, Lay 2 – 16, Epoch 20000.....	87
4.31. Caso ID31: Opt – Adam, Loss – MAE, Lay 2 – 32, Epoch 10000.....	89
4.32. Caso ID32: Opt – Adam, Loss – MAPE, Lay 2 – 32, Epoch 20000.	91
4.33. Caso ID33: Opt – RMSprop, Loss – MSE, Lay 1 – 16, Epoch 10000.....	93
4.34. Caso ID34: Opt – RMSprop, Loss – MSE, Lay 1 – 16, Epoch 20000.....	95
4.35. Caso ID35: Opt – RMSprop, Loss – MSE, Lay 1 – 32, Epoch 10000.....	97
4.36. Caso ID36: Opt – RMSprop, Loss – MSE, Lay 1 – 32, Epoch 20000.....	99
4.37. Caso ID37: Opt – RMSprop, Loss – MSE, Lay 2 – 16, Epoch 10000.....	101
4.38. Caso ID38: Opt – RMSprop, Loss – MSE, Lay 2 – 16, Epoch 20000.....	103
4.39. Caso ID39: Opt – RMSprop, Loss – MSE, Lay 2 – 32, Epoch 10000.....	105
4.40. Caso ID40: Opt – RMSprop, Loss – MSE, Lay 2 – 32, Epoch 20000.....	107
4.41. Caso ID41: Opt – RMSprop, Loss – MAE, Lay 1 – 16, Epoch 10000.....	109
4.42. Caso ID42: Opt – RMSprop, Loss – MPE, Lay 1 – 16, Epoch 20000.....	111
4.43. Caso ID43: Opt – RMSprop, Loss – MAPE, Lay 1 – 32, Epoch 10000.....	113
4.44. Caso ID44: Opt – RMSprop, Loss – MAE, Lay 1 – 32, Epoch 20000.....	115
4.45. Caso ID45: Opt – RMSprop, Loss – MAE, Lay 2 – 16, Epoch 10000.....	117
4.46. Caso ID46: Opt – RMSprop, Loss – MAE, Lay 2 – 16, Epoch 20000.....	119
4.47. Caso ID47: Opt – RMSprop, Loss – MAE, Lay 2 – 32, Epoch 10000.....	121

4.48. Caso ID48: Opt – RMSprop, Loss – MAE, Lay 2 – 32, Epoch 20000.....	123
4.49. Resumen de resultados.....	125
5. CONCLUSIONES Y LÍNEAS FUTURAS.....	126
5.1. Conclusiones.	126
5.2. Líneas futuras.....	132
6. BIBLIOGRAFÍA.	133
7. ANEXOS.	135
7.1. Modelo del TNT equivalente (MATLAB).	135
7.2. Normalización de datos de entrada y salida (MATLAB).	137
7.3. Entrenamiento, validación y test de la Red Neuronas (Python).....	139
7.4. Desnormalización y Test de Student (MATLAB).....	141
7.5. Test de Student para las 100 primeras masas (MATLAB).....	143
7.6. Modelo TNT y normalización de datos no usados antes (MATLAB).....	145
7.7. Desnormalización y Test de Student para datos no usados.....	148

INDICE DE FIGURAS

Figura 1: Efecto de la explosiones en la ciudad de Tianjian (China).	7
Figura 2: Vista aérea tras las explosiones en la ciudad de Tianjian (China).	7
Figura 3: Zona de Alerta (m) Vs masa de explosivo (kg).	16
Figura 4: Zona de Intervención (m) Vs masa de explosivo (kg).	17
Figura 5: Zona de Efecto Dominó (m) Vs masa de explosivo (kg).	17
Figura 6: Representación de una Neuronal Biológica.	18
Figura 7: Representación de una Neurona Artificial.	19
Figura 8: Representación de la Función Escalón.	20
Figura 9: Representación de la Función Escalón Simétrico.	20
Figura 10: Representación de la Función Sigmoide.	21
Figura 11: Representación de la Función Sigmoide Tangente Hiperbólica.	21
Figura 12: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	29
Figura 13: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	29
Figura 14: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	30
Figura 15: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	31
Figura 16: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	31
Figura 17: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	32
Figura 18: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	33
Figura 19: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	33
Figura 20: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	34
Figura 21: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	35
Figura 22: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	35
Figura 23: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	36
Figura 24: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	37
Figura 25: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	37
Figura 26: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	38
Figura 27: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	39
Figura 28: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	39
Figura 29: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	40
Figura 30: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	41

Figura 31: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	41
Figura 32: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	42
Figura 33: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	43
Figura 34: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	43
Figura 35: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	44
Figura 36: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	45
Figura 37: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	45
Figura 38: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	46
Figura 39: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	47
Figura 40: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	47
Figura 41: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	48
Figura 42: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	49
Figura 43: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	49
Figura 44: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	50
Figura 45: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	51
Figura 46: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	51
Figura 47: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	52
Figura 48: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	53
Figura 49: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	53
Figura 50: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	54
Figura 51: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	55
Figura 52: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	55
Figura 53: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	56
Figura 54: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	57
Figura 55: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	57
Figura 56: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	58
Figura 57: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	59
Figura 58: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	59
Figura 59: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	60
Figura 60: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	61
Figura 61: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	61
Figura 62: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	62

Figura 63: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	63
Figura 64: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	63
Figura 65: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	64
Figura 66: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	65
Figura 67: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	65
Figura 68: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	66
Figura 69: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	67
Figura 70: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	67
Figura 71: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	68
Figura 72: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	69
Figura 73: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	69
Figura 74: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	70
Figura 75: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	71
Figura 76: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	71
Figura 77: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	72
Figura 78: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	73
Figura 79: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	73
Figura 80: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	74
Figura 81: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	75
Figura 82: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	75
Figura 83: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	76
Figura 84: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	77
Figura 85: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	77
Figura 86: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	78
Figura 87: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	79
Figura 88: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	79
Figura 89: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	80
Figura 90: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	81
Figura 91: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	81
Figura 92: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	82
Figura 93: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	83
Figura 94: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	83

Figura 95: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	84
Figura 96: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	85
Figura 97: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	85
Figura 98: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	86
Figura 99: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	87
Figura 100: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	87
Figura 101: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	88
Figura 102: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	89
Figura 103: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	89
Figura 104: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	90
Figura 105: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	91
Figura 106: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	91
Figura 107: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	92
Figura 108: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	93
Figura 109: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	93
Figura 110: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	94
Figura 111: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	95
Figura 112: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	95
Figura 113: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	96
Figura 114: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	97
Figura 115: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	97
Figura 116: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	98
Figura 117: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	99
Figura 118: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	99
Figura 119: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	100
Figura 120: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	101
Figura 121: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	101
Figura 122: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	102
Figura 123: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	103
Figura 124: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	103
Figura 125: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	104
Figura 126: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	105

Figura 127: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	105
Figura 128: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	106
Figura 129: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	107
Figura 130: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	107
Figura 131: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	108
Figura 132: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	109
Figura 133: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	109
Figura 134: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	110
Figura 135: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	111
Figura 136: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	111
Figura 137: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	112
Figura 138: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	113
Figura 139: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	113
Figura 140: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	114
Figura 141: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	115
Figura 142: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	115
Figura 143: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	116
Figura 144: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	117
Figura 145: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	117
Figura 146: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	118
Figura 147: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	119
Figura 148: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	119
Figura 149: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	120
Figura 150: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	121
Figura 151: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	121
Figura 152: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	122
Figura 153: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	123
Figura 154: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).....	123
Figura 155: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	124
Figura 156: Aproximación de ZA para experimentos con Opt “SGD”.....	126
Figura 157: Aproximación de ZA para experimentos con Opt “Adam”.	127
Figura 158: Aproximación de ZA para experimentos con Opt “RMStrop”.	127

Figura 159: Resultado del Test de Student para los 100 primeros valores de masa.	128
Figura 160: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).	130
Figura 161: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).	130
Figura 162: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).	131

INDICE DE TABLAS

Tabla 1: Relación de equivalencia entre masa del TNT y de distintos explosivos.	12
Tabla 2: Muestra de los resultados obtenidos para el modelo implementado.	15
Tabla 3: Relación de experimentos a desarrollar.	27
Tabla 4: Test de Student, ID1 (SGD – MSE – 1 CO – 16 N – 10000).	30
Tabla 5: Test de Student, ID2 (SGD – MSE – 1 CO – 16 N – 20000).	32
Tabla 6: Test de Student, ID3 (SGD – MSE – 1 CO – 32 N – 10000).	34
Tabla 7: Test de Student, ID4 (SGD – MSE – 1 CO – 32 N – 20000).	36
Tabla 8: Test de Student, ID5 (SGD – MSE – 2 CO – 16 N – 10000).	38
Tabla 9: Test de Student, ID6 (SGD – MSE – 2 CO – 16 N – 20000).	40
Tabla 10: Test de Student, ID7 (SGD – MSE – 2 CO – 32 N – 10000).	42
Tabla 11: Test de Student, ID8 (SGD – MSE – 2 CO – 32 N – 20000).	44
Tabla 12: Test de Student, ID9 (SGD – MAE – 1 CO – 16 N – 10000).	46
Tabla 13: Test de Student, ID10 (SGD – MAE – 1 CO – 16 N – 20000).	48
Tabla 14: Test de Student, ID11 (SGD – MAE – 1 CO – 32 N – 10000).	50
Tabla 15: Test de Student, ID12 (SGD – MAE – 1 CO – 32 N – 20000).	52
Tabla 16: Test de Student, ID13 (SGD – MAE – 2 CO – 16 N – 10000).	54
Tabla 17: Test de Student, ID14 (SGD – MAE – 2 CO – 16 N – 20000).	56
Tabla 18: Test de Student, ID15 (SGD – MAE – 2 CO – 32 N – 10000).	58
Tabla 19: Test de Student, ID16 (SGD – MAE – 2 CO – 32 N – 20000).	60
Tabla 20: Test de Student, ID17 (Adam – MSE – 1 CO – 16 N – 10000).	62
Tabla 21: Test de Student, ID18 (Adam – MSE – 1 CO – 16 N – 20000).	64
Tabla 22: Test de Student, ID19 (Adam – MSE – 1 CO – 32 N – 10000).	66
Tabla 23: Test de Student, ID20 (Adam – MSE – 1 CO – 32 N – 20000).	68
Tabla 24: Test de Student, ID21 (Adam – MSE – 2 CO – 16 N – 10000).	70
Tabla 25: Test de Student, ID22 (Adam – MSE – 2 CO – 16 N – 20000).	72
Tabla 26: Test de Student, ID23 (Adam – MSE – 2 CO – 32 N – 10000).	74
Tabla 27: Test de Student, ID24 (Adam – MSE – 2 CO – 32 N – 20000).	76
Tabla 28: Test de Student, ID25 (Adam – MAE – 1 CO – 16 N – 10000).	78
Tabla 29: Test de Student, ID26 (Adam – MAE – 1 CO – 16 N – 20000).	80
Tabla 30: Test de Student, ID27 (Adam – MAE – 1 CO – 32 N – 10000).	82

Tabla 31: Test de Student, ID28 (Adam – MAE – 1 CO – 32 N – 20000).	84
Tabla 32: Test de Student, ID29 (Adam – MAE – 2 CO – 16 N – 10000).	86
Tabla 33: Test de Student, ID30 (Adam – MAE – 2 CO – 16 N – 20000).	88
Tabla 34: Test de Student, ID31 (Adam – MAE – 2 CO – 32 N – 10000).	90
Tabla 35: Test de Student, ID32 (Adam – MAE – 2 CO – 32 N – 20000).	92
Tabla 36: Test de Student, ID33 (RMSprop – MSE – 1 CO – 16 N – 10000).	94
Tabla 37: Test de Student, ID34 (RMSprop – MSE – 1 CO – 16 N – 20000).	96
Tabla 38: Test de Student, ID35 (RMSprop – MSE – 1 CO – 32 N – 10000).	98
Tabla 39: Test de Student, ID36 (RMSprop – MSE – 1 CO – 32 N – 20000).	100
Tabla 40: Test de Student, ID37 (RMSprop – MSE – 2 CO – 16 N – 10000).	102
Tabla 41: Test de Student, ID38 (RMSprop – MSE – 2 CO – 16 N – 20000).	104
Tabla 42: Test de Student, ID39 (RMSprop – MSE – 2 CO – 32 N – 10000).	106
Tabla 43: Test de Student, ID40 (RMSprop – MSE – 2 CO – 32 N – 20000).	108
Tabla 44: Test de Student, ID41 (RMSprop – MAE – 1 CO – 16 N – 10000).	110
Tabla 45: Test de Student, ID42 (RMSprop – MAE – 1 CO – 16 N – 20000).	112
Tabla 46: Test de Student, ID43 (RMSprop – MAE – 1 CO – 32 N – 10000).	114
Tabla 47: Test de Student, ID44 (RMSprop – MAE – 1 CO – 32 N – 20000).	116
Tabla 48: Test de Student, ID45 (RMSprop – MAE – 2 CO – 16 N – 10000).	118
Tabla 49: Test de Student, ID46 (RMSprop – MAE – 2 CO – 16 N – 20000).	120
Tabla 50: Test de Student, ID47 (RMSprop – MAE – 2 CO – 32 N – 10000).	122
Tabla 51: Test de Student, ID48 (RMSprop – MAE – 2 CO – 32 N – 20000).	124
Tabla 52: Resumen de resultados.	125
Tabla 53: Resumen de los mejores resultados.	126
Tabla 54: Test de Student para las predicciones con datos no contemplados a priori.	131

1. INTRODUCCIÓN.

La mejora de las condiciones de vida de las personas está estrechamente ligada al desarrollo industrial. Las sustancias peligrosas que se emplean en multitud de procesos industriales presentan peligros intrínsecos que los seres humanos debemos asumir con el propósito de disponer de productos y servicios que mejoran la calidad de nuestras vidas.

Existen dos maneras de promover la seguridad ante la necesidad de disponer de estos servicios y productos en relación a la gestión de sustancias peligrosas. Por una parte, el modo ideal de promover la seguridad en este sentido sería el no disponer de las citadas sustancias peligrosas o llevarlas a lugares muy alejados. Esta posibilidad está enfrentada a la necesidad de disponer de los servicios y productos antes referenciados, y es por ello que sólo es posible la segunda opción, la de disponer de las mismas y crear un marco que permita maximizar la seguridad y por tanto minimizar el riesgo de ocurrencia de accidentes.

Con el objeto de promover esta segunda opción, existe a nivel internacional todo un marco legislativo que, entre otros aspectos, promueve el uso de métodos matemáticos de cálculo de consecuencias que permiten planificar emergencias. Estos modelos matemáticos pueden ser emulados por sistemas inteligentes en base a aprendizaje automático, como son las Redes Neuronales, siendo este el objetivo final del presente Trabajo Fin de Máster. Para ello se toma un tipo de accidente específico, concretamente el de la detonación de un explosivo, considerando que este trabajo puede ser extensible a otros accidentes tipificados en el entorno de los Establecimientos Industriales en los que se almacenan sustancias peligrosas.

Palabras clave: Accidente Grave, Planificación de Emergencias, Detonación, Riesgo, Consecuencias, Aprendizaje Automático, Sistemas Inteligentes, Redes Neuronales.

2. CONTEXTUALIZACIÓN (ANTECEDENTES Y ESTADO ACTUAL).

2.1. Preámbulo.

El Análisis del Riesgo, en el ámbito de la Seguridad Industrial, es una herramienta útil e importante para la planificación de emergencias derivadas de posibles accidentes en los que intervienen sustancias peligrosas.

Desde la Dirección General de Protección Civil y Emergencias dependiente del Ministerio del Interior del Gobierno de España, entidad con competencias en lo relacionado a la gestión de riesgos y emergencias en nuestro país, se hace una primera diferenciación entre Riesgos Naturales y Riesgos Tecnológicos.

Los Riesgos Naturales, son aquellos cuyo origen se encuentra en fenómenos de la naturaleza (Inundaciones, Movimientos Sísmicos, Erupciones Volcánicas, debidos a Fenómenos Meteorológicos Adversos, a Incendios Forestales,...), quedando la presencia de estos condicionada por las características geográficas y particulares de cada región.

Los Riesgos Tecnológicos se encuentran estrechamente relacionados con las actividades del transporte (aéreo, marino y por carretera), y de la industria. En este ámbito toma sentido la Seguridad Industrial.

La Seguridad Industrial es divisible como disciplina. Las divisiones surgen a partir del desarrollo histórico por una parte y de las consideraciones de técnicos y legisladores en la materia por otra. Estas pueden considerarse como se expone a continuación [1]:

- Seguridad laboral.
- Seguridad de los productos industriales.
- Seguridad de los procesos e instalaciones industriales.

Es recomendable la formación y estudio de estas temáticas por áreas, no obstante cabe destacar el carácter unitario de la Seguridad Industrial, debido a que accidentes relativos a cualquiera de las citadas áreas podría ocasionar graves consecuencias a personas, bienes materiales o medioambiente. La seguridad en la industria nunca será absoluta, pero cierto es que el nivel de la misma en la actualidad es muy elevado. No obstante se ha de seguir profundizando y trabajando para que la aparición de nuevas tecnologías no comporte niveles de seguridad no aceptables.

El desarrollo tecnológico está estrechamente ligado a la evolución de las sociedades y por extensión a la mejora en sus condiciones de vida. Este desarrollo precisa de una mayor industrialización, lo que implica un mayor riesgo de ocurrencia de accidentes. Para lograr el equilibrio en relación al desarrollo tecnológico, es preciso el control del riesgo de que se produzcan accidentes.

En el ámbito de la Seguridad Industrial, se entiende como accidente grave, aquel que tiene repercusiones sobre las personas y el medioambiente, provocando la emisión de sustancias tóxicas o de energía por encima de lo que se considera normal. La emisión de energía suele ir acompañada de fenómenos peligrosos del tipo térmico (incendios) o mecánico (detonaciones, deflagraciones,...), favoreciendo en ocasiones la dispersión de los agentes tóxicos involucrados. En relación a los accidentes relativos a la actividad industrial, la Dirección General de Protección Civil y Emergencias diferencia entre dos grupos de Riesgos, los Riesgos Químicos por una parte y los Riesgos Nucleares o Radiológicos por otra. Estos últimos, son objeto de legislación propia por la peculiaridad y particularidad de sus instalaciones. En lo que respecta al presente Trabajo Fin de Máster, se consideran únicamente los accidentes en el ámbito del Real Decreto 840/2015, de 21 de septiembre, por el que se aprueban medidas de control de los riesgos inherentes a los accidentes graves en los que intervengan sustancias peligrosas, quedando definidos los mismos como “cualquier suceso, como una emisión en forma de fuga o vertido, un incendio o una explosión importantes, que resulte de un proceso no controlado durante el funcionamiento de cualquier establecimiento

al que sea de aplicación este real decreto, que suponga un riesgo grave, inmediato o diferido, para la salud humana, los bienes, o el medio ambiente, dentro o fuera del establecimiento y en el que intervengan una o varias sustancias peligrosas” [2].

Para el eficiente control y planificación ante el riesgo de que se produzca un accidente grave en un establecimiento industrial, es precisa la evaluación de las consecuencias de los fenómenos peligrosos que se pudieran producir sobre los elementos vulnerables próximos. Los fenómenos peligrosos se consideran de tres tipos [3].

Los **fenómenos peligrosos del tipo mecánico** quedan representados por las ondas de presión y los proyectiles. Las ondas de presión son provocadas por las explosiones o equilibrio rápido entre una masa de gases a presión elevada y la atmósfera que la envuelve. En el caso de que la energía necesaria para la expansión del gas proceda de un fenómeno físico, se dice que la explosión es física y se requiere que el producto esté confinado en un recipiente estanco (denominándose estallido). Por contra, si la energía procede de una reacción química, se trata de una explosión química (o explosión, simplemente). En este caso la explosión puede ocurrir aunque el producto no esté confinado.

Los **fenómenos peligrosos del tipo térmico** se producen a partir de la oxidación rápida, no explosiva, de sustancias combustibles, produciendo llama, que puede ser estacionaria (incendio de charco, dardo de fuego) o progresiva (llamarada, bola de fuego), pero que en todos los casos disipa la energía de combustión mayoritariamente por radiación que puede afectar a seres vivos e instalaciones materiales.

Si la materia sobre la que incide el flujo de radiación térmica no puede disiparlo a la misma velocidad que lo recibe, éste provoca un incremento de su temperatura. Si este incremento no se limita, se producen alteraciones irreversibles y

catastróficas, que pueden culminar en la combustión o fusión y volatilización de la materia expuesta.

Los **fenómenos peligrosos del tipo químico** incluyen las nubes tóxicas o la contaminación del medio ambiente debida a fugas o vertidos incontrolados de sustancias peligrosas para las personas y el medio ambiente.

El presente trabajo se centra en la planificación de emergencias en las que se producen fenómenos peligrosos del tipo mecánico, y más concretamente en las que se producen sobrepresiones a partir de la detonación de un explosivo. La planificación de emergencias requiere del cálculo de las posibles consecuencias de un accidente, siendo objeto del presente trabajo describir y aproximar el modelo matemático que permite establecer las consecuencias derivadas de la detonación de un explosivo.

Una vez descrito el modelo matemático, se pretende obtener una solución inteligente que a partir de un conjunto de entrenamiento, conformado mediante la iteración del modelo matemático citado anteriormente, sea capaz de predecir con un alto grado de precisión las soluciones que aporta el modelo sin la necesidad de ejecución del mismo. Para ello, se ha considerado conformar un sistema inteligente en base a Redes Neuronales Artificiales.

Las Redes de Neuronales Artificiales son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso biológico [4]. Se trata de un sistema de interconexión de neuronas que colaboran entre sí para producir un estímulo de salida. En inteligencia artificial es frecuente referirse a ellas como Redes de Neuronas o Redes Neuronales.

Las Redes Neuronales tienen múltiples aplicaciones en la actualidad. Una de las aplicaciones para las que se emplean consiste en el reconocimiento de imágenes. A partir de un proceso de aprendizaje por medio del cual se le suministra un

conjunto de imágenes y su definición, tras dicho aprendizaje la red neuronal será capaz de reconocer imágenes de los objetos para los cuales ha sido entrenada.

Otra aplicación consiste en el reconocimiento de sonidos. Como en el caso anterior, tras un proceso de aprendizaje será capaz de reconocer sonidos. Existen multitud de aplicaciones, no obstante, la que resulta de mayor interés en relación a los objetivos que se plantean para el presente Trabajo Fin de Máster consiste en la aproximación de funciones. Al disponer de un conjunto de datos experimentales con los que alimentar a la Red Neuronal y un conjunto de datos objetivo o esperados a partir de los mismos, como resultado será posible obtener la función que aproxime los citados datos y por tanto la función de ajuste del sistema.

2.2. Detonaciones en la industria.

La mayoría de los accidentes que se producen en la Industria, no tienen efectos que sobrepasen los límites de la propia instalación, por lo que tienden a afectar al personal y a bienes materiales propios, pudiendo provocar muertes, heridos y pérdidas económicas de diversa consideración, en un montante, en conjunto, mayor en comparación a aquellos accidentes cuyas consecuencias sí superan los límites de la propia instalación.

Sin embargo, aún siendo menor el número de accidentes en los que las consecuencias sobrepasan los límites de la propia instalación, pudiendo presentar en conjunto un montante menor de pérdida de vidas humanas y de bienes materiales, cierto es que en sí mismos, presentan un balance de pérdidas escandaloso en términos sociales. Cabe mencionar algunos accidentes acaecidos a lo largo de la historia, como el ocurrido en Alemania en 1921 en Oppau, en la que una explosión de Nitrato de Amonio acabó con la vida de 561 personas, descrito en la publicación "LEES' LOSS PREVENTION IN THE PROCESS INDUSTRIES" [5].



Fuente: Agencia Reuters.

Figura 1: Efecto de la explosiones en la ciudad de Tianjian (China).



Fuente: Agencia Reuters.

Figura 2: Vista aérea tras las explosiones en la ciudad de Tianjian (China).

Más recientemente, 12 de agosto de 2015, en la zona portuaria de la ciudad de Tianjian (noroeste de China), se registraron dos gigantescas explosiones que según diferentes medios de comunicación afectaron a una terminal de contenedores, con un balance de muertos superior a las 100 personas y más de 6.000 evacuados. Las Figuras 1 y 2 muestran los efectos del citado accidente.

2.3. Cálculo de Consecuencias: Planificación de Emergencias.

Se entiende por análisis de consecuencias el cálculo, espacial y temporal, de las variables representativas de los fenómenos peligrosos de tipo mecánico, térmico y químico definidos por la “Directriz básica de protección civil para el control y planificación ante el riesgo de accidentes graves en los que intervienen sustancias peligrosas”, aprobada por el Real Decreto 1196/2003 [3], y sus posibles efectos sobre las personas, el medio ambiente y los bienes, con el fin de estimar la naturaleza y magnitud del daño, de las diferentes hipótesis accidentales que se pudieran plantear, determinando para las mismas las denominadas zonas de intervención y alerta. Estas quedan definidas por la Directriz anteriormente citada como:

- **Zona de intervención:** Es aquella en la que las consecuencias de los accidentes producen un nivel de daños que justifica la aplicación inmediata de medidas de protección.
- **Zona de alerta:** Es aquella en la que las consecuencias de los accidentes provocan efectos que, aunque perceptibles por la población, no justifican la intervención, excepto para los grupos críticos.

Se analiza a su vez la vulnerabilidad que suponen las magnitudes de los fenómenos peligrosos estimadas para las personas, el medio ambiente y los bienes.


Las variables representativas de los fenómenos peligrosos de tipo mecánico que se analizan en el presente Trabajo Fin de Máster quedan representadas, según la Directriz Básica de Protección Civil anteriormente citada por la sobrepresión local estática debida a la onda de presión generada. Esta Directriz Básica establece por otra parte los umbrales que determinan las anteriormente expuestas Zonas de Alerta e Intervención, siendo estos de:

- Una sobrepresión local estática de la onda de presión de 125 milibares para la Zona de Alerta.
- Una sobrepresión local estática de la onda de presión de 50 milibares para la Zona de Intervención.

En relación a los efectos de la sobrepresión sobre los bienes materiales, cabe mencionar lo que la Directriz Básica define como Zona de Efecto Dominó, siendo esta el área en que cuando un accidente afecta a otras instalaciones, estas instalaciones a su vez pudieran dar origen a un nuevo accidente. En este caso se establece una sobrepresión local estática de la onda de presión de 160 milibares.

2.4. Redes Neuronales: Aproximación de funciones.

Como se comentó anteriormente, es objeto del presente Trabajo Fin de Máster diseñar una Red Neuronal Artificial capaz de aproximar una función y por lo tanto predecir un resultado. A partir de un conjunto de datos de entrada y sus correspondientes salidas se ha de definir la relación entre los mismos.



Para ello se construirá un conjunto de aprendizaje a partir de la implementación del modelo matemático que describe el comportamiento de la detonación de un explosivo.

El dato inicial o de entrada al modelo (y posteriormente a la red neuronal) será la masa de un determinado explosivo, obteniendo como salida las distancias que definen las Zonas de Alerta, Intervención y Efecto Dominó. Para ello se generará de manera aleatoria un conjunto de masas de explosivo, con el objetivo de aleatorizar el conjunto de aprendizaje.

El citado conjunto de aprendizaje se empleará por tanto para el ajuste del modelo matemático que describe el comportamiento de la Red Neuronal y que relaciona los datos de entrada con los datos de salida (predicción) al modelo. El conjunto de aprendizaje se dividirá previamente con el propósito de emplear un subconjunto para el entrenamiento de la Red Neuronal y otro subconjunto para la evaluación de la precisión de la misma.

Los métodos de entrenamiento de redes neuronales se clasifican en tres grandes grupos [6].

- Entrenamiento supervisado.
- Entrenamiento no supervisado.
- Entrenamiento por refuerzo.

Es en el primero de ellos en los que se aporta a la red neuronal un conjunto de datos de entrada y de datos de salida u objetivo, siendo este el método empleado para el presente Trabajo Fin de Máster.

3. FUNDAMENTOS TEÓRICOS.

El modelo matemático empleado para la estimación de las consecuencias de la detonación de un explosivo se denomina “Método del TNT equivalente”.

3.1. Método del TNT equivalente.

El TNT es un explosivo convencional cuyos efectos han sido muy estudiados. Es por tanto bastante conocida la relación entre la masa del TNT que explota y la sobrepresión de la onda generada en función de la distancia al origen de la explosión. Mediante la comparación de la energía generada por la explosión de la cantidad equivalente de TNT que produce el mismo efecto que la de otra sustancia, es posible establecer las zonas de planificación ante una emergencia de esta tipología. Para ello, en primer lugar es necesario establecer la masa equivalente en TNT del explosivo en cuestión. Esta relación se resuelve mediante el modelo matemático que se muestra mediante la Ecuación 1.

$$w_{TNT} = w_{explosivo} \left(\frac{w_{TNT}}{w_{explosivo}} \right)_{explosivo} \quad (1)$$

Donde w_{TNT} representa la masa equivalente en TNT del explosivo, $w_{explosivo}$ la masa del explosivo y $(w_{TNT}/w_{explosivo})_{explosivo}$ la relación entre uno y otro. Mediante la Tabla 1 se muestra esta relación para algunas de las sustancias más comunes [7]. Esta relación se describe para el cálculo de la sobrepresión, teniendo como unidad el Pascal.

Explosivo	Equivalencia TNT (Sobrepresiones)
Nitroglicerina	1.69
PETN	1.77
Ácido Pírico	1.06
RDX	1.57
Trinitrobenceno	1.11
2,4-Dinitrotolueno	0.77
Nitrato de Amónio	0.56
Peróxido de ciclohexanona	0.19
Clorato Sódico	0.15
Nitrometano	1.34
Composición A-3	1.09
Composición C-4	1.37
Ciclotol (70/30)	1.14
HBX-1	1.17
HBX-3	1.14
H-6	1.38
Minol II	1.20
Pentolita	1.38
Picratol	0.90
TNETB	1.36
Tritonal	1.07

Fuente: Tesis Doctoral Fernando Díaz Alonso.

Tabla 1: Relación de equivalencia entre masa del TNT y de distintos explosivos.

A partir de la cantidad de TNT equivalente es posible determinar la distancia escalada (z') por medio de las Ecuaciones 2 y 3 [8].

- Si la presión (P_s) tiene un valor de entre 400 y 11000 Pascales:

$$P_s = 1.83 \times 10^5 z'^{(-1.16)} \quad (2)$$

- Si la presión (P_s) tiene un valor de entre 11000 y 1130000 Pascales:

$$P_s = 1.13 \times 10^6 z'^{(-2.01)} \quad (3)$$

Una vez obtenida la distancia escalada para las sobrepresiones de interés es posible determinar la distancia a la que las sobrepresiones de interés se dan por medio de la Ecuación 4:

$$Z' = \frac{Z}{W_{TNT}^{1/3}} \quad (4)$$

A continuación se muestra el ejemplo de cálculo para el caso del Nitrato de Amonio, sustancia explosiva presente en el territorio regional. Se considera una cantidad de 100 kg.

Paso 1: Cálculo de la masa equivalente en TNT (Ecuación 1).

$$W_{TNT} = 100 \times 0.56 = 56$$

Paso 2: Cálculo de la distancia equivalente a las sobrepresiones de interés (Ecuación 2 o 3, en función de P_s).

$$\begin{aligned} Z'_{5000} &= 22,27 \\ Z'_{12500} &= 9,40 \\ Z'_{16000} &= 8,31 \end{aligned}$$

Paso 3: Cálculo de la distancia de interés (Ecuación 4).

$$\begin{aligned} Z_{5000} &= 85,20 \\ Z_{12500} &= 35,96 \\ Z_{16000} &= 31,79 \end{aligned}$$

3.2. Implementación del modelo del TNT equivalente.

Con el propósito de automatizar el proceso mediante el cual obtener un conjunto de resultados que permitan entrenar a la red neuronal que se diseñará, se ha implementado el conjunto de modelos matemáticos descritos mediante las Ecuaciones 1 a 4 en un código en MATLAB. Este código se muestra mediante anexo (Modelo de equivalencia en TNT).

Como se observa, el código comienza extrayendo del fichero de texto los datos que precisa el modelo para su ejecución. Estos se muestran a continuación:

- Nombre de la sustancia explosiva.
- Equivalencia en TNT.
- Cantidad mínima de masa de explosiva para generar el conjunto de entrenamiento.
- Cantidad máxima de masa de explosiva para generar el conjunto de entrenamiento.
- Número de datos de masa para conformar el tamaño del conjunto de aprendizaje.

Para el presente Trabajo Fin de Máster se ha generado un conjunto de simulaciones para la sustancia explosiva “Nitrato de Amonio”, con una masa equivalente en TNT de 0.56, una cantidad mínima de sustancia de 0 kg y máxima de 20000 kg, y un número de simulaciones para conformar el conjunto de aprendizaje de 15000 datos. Una muestra de los resultados obtenidos se muestra mediante la Tabla 2.

Masa Nitrato de Amonio [kg]	Zona de Alerta [m]	Zona de Intervención [m]	Zona de Efecto Dominó [m]
5715	328,26905	138,55415	122,54095
18625	486,69471	205,42166	181,68034
15997	462,63382	195,26616	172,69855
6621	344,77232	145,51977	128,70153
14749	450,27592	190,0502	168,08542
11349	412,61378	174,15395	154,02636
321	125,71667	53,06186	46,92931
8510	374,85881	158,21852	139,93264
587	153,73423	64,88737	57,3881
15684	459,5966	193,98422	171,56477
19617	495,18642	209,0058	184,85025
13799	440,393	185,87886	164,39618
15594	458,71581	193,61246	171,23598
11960	419,88941	177,22481	156,74231
5692	327,82809	138,36803	122,37634
14925	452,05989	190,80317	168,75136
13878	441,23182	186,23291	164,7093
8850	379,786	160,29817	141,77193
8382	372,96987	157,42125	139,22751
3015	265,24893	111,95493	99,0159
10806	405,92536	171,33094	151,52961
3927	289,67532	122,2647	108,13413
14984	452,65479	191,05426	168,97343
14313	445,79455	188,15872	166,41255
14090	443,46723	187,17642	165,54377
14726	450,04174	189,95136	167,998
13134	433,20175	182,84362	161,71173
17822	479,59724	202,42599	179,0309
9822	393,20996	165,96408	146,78302
6835	348,44751	147,07098	130,07346
19255	492,12154	207,71219	183,70614
2499	249,16093	105,16459	93,01035
4172	295,57836	124,75623	110,3377
3099	267,68974	112,98514	99,92704
16152	464,12322	195,8948	173,25453
1347	202,77468	85,58612	75,69462
9812	393,07647	165,90774	146,73319
11968	419,98301	177,26432	156,77725
7300	356,17668	150,33326	132,95871
13771	440,09492	185,75305	164,28491
17138	473,38146	199,80247	176,71058
18013	481,30445	203,14657	179,66819
19030	490,19716	206,89996	182,98779
18001	481,19755	203,10144	179,62828
130	93,012	39,25804	34,72085
838	173,10351	73,06266	64,61855

Tabla 2: Muestra de los resultados obtenidos para el modelo implementado.

Como se observa, se ha realizado el cálculo de las distancias objeto de planificación ante emergencias (Zona de Alerta, Zona de Intervención, Zona de Efecto Dominó) que toman como origen el punto en el que se produce la detonación de un explosivo.

Esta información conforma el conjunto de aprendizaje que será empleado para entrenar y testear la Red Neuronal que permitirá emular el comportamiento del modelo matemático empleado. La Red Neuronal, además de aproximar las zonas de planificación para las masas de sustancia explosivas incluidas en el conjunto de entrenamiento, será capaz de aportar resultados para las masas intermedias no contempladas por el modelo a priori.

Mediante las Figuras 3 a 5 se muestran las gráficas que contienen el resultado de la simulación para las Zonas de Alerta, de Intervención y de Efecto Dominó.




Figura 3: Zona de Alerta (m) Vs masa de explosivo (kg).




Figura 4: Zona de Intervención (m) Vs masa de explosivo (kg).





Figura 5: Zona de Efecto Dominó (m) Vs masa de explosivo (kg).

Una vez calculadas de manera aleatoria las distancias que representan las Zonas de Alerta, Intervención y de Efecto Dominó (conjunto de aprendizaje), se generan dos ficheros por medio del cual se exportan los datos. El conjunto de entrenamiento dispondrá del 60 % de los datos, mientras que el conjunto de test dispondrá del 40 % restante.

3.3. Redes Neuronales.

3.3.1. Redes Neuronales Biológicas.

Las neuronas biológicas son células que se componen principalmente de tres partes como se observa a través de la Figura 6: Soma (cuerpo celular), Dendritas (canales de entrada) y Axón (canal de salida). Descrito de una forma muy simplificada, las neuronas transmiten información a través de procesos electroquímicos. Cuando una neurona recibe, a través de las Dendritas, una cantidad de estímulos mayor a un cierto umbral, ésta se despolariza excitando, a través del Axón, a otras neuronas próximas conectadas a través de las sinapsis (ubicadas al final del axón).



(Fuente: <https://cayetanoguerra.github.io/ia/>)

Figura 6: Representación de una Neuronal Biológica.

3.3.2. Redes Neuronales Artificiales.

Las Redes Neuronales Artificiales emulan el comportamiento anteriormente descrito. A partir de la suma de una serie de entradas (e_i) multiplicadas por un peso (w_i), y otra entrada de valor 1 cuyo peso (w_0) representa la polarización de la neurona, se obtiene un determinado valor neto (n). El valor neto obtenido de la suma se puede hacer entrar en una función de activación ($f(n)$), a través de la cual se decide cuando la neurona se activa.




Figura 7: Representación de una Neurona Artificial.

Mediante la Ecuación 5, se muestra la expresión matemática por medio de la cual se determina el valor neto, a partir de la Neurona Artificial que se muestra mediante la Figura 7.

$$n = e_1w_1 + e_2w_2 + \dots + e_nw_n + w_0 \quad (5)$$

La salida evaluará la función de activación con relación a la salida neta, como muestra la Ecuación 6.

$$\text{salida} = f(e_1w_1 + e_2w_2 + \dots + e_nw_n + w_0) \quad (6)$$

Existen multitud de funciones que se emplean para la activación de una Neurona Artificial. Se muestran a continuación algunos ejemplos.

- **Función Escalón:** La Neurona Artificial se mantiene desactiva cuando el valor neto de entrada a la función es nulo.

$$f(n) = \begin{cases} 1 & n \geq 0 \\ 0 & n < 0 \end{cases} \quad (7)$$




Figura 8: Representación de la Función Escalón.

- Función Escalón Simétrico: La Neurona Artificial se mantiene desactiva cuando el valor neto de entrada a la función es -1.

$$f(n) = \begin{cases} 1 & n \geq 0 \\ -1 & n < 0 \end{cases} \quad (8)$$




Figura 9: Representación de la Función Escalón Simétrico.

- **Función Sigmoide:** Esta función de activación presenta una importante ventaja ya que es derivable. Como se observa, presenta una pendiente continua.

$$f(n) = \frac{1}{1 + e^{-n}} \quad (9)$$




Figura 10: Representación de la Función Sigmoide.

- **Función Sigmoide Tangente Hiperbólica:** En este caso el valor para la activación está entre 0 y 1.

$$f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (10)$$




Figura 11: Representación de la Función Sigmoide Tangente Hiperbólica.

3.4. Entorno de trabajo para la solución propuesta.

Con el propósito de obtener una solución al problema que se plantea, se emplea la librería de “Deep Learning” para Python denominada Keras [9]. Keras es una Interfaz de Programación de Aplicaciones (API) para una red neuronal de alto nivel con capacidad para correr sobre TensorFlow, CNTK o Theano. TensorFlow, es una biblioteca para el aprendizaje automático, con capacidad para construir y entrenar redes neuronales para detectar y descifrar patrones y correlaciones, análogos al aprendizaje y razonamiento usados por los humanos [10]. Características similares presentan CNTK y Theano en relación al propósito del presente Trabajo Fin de Máster.

La estructura de datos del núcleo de Keras es un modelo organizado mediante capas. Dispone de dos modelos de trabajo fundamentales. Por una parte el denominado “*Sequential*”, consistente en un modelo lineal de apilamiento de capas. Para arquitecturas más complejas se emplea la API, permitiendo la construcción de capas de manera arbitraria. Para afrontar el presente Trabajo Fin de Máster se empleará el modelo “*Sequential*”. Este modelo se crea pasando una lista de instancias al constructor. Mediante el método `.add()` se añaden las capas correspondientes, del modo que se muestra a continuación.

```
from keras.models import Sequential
from keras.layers import Dense, Activation

model = Sequential()
model.add(Dense('neuronas en capa de entrada', input_dim='entradas'))
model.add(Activation('función de activación'))
```

“*Dense*” se usa para referenciar la capa de entrada de una Red Neuronal densamente conectada. A continuación se indican el número de neuronas para la capa de entrada y el número de entradas a la misma, siempre mediante números enteros.

A continuación se debe indicar la función de activación que empleará la red neuronal. Pueden ser empleadas distintas funciones de activación. A continuación se indican algunas de las mismas a modo de ejemplo.

- Softmax.
- Selu (*"Scaled Exponential Linear Unit"*).
- Elu.
- Softplus.
- Softsign.
- Relu.
- Tanh.
- Sigmoid.

Antes de entrenar un modelo, es necesario configurar el proceso de aprendizaje. Esto se realiza mediante el método *"compile"*.

```
model.compile(optimizer='optimizador', loss='función de pérdida')
```

Según describe la documentación disponible, para resolver problemas de regresión, este método ha de recibir dos argumentos:

- El optimizador. Existen múltiples posibilidades, como por ejemplo:
 - o SGD (*Stochastic gradient descent optimizer*).
 - o RMSprop.
 - o Adagrad.
 - o Adadelta.
 - o Adam.
 - o Nadam.
- La función de pérdida. Existen múltiples posibilidades, como por ejemplo:
 - o MSE (*Mean squared error*).
 - o MAE (*Mean absolute error*).

- o MAPE (*Mean absolute percentage error*).
- o *Poisson*.

Con el propósito de entrenar la red neuronal, el modelo emplea la función “*fit*”.

```
model.fit(datos, objetivos, epochs='iteraciones', batch_size='tamaño de lote')
```

Este método recibe cuatro argumentos:

- Datos de entrada a la red neuronal.
- Datos objetivo o salida esperada para la red neuronal.
- Número de iteraciones para el algoritmo.
- Tamaño de lote o sección en las que se divide el conjunto de entrenamiento para cada iteración.

Tras el entrenamiento, se testea el acierto de la red mediante el empleo de un conjunto de datos de test diferente a los empleados durante el entrenamiento. Esto se realiza mediante el método “*evaluate*”.

```
score = model.evaluate(datos_test, objetivos_test, batch_size='tamaño de lote')
```

Como se observa, este método recibe tres argumentos:

- Datos de entrada a la red neuronal.
- Datos objetivo o salida esperada para la red neuronal.
- Tamaño de lote o sección en las que se divide el conjunto de test.

Con el propósito de comprobar lo idóneo del ajuste, la red neuronal es capaz de generar datos de salida a partir de un conjunto de datos de entrada. De este modo será posible comprobar la precisión. Este proceso se realiza mediante el método “*predict*”.

Predict(x, batch_size=32)

Como se observa, este método recibe dos argumentos:

- Datos de entrada a la red neuronal.
- Tamaño de lote o sección en las que se divide el conjunto de datos de entrada.

Este método devuelve la predicción.

3.5. Ajustes propuestos y conjunto de experimentos.

Como se desprende del entorno de trabajo descrito anteriormente, será necesario decidir la configuración del mismo para generar el conjunto de experimentos a realizar, pudiendo establecer comparativas entre experimentos y definir finalmente la configuración más conveniente. Resulta de especial interés la función de activación a emplear. Para resolver problemas de regresión como el que se plantea en el presente Trabajo Fin de Máster, resulta conveniente el uso de la **Función Tangente Hiperbólica** [11]. Para potenciar el mejor ajuste se acondicionan tanto los datos de entrada a la red, como los datos objetivo o salida de la red, normalizándolos a valores entre 0.1 y 0.9.

La normalización de los datos se ejecuta mediante la Ecuación 11:

$$X' = a + \frac{(X - X_{min})(b - a)}{(X_{max} - X_{min})} \quad (11)$$

Donde:

a = Valor mínimo normalizado (0.1).

b = Valor máximo normalizado (0.9).

Xmin = Valor mínimo a normalizar.

$X_{\max}$ = Valor máximo a normalizar.

X = Valor a normalizar.

X' = Valor normalizado.

Otro parámetro importante será el optimizador a emplear durante el proceso de aprendizaje. Con el propósito de establecer una comparativa se emplearán el **SGD** (Stochastic gradient descent), el **Adam** (basado en estimaciones adaptativas de momentos de bajo orden), siendo este el modelo propuesto para resolver problemas de regresión en algunos trabajos [12], y finalmente el **RMSprop** (optimizador que combina la idea de emplear únicamente el signo del gradiente con la de adaptar el paso de manera diferenciada a cada peso de la red).

La función de pérdidas resulta ser otro parámetro de interés. Se emplearán tanto el **MSE** (error cuadrático medio), función de pérdidas más comúnmente empleada, como el **MAE** (error absoluto medio), por considerar que pudiera presentar un mejor ajuste a regiones más problemáticas a la hora de aproximar una función como es el problema de regresión que se plantea.

Otro de las decisiones consiste en el número de capas ocultas entre la capa de entrada y de salida de la red, así como el número de neuronas en la/las capa/capas oculta/ocultas. Se considerarán **una y dos capas ocultas**, con un número de neuronas para las mismas de **16 y 32**. La Red Neuronal presentará por otra parte una única neurona en la capa de entrada y de salida.

Otro parámetro importante será el número de iteraciones o épocas, siendo empleadas **10000 y 20000** para los experimentos finalmente propuestos.

Mediante la Tabla 3 se muestra un cuadro resumen del conjunto de experimentos propuestos.

ID	Activación	Optimizador	Pérdidas	Capas Ocultas	Neuronas Capas Ocultas	Épocas
1	Tanh	SGD	MSE	1	16	10000
2	Tanh	SGD	MSE	1	16	20000
3	Tanh	SGD	MSE	1	32	10000
4	Tanh	SGD	MSE	1	32	20000
5	Tanh	SGD	MSE	2	16 - 16	10000
6	Tanh	SGD	MSE	2	16 - 16	20000
7	Tanh	SGD	MSE	2	32 - 32	10000
8	Tanh	SGD	MSE	2	32 - 32	20000
9	Tanh	SGD	MAE	1	16	10000
10	Tanh	SGD	MAE	1	16	20000
11	Tanh	SGD	MAE	1	32	10000
12	Tanh	SGD	MAE	1	32	20000
13	Tanh	SGD	MAE	2	16 - 16	10000
14	Tanh	SGD	MAE	2	16 - 16	20000
15	Tanh	SGD	MAE	2	32 - 32	10000
16	Tanh	SGD	MAE	2	32 - 32	20000
17	Tanh	Adam	MSE	1	16	10000
18	Tanh	Adam	MSE	1	16	20000
19	Tanh	Adam	MSE	1	32	10000
20	Tanh	Adam	MSE	1	32	20000
21	Tanh	Adam	MSE	2	16 - 16	10000
22	Tanh	Adam	MSE	2	16 - 16	20000
23	Tanh	Adam	MSE	2	32 - 32	10000
24	Tanh	Adam	MSE	2	32 - 32	20000
25	Tanh	Adam	MAE	1	16	10000
26	Tanh	Adam	MAE	1	16	20000
27	Tanh	Adam	MAE	1	32	10000
28	Tanh	Adam	MAE	1	32	20000
29	Tanh	Adam	MAE	2	16 - 16	10000
30	Tanh	Adam	MAE	2	16 - 16	20000
31	Tanh	Adam	MAE	2	32 - 32	10000
32	Tanh	Adam	MAE	2	32 - 32	20000
33	Tanh	RMSprop	MSE	1	16	10000
34	Tanh	RMSprop	MSE	1	16	20000
35	Tanh	RMSprop	MSE	1	32	10000
36	Tanh	RMSprop	MSE	1	32	20000
37	Tanh	RMSprop	MSE	2	16 - 16	10000
38	Tanh	RMSprop	MSE	2	16 - 16	20000
39	Tanh	RMSprop	MSE	2	32 - 32	10000
40	Tanh	RMSprop	MSE	2	32 - 32	20000
41	Tanh	RMSprop	MAE	1	16	10000
42	Tanh	RMSprop	MAE	1	16	20000
43	Tanh	RMSprop	MAE	1	32	10000
44	Tanh	RMSprop	MAE	1	32	20000
45	Tanh	RMSprop	MAE	2	16 - 16	10000
46	Tanh	RMSprop	MAE	2	16 - 16	20000
47	Tanh	RMSprop	MAE	2	32 - 32	10000
48	Tanh	RMSprop	MAE	2	32 - 32	20000

Tabla 3: Relación de experimentos a desarrollar.

4. RESULTADOS.

A continuación se muestra el resultado obtenido tras la ejecución de los experimentos anteriormente definidos. Por una parte, los resultados se muestran de manera gráfica. En los diferentes gráficos se enfrentan los resultados obtenidos mediante la aplicación del modelo de cálculo por una parte (color azul), y los obtenidos tras el entrenamiento de la red neuronal (color rojo), para las Zonas de Alerta, de Intervención y de Efecto Dominó. De este modo pueden identificarse las diferencias y similitudes de un modo visual.

Por otra parte, con el propósito de comparar los resultados obtenidos de un modo estadístico, se ha considerado oportuno realizar para los datos aportados por uno y otro modelo un Test de Student. El mismo recibe los resultados obtenidos mediante la aplicación del modelo de cálculo, así como los obtenidos tras el entrenamiento de la red neuronal. Además, como se pretende determinar si existe alguna diferencia estadísticamente significativa entre las medidas con un 95% de confianza, se añade un valor alfa de 0.05. El Test devuelve dos valores:

- Un valor **h**, de manera que si este valor es nulo (0) la hipótesis nula no puede ser descartada. Esto implica que no puede ser descartada la hipótesis “las medias son iguales”.
- Un valor **p**, de manera que $100 \cdot (1-p)$ indica el porcentaje de confianza de que exista una diferencia estadísticamente significativa entre las medias. Si está próximo al 95 % indicará que la hipótesis nula podría ser descartada.

4.1. Caso ID1: Opt – SGD, Loss – MSE, Lay 1 – 16, Epoch 10000.




Figura 12: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 13: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 14: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 17.85 %.
pZa	0.8215	
hZi	0	
pZi	0.8215	
hZd	0	
pZd	0.8215	

Tabla 4: Test de Student, ID1 (SGD – MSE – 1 CO – 16 N – 10000).

4.2. Caso ID2: Opt – SGD, Loss – MSE, Lay 1 – 16, Epoch 20000.




Figura 15: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 16: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 17: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 13.36 %.
pZa	0.8664	
hZi	0	
pZi	0.8664	
hZd	0	
pZd	0.8664	

Tabla 5: Test de Student, ID2 (SGD – MSE – 1 CO – 16 N – 20000).

4.3. Caso ID3: Opt – SGD, Loss – MSE, Lay 1 – 32, Epoch 10000.




Figura 18: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 19: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 20: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 23.47 %.
pZa	0.7653	
hZi	0	
pZi	0.7653	
hZd	0	
pZd	0.7653	

Tabla 6: Test de Student, ID3 (SGD – MSE – 1 CO – 32 N – 10000).

4.4. Caso ID4: Opt – SGD, Loss – MSE, Lay 1 – 32, Epoch 20000.




Figura 21: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 22: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 23: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 21.81 %.
pZa	0.7819	
hZi	0	
pZi	0.7819	
hZd	0	
pZd	0.7819	

Tabla 7: Test de Student, ID4 (SGD – MSE – 1 CO – 32 N – 20000).

4.5. Caso ID5: Opt – SGD, Loss – MSE, Lay 2 – 16, Epoch 10000.




Figura 24: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 25: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 26: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 2.13 %.
pZa	0.9787	
hZi	0	
pZi	0.9787	
hZd	0	
pZd	0.9787	

Tabla 8: Test de Student, ID5 (SGD – MSE – 2 CO – 16 N – 10000).

4.6. Caso ID6: Opt – SGD, Loss – MSE, Lay 2 – 16, Epoch 20000.




Figura 27: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 28: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 29: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 2.25 %.
pZa	0.9775	
hZi	0	
pZi	0.9775	
hZd	0	
pZd	0.9775	

Tabla 9: Test de Student, ID6 (SGD – MSE – 2 CO – 16 N – 20000).

4.7. Caso ID7: Opt – SGD, Loss – MSE, Lay 2 – 32, Epoch 10000.




Figura 30: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 31: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 32: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 9.96 %.
pZa	0.9004	
hZi	0	
pZi	0.9004	
hZd	0	
pZd	0.9004	

Tabla 10: Test de Student, ID7 (SGD – MSE – 2 CO – 32 N – 10000).

4.8. Caso ID8: Opt – SGD, Loss – MSE, Lay 2 – 32, Epoch 20000.




Figura 33: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 34: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 35: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 0.79 %.
pZa	0.9921	
hZi	0	
pZi	0.9921	
hZd	0	
pZd	0.9921	

Tabla 11: Test de Student, ID8 (SGD – MSE – 2 CO – 32 N – 20000).

4.9. Caso ID9: Opt – SGD, Loss – MAE, Lay 1 – 16, Epoch 10000.




Figura 36: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 37: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 38: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

El Test de Student realizado aportó los siguientes resultados:

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 61.03 %.
pZa	0.3897	
hZi	0	
pZi	0.3897	
hZd	0	
pZd	0.3897	

Tabla 12: Test de Student, ID9 (SGD – MAE – 1 CO – 16 N – 10000).

4.10. Caso ID10: Opt – SGD, Loss – MAE, Lay 1 – 16, Epoch 20000.




Figura 39: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 40: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 41: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

El Test de Student realizado aportó los siguientes resultados:

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 53.21 %.
pZa	0.4679	
hZi	0	
pZi	0.4679	
hZd	0	
pZd	0.4679	

Tabla 13: Test de Student, ID10 (SGD – MAE – 1 CO – 16 N – 20000).

4.11. Caso ID11: Opt – SGD, Loss – MAE, Lay 1 – 32, Epoch 10000.




Figura 42: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 43: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 44: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

El Test de Student realizado aportó los siguientes resultados:

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 70.69 %.
pZa	0.2931	
hZi	0	
pZi	0.2931	
hZd	0	
pZd	0.2931	

Tabla 14: Test de Student, ID11 (SGD – MAE – 1 CO – 32 N – 10000).

4.12. Caso ID12: Opt – SGD, Loss – MAE, Lay 1 – 32, Epoch 20000.




Figura 45: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 46: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 47: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

El Test de Student realizado aportó los siguientes resultados:

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 48.48 %.
pZa	0.5152	
hZi	0	
pZi	0.5152	
hZd	0	
pZd	0.5152	

Tabla 15: Test de Student, ID12 (SGD – MAE – 1 CO – 32 N – 20000).

4.13. Caso ID13: Opt – SGD, Loss – MAE, Lay 2 – 16, Epoch 10000.




Figura 48: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 49: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 50: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) puede ser descartada: • $h=1$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 99.98 %.
pZa	1.94e-4	
hZi	0	
pZi	1.94e-4	
hZd	0	
pZd	1.94e-4	

Tabla 16: Test de Student, ID13 (SGD – MAE – 2 CO – 16 N – 10000).

4.14. Caso ID14: Opt – SGD, Loss – MAE, Lay 2 – 16, Epoch 20000.




Figura 51: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 52: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 53: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 88.36 %.
pZa	0.1164	
hZi	0	
pZi	0.1164	
hZd	0	
pZd	0.1164	

Tabla 17: Test de Student, ID14 (SGD – MAE – 2 CO – 16 N – 20000).

4.15. Caso ID15: Opt – SGD, Loss – MAE, Lay 2 – 32, Epoch 10000.




Figura 54: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 55: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 56: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 8.83 %.
pZa	0.9117	
hZi	0	
pZi	0.9117	
hZd	0	
pZd	0.9117	

Tabla 18: Test de Student, ID15 (SGD – MAE – 2 CO – 32 N – 10000).

4.16. Caso ID16: Opt – SGD, Loss – MAE, Lay 2 – 32, Epoch 20000.




Figura 57: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 58: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 59: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • h=0. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 69.15 %.
pZa	0.3085	
hZi	0	
pZi	0.3085	
hZd	0	
pZd	0.3085	

Tabla 19: Test de Student, ID16 (SGD – MAE – 2 CO – 32 N – 20000).

4.17. Caso ID17: Opt – Adam, Loss – MSE, Lay 1 – 16, Epoch 10000.




Figura 60: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 61: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 62: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • h=0. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 10.80 %.
pZa	0.8920	
hZi	0	
pZi	0.8920	
hZd	0	
pZd	0.8920	

Tabla 20: Test de Student, ID17 (Adam – MSE – 1 CO – 16 N – 10000).

4.18. Caso ID18: Opt – Adam, Loss – MSE, Lay 1 – 16, Epoch 20000.




Figura 63: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 64: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 65: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • h=0. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 15.18 %.
pZa	0.8482	
hZi	0	
pZi	0.8482	
hZd	0	
pZd	0.8482	

Tabla 21: Test de Student, ID18 (Adam – MSE – 1 CO – 16 N – 20000).

4.19. Caso ID19: Opt – Adam, Loss – MSE, Lay 1 – 32, Epoch 10000.




Figura 66: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 67: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 68: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 1.30 %.
pZa	0.9870	
hZi	0	
pZi	0.9870	
hZd	0	
pZd	0.9870	

Tabla 22: Test de Student, ID19 (Adam – MSE – 1 CO – 32 N – 10000).

4.20. Caso ID20: Opt – Adam, Loss – MSE, Lay 1 – 32, Epoch 20000.




Figura 69: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 70: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 71: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 26.57 %.
pZa	0.7343	
hZi	0	
pZi	0.7343	
hZd	0	
pZd	0.7343	

Tabla 23: Test de Student, ID20 (Adam – MSE – 1 CO – 32 N – 20000).

4.21. Caso ID21: Opt – Adam, Loss – MSE, Lay 2 – 16, Epoch 10000.




Figura 72: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 73: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 74: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 6.28 %.
pZa	0.9372	
hZi	0	
pZi	0.9372	
hZd	0	
pZd	0.9372	

Tabla 24: Test de Student, ID21 (Adam – MSE – 2 CO – 16 N – 10000).

4.22. Caso ID22: Opt – Adam, Loss – MSE, Lay 2 – 16, Epoch 20000.




Figura 75: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 76: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 77: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 12.61 %.
pZa	0.8739	
hZi	0	
pZi	0.8739	
hZd	0	
pZd	0.8739	

Tabla 25: Test de Student, ID22 (Adam – MSE – 2 CO – 16 N – 20000).

4.23. Caso ID23: Opt – Adam, Loss – MSE, Lay 2 – 32, Epoch 10000.




Figura 78: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 79: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 80: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 24.79 %.
pZa	0.7521	
hZi	0	
pZi	0.7521	
hZd	0	
pZd	0.7521	

Tabla 26: Test de Student, ID23 (Adam – MSE – 2 CO – 32 N – 10000).

4.24. Caso ID24: Opt – Adam, Loss – MSE, Lay 2 – 32, Epoch 20000.




Figura 81: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 82: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 83: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 2.74 %.
pZa	0.9726	
hZi	0	
pZi	0.9726	
hZd	0	
pZd	0.9726	

Tabla 27: Test de Student, ID24 (Adam – MSE – 2 CO – 32 N – 20000).

4.25. Caso ID25: Opt – Adam, Loss – MAE, Lay 1 – 16, Epoch 10000.




Figura 84: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 85: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 86: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 26.30 %.
pZa	0.7370	
hZi	0	
pZi	0.7370	
hZd	0	
pZd	0.7370	

Tabla 28: Test de Student, ID25 (Adam – MAE – 1 CO – 16 N – 10000).

4.26. Caso ID26: Opt – Adam, Loss – MAPE, Lay 1 – 16, Epoch 20000.




Figura 87: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 88: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 89: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 2.39 %.
pZa	0.9761	
hZi	0	
pZi	0.9761	
hZd	0	
pZd	0.9761	

Tabla 29: Test de Student, ID26 (Adam – MAE – 1 CO – 16 N – 20000).

4.27. Caso ID27: Opt – Adam, Loss – MAE, Lay 1 – 32, Epoch 10000.




Figura 90: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 91: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 92: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 25.49 %.
pZa	0.7451	
hZi	0	
pZi	0.7451	
hZd	0	
pZd	0.7451	

Tabla 30: Test de Student, ID27 (Adam – MAE – 1 CO – 32 N – 10000).

4.28. Caso ID28: Opt – Adam, Loss – MAPE, Lay 1 – 32, Epoch 20000.




Figura 93: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 94: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 95: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 25.75 %.
pZa	0.7425	
hZi	0	
pZi	0.7425	
hZd	0	
pZd	0.7425	

Tabla 31: Test de Student, ID28 (Adam – MAE – 1 CO – 32 N – 20000).

4.29. Caso ID29: Opt – Adam, Loss – MAE, Lay 2 – 16, Epoch 10000.




Figura 96: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 97: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 98: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 10.09 %.
pZa	0.8991	
hZi	0	
pZi	0.8991	
hZd	0	
pZd	0.8991	

Tabla 32: Test de Student, ID29 (Adam – MAE – 2 CO – 16 N – 10000).

4.30. Caso ID30: Opt – Adam, Loss – MAE, Lay 2 – 16, Epoch 20000.




Figura 99: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 100: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 101: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 3.70 %.
pZa	0.9630	
hZi	0	
pZi	0.9630	
hZd	0	
pZd	0.9630	

Tabla 33: Test de Student, ID30 (Adam – MAE – 2 CO – 16 N – 20000).

4.31. Caso ID31: Opt – Adam, Loss – MAE, Lay 2 – 32, Epoch 10000.




Figura 102: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 103: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 104: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 5.25 %.
pZa	0.9475	
hZi	0	
pZi	0.9475	
hZd	0	
pZd	0.9475	

Tabla 34: Test de Student, ID31 (Adam – MAE – 2 CO –32 N – 10000).

4.32. Caso ID32: Opt – Adam, Loss – MAPE, Lay 2 – 32, Epoch 20000.




Figura 105: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 106: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 107: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 3.72 %.
pZa	0.9628	
hZi	0	
pZi	0.9628	
hZd	0	
pZd	0.9628	

Tabla 35: Test de Student, ID32 (Adam – MAE – 2 CO –32 N – 20000).

4.33. Caso ID33: Opt – RMSprop, Loss – MSE, Lay 1 – 16, Epoch 10000.




Figura 108: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 109: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 110: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 38.45 %.
pZa	0.6155	
hZi	0	
pZi	0.6155	
hZd	0	
pZd	0.6155	

Tabla 36: Test de Student, ID33 (RMSprop – MSE – 1 CO –16 N – 10000).

4.34. Caso ID34: Opt – RMSprop, Loss – MSE, Lay 1 – 16, Epoch 20000.




Figura 111: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 112: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 113: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 61.52 %.
pZa	0.3848	
hZi	0	
pZi	0.3848	
hZd	0	
pZd	0.3848	

Tabla 37: Test de Student, ID34 (RMSprop – MSE – 1 CO –16 N – 20000).

4.35. Caso ID35: Opt – RMSprop, Loss – MSE, Lay 1 – 32, Epoch 10000.




Figura 114: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 115: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 116: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 6.45 %.
pZa	0.9355	
hZi	0	
pZi	0.9355	
hZd	0	
pZd	0.9355	

Tabla 38: Test de Student, ID35 (RMSprop – MSE – 1 CO –32 N – 10000).

4.36. Caso ID36: Opt – RMSprop, Loss – MSE, Lay 1 – 32, Epoch 20000.




Figura 117: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 118: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 119: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: $h=0$. - La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 6.32 %.
pZa	0.9368	
hZi	0	
pZi	0.9368	
hZd	0	
pZd	0.9368	

Tabla 39: Test de Student, ID36 (RMSprop – MSE – 1 CO – 32 N – 20000).

4.37. Caso ID37: Opt – RMSprop, Loss – MSE, Lay 2 – 16, Epoch 10000.




Figura 120: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 121: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 122: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 72.86 %.
pZa	0.2714	
hZi	0	
pZi	0.2714	
hZd	0	
pZd	0.2714	

Tabla 40: Test de Student, ID37 (RMSprop – MSE – 2 CO –16 N – 10000).

4.38. Caso ID38: Opt – RMSprop, Loss – MSE, Lay 2 – 16, Epoch 20000.




Figura 123: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 124: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 125: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 38.51 %.
pZa	0.6149	
hZi	0	
pZi	0.6149	
hZd	0	
pZd	0.6149	

Tabla 41: Test de Student, ID38 (RMSprop – MSE – 2 CO –16 N – 20000).

4.39. Caso ID39: Opt – RMSprop, Loss – MSE, Lay 2 – 32, Epoch 10000.




Figura 126: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 127: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 128: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 68.95 %.
pZa	0.3105	
hZi	0	
pZi	0.3105	
hZd	0	
pZd	0.3105	

Tabla 42: Test de Student, ID39 (RMSprop – MSE – 2 CO – 32 N – 10000).

4.40. Caso ID40: Opt – RMSprop, Loss – MSE, Lay 2 – 32, Epoch 20000.




Figura 129: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 130: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 131: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 61.54 %.
pZa	0.3846	
hZi	0	
pZi	0.3846	
hZd	0	
pZd	0.3846	

Tabla 43: Test de Student, ID40 (RMSprop – MSE – 2 CO – 32 N – 20000).

4.41. Caso ID41: Opt – RMSprop, Loss – MAE, Lay 1 – 16, Epoch 10000.




Figura 132: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 133: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 134: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 27.30 %.
pZa	0.7270	
hZi	0	
pZi	0.7270	
hZd	0	
pZd	0.7270	

Tabla 44: Test de Student, ID41 (RMSprop – MAE – 1 CO –16 N – 10000).

4.42. Caso ID42: Opt – RMSprop, Loss – MPE, Lay 1 – 16, Epoch 20000.




Figura 135: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 136: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 137: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 1.68 %.
pZa	0.9832	
hZi	0	
pZi	0.9832	
hZd	0	
pZd	0.9832	

Tabla 45: Test de Student, ID42 (RMSprop – MAE – 1 CO –16 N – 20000).

4.43. Caso ID43: Opt – RMSprop, Loss – MAPE, Lay 1 – 32, Epoch 10000.




Figura 138: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 139: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 140: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 11.71 %.
pZa	0.8829	
hZi	0	
pZi	0.8829	
hZd	0	
pZd	0.8829	

Tabla 46: Test de Student, ID43 (RMSprop – MAE – 1 CO –32 N – 10000).

4.44. Caso ID44: Opt – RMSprop, Loss – MAE, Lay 1 – 32, Epoch 20000.




Figura 141: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 142: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 143: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 48.82 %.
pZa	0.5118	
hZi	0	
pZi	0.5118	
hZd	0	
pZd	0.5118	

Tabla 47: Test de Student, ID44 (RMSprop – MAE – 1 CO –32 N – 20000).

4.45. Caso ID45: Opt – RMSprop, Loss – MAE, Lay 2 – 16, Epoch 10000.




Figura 144: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 145: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 146: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 62.77 %.
pZa	0.3723	
hZi	0	
pZi	0.3723	
hZd	0	
pZd	0.3723	

Tabla 48: Test de Student, ID45 (RMSprop – MAE – 2 CO –16 N – 10000).

4.46. Caso ID46: Opt – RMSprop, Loss – MAE, Lay 2 – 16, Epoch 20000.




Figura 147: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 148: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 149: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 46.14 %.
pZa	0.5386	
hZi	0	
pZi	0.5386	
hZd	0	
pZd	0.5386	

Tabla 49: Test de Student, ID46 (RMSprop – MAE – 2 CO –16 N – 20000).

4.47. Caso ID47: Opt – RMSprop, Loss – MAE, Lay 2 – 32, Epoch 10000.




Figura 150: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 151: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 152: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 65.77 %.
pZa	0.3423	
hZi	0	
pZi	0.3423	
hZd	0	
pZd	0.3423	

Tabla 50: Test de Student, ID47 (RMSprop – MAE – 2 CO – 32 N – 10000).

4.48. Caso ID48: Opt – RMSprop, Loss – MAE, Lay 2 – 32, Epoch 20000.




Figura 153: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 154: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 155: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 38.83 %.
pZa	0.6117	
hZi	0	
pZi	0.6117	
hZd	0	
pZd	0.6117	

Tabla 51: Test de Student, ID48 (RMSprop – MAE – 2 CO – 32 N – 20000).

4.49. Resumen de resultados.

ID	Confianza diferencia significativa (%)
1	17.85
2	13.36
3	23.47
4	21.81
5	2.13
6	2.25
7	9.96
8	0.79
9	61.03
10	53.21
11	70.69
12	48.48
13	99.98
14	88.36
15	8.83
16	69.15
17	10.80
18	15.18
19	1.30
20	26.57
21	6.26
22	12.61
23	24.79
24	2.74
25	26.30
26	2.39
27	25.45
28	25.75
29	10.09
30	3.70
31	5.25
32	3.72
33	38.45
34	61.25
35	6.45
36	6.32
37	72.86
38	38.51
39	68.95
40	61.54
41	27.30
42	1.68
43	11.71
44	48.82
45	62.77
46	46.14
47	65.77
48	38.83

Tabla 52: Resumen de resultados.

5. CONCLUSIONES Y LÍNEAS FUTURAS.


5.1. Conclusiones.

La Tabla 52 muestra el resumen de los resultados obtenidos tras la experimentación. Con el propósito de analizar los casos con mejor comportamiento esperado, se han extraído aquellas soluciones que aportaron una confianza en que existe una diferencia estadísticamente significativa entre las medias inferior al 3%. Estos casos se muestran mediante la Tabla 53.


ID	Confianza diferencia significativa (%)
5	2.13
6	2.25
8	0.79
19	1.30
24	2.74
26	2.39
42	1.68

Tabla 53: Resumen de los mejores resultados.


En los resultados gráficos aportados para cada caso existen diferencias notables. Estas se manifiestan de manera más incisiva en el caso de la Zona de Alerta como se muestra mediante las Figuras 156 a 158.



Aproximación de ZA para ID5



Aproximación de ZA para ID6



Aproximación de ZA para ID8

Figura 156: Aproximación de ZA para experimentos con Opt "SGD".



Figura 157: Aproximación de ZA para experimentos con Opt "Adam".




Figura 158: Aproximación de ZA para experimentos con Opt "RMStrop".

Como se observa, las diferencias más notables entre las distancias obtenidas mediante el modelo matemático y las obtenidas mediante la aproximación a través de la Red Neuronal, se encuentran cuando las masas son más pequeñas. Para profundizar en esta cuestión se ha considerado realizar un nuevo Test de Student para estos casos, escogiendo únicamente los 100 primeros valores de masa disponibles en el conjunto de test. El resultado se muestra por medio de la Tabla 159.








	Caso ID5 H=1		Caso ID24 H=0 Confianza en que exista diferencia significativa: 26.68%
	Caso ID6 H=1		Caso ID26 H=1
	Caso ID8 H=1		Caso ID42 H=1
	Caso ID19 H=0 Confianza en que exista diferencia significativa: 85.27%		

Figura 159: Resultado del Test de Student para los 100 primeros valores de masa.

Se observa como en las condiciones para las que se ha ejecutado el experimento (habiendo escogido únicamente las primeras 100 masas disponibles en el conjunto de test), para los casos ID5, ID6, ID8, ID26 e ID42 se rechaza la hipótesis nula (lo que implica que las medias de ambas muestras no son iguales, estableciéndose de este modo la diferencia entre las mismas).

Sin embargo, para los casos ID 19 e ID24, la hipótesis nula no puede ser rechazada, estableciendo una confianza en que existe una diferencia estadística significativa entre las medias del 85.27% para el primer caso, y del 26.68% en el segundo, quedando esta última más alejada del 95%. **Es por tanto que es el caso ID24 el que mejor se comporta en relación al experimento. Este empleó el Optimizador “Adam”, con una función de pérdidas “MSE”, 2 capas ocultas con 32 neuronas cada una, iterada durante 20000 “Epoch”.**

Con el propósito de comprobar que los parámetros de ajuste para la Red Neuronal resultan válidos cuando se emplean datos no usados en el conjunto de aprendizaje, se ha realizado un nuevo experimento. En este caso, se emplearon para la predicción de la salida de la red todas aquellas masas no incluidas previamente en los conjuntos de entrenamiento y de test, es decir, si se emplearon 15.000 datos de masa entre 1 y 20.000 kilogramos para generar los conjuntos de entrenamiento y de test, se han empleado para realizar la predicción tras el ajuste de la Red Neuronal todas aquellas masas no contempladas en estos conjuntos.




Figura 160: ZA mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 161: ZI mediante modelo matemático (azul) Vs red neuronal (rojo).




Figura 162: ZD mediante modelo matemático (azul) Vs red neuronal (rojo).

Parámetros	Valores	Interpretación
hZa	0	La hipótesis nula (las medias son iguales) no puede ser descartada: • $h=0$. • La confianza en que existe una diferencia estadísticamente significativa entre las medias es del 20.25%.
pZa	0.7975	
hZi	0	
pZi	0.7975	
hZd	0	
pZd	0.7975	

Tabla 54: Test de Student para las predicciones con datos no contemplados a priori.

Mediante las Figuras 160 a 162 se muestra el resultado gráfico obtenido. La Tabla 54 muestra el resultado del Test de Student practicado. Como se observa, tanto a nivel gráfico como estadístico, el resultado obtenido del experimento final resulta ser satisfactorio.

5.2. Líneas futuras.

El empleo de redes neuronales con el objetivo de predecir las consecuencias de la detonación de un explosivo ha resultado exitoso. Las consecuencias de los accidentes graves que pueden tener lugar en la industria pueden estar relacionadas con otras sustancias y otros efectos, sirvan de ejemplo:

- Consecuencias en relación a fenómenos peligrosos del tipo mecánico [8]:
 - o Explosión de una nube de vapor confinada.
 - o Explosión de una nube de vapores no confinada.
 - o Estallido de un depósito.
 - o Proyección de fragmentos.
- Consecuencias en relación a fenómenos peligrosos del tipo térmico [13]:
 - o Incendio de charco o depósito.
 - o Dardo de fuego.
 - o Bola de fuego.
 - o Incendio flash.
- Consecuencias en relación a fenómenos peligrosos del tipo tóxico [14]:
 - o Nubes tóxicas.

Es por tanto que podría ampliarse el empleo de redes neuronales para la aproximación del efecto derivado de accidentes industriales que involucran otras sustancias peligrosas y otras consecuencias diferentes a las analizadas para el presente Trabajo Fin de Máster.

6. BIBLIOGRAFÍA.

- [1] La Seguridad Industrial, Fundamentos y Aplicaciones. Iniciativa ATYCA (Programa de Calidad y Seguridad Industrial) Ministerio de Industria y Energía y Fundación para el fomento de la innovación industrial.
- [2] Real Decreto 840/2015, de 21 de septiembre, por el que se aprueban medidas de control de los riesgos inherentes a los accidentes graves en los que intervengan sustancias peligrosas.
- [3] Real Decreto 1196/2003, de 19 de septiembre, por el que se aprueba la Directriz básica de protección civil para el control y planificación ante el riesgo de accidentes graves en los que intervienen sustancias peligrosas.
- [4] Guerra, C. Inteligencia Artificial. <https://cayetanoguerra.github.io/ia/>. Universidad de Las Palmas de Gran Canaria.
- [5] Lee's Loss Prevention in the Process Industries, Third Edition, by Sam Mannan. Volumen 3. ISBN-0-7506-7589-3.
- [6] Pérez, F., Fernández, H. "*Las redes neuronales y la evaluación del riesgo de crédito*". Revista de Ingeniería Universidad de Medellín. Vol.6 no.10 Medellín June 2007.
- [7] Fernando Díaz Alonso. Tesis Doctoral titulada "*Análisis de consecuencias y zonas de planificación para explosiones industriales accidentales (en el ámbito de las directivas SEVESO)*". Universidad de Murcia, Facultad de Química, Departamento de Ingeniería Química.
- [8] Díaz, F., González, E., Sánchez, J., Miñana, A. Ruiz, J., Martínez, J. "*Characteristic overpressure–impulse–distance curves for the detonation of explosives, pyrotechnics or unstable substances*". Journal of Loss Prevention in the process industries 19 (2006) 724-728.
- [9] Keras Documentation. <https://keras.io/>.
- [10] "TensorFlow: Open source machine learning" "It is machine learning software being used for various kinds of perceptual and language understanding tasks" — Jeffrey Dean, minute 0:47 / 2:17 from Youtube clip.

- [11] Luis Llano et al. “*Comparación del Desempeño de Funciones de Activación en Redes Feedforward para aproximar Funciones de Datos con y sin Ruido*”. Revista Avances en Sistemas e Informática, Vol.4 No. 2, Septiembre de 2007, Medellín, ISSN 1657-7663 Edición Especial: II Congreso Colombiano de Computación CCC2007.
- [12] Jason Brownlee. “*Regression Tutorial with the Keras Deep Learning Library in Python*”. <https://machinelearningmastery.com>. June 9, 2016.
- [13] Zonas de planificación para accidentes graves de tipo térmico. Departamento de Ingeniería Química de la Universidad de Murcia. Dirección General de Protección Civil. Ministerio del Interior. 2002.
- [14] Zonas de planificación para accidentes graves de tipo tóxico. Departamento de Ingeniería Química de la Universidad de Murcia. Dirección General de Protección Civil. Ministerio del Interior. 2003.

7. ANEXOS.

7.1. Modelo del TNT equivalente (MATLAB).

```
% Lectura del fichero generado previamente.
% Sustancia, Equivalencia TNT, Cantidad mínima de explosivo [kg],
% Cantidad máxima de explosivo [kg], número de simulaciones para set.

fID = fopen('Informacion.txt');           % Apertura del fichero.
lin=fgetl(fID);                           % Devuelve la siguiente línea.
posB=find(lin==',');                      % Localiza la primera coma.
sustancia=lin(1:posB(1)-1);               % Extrae el Nombre (final: coma -1).
equi_TNT=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Masa equivalente.
masa_min=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Masa mínima.
masa_max=str2double(lin(posB(3)+1:posB(4)-1)); % Extrae Masa máxima.
Genera_set=str2double(lin(posB(4)+1:end)); % Número de simulaciones para el set.

% Genera un conjunto aleatorio de cantidades de masa explosiva.
vector_masa=randi([masa_min,masa_max],1,genera_set);

for i=1:length(vector_masa)
    masa_equivalente=vector_masa(i)*equi_TNT;
    % Cálculo z escalada:
    % Zona de Alerta escalada (5000 Pascales).
    distancia_p5000=exp(log(5000/(1.83*1e5))/-1.16);
    % Zona de Intervención escalada (12500 Pascales).
    distancia_p12500=exp(log(12500/(1.13*1e6))/-2.01);
    % Zona de Efecto Dominó escalada (16000 Pascales).
    distancia_p16000=exp(log(16000/(1.13*1e6))/-2.01);
    % Cálculo z:
    % Zona de Alerta (5000 Pascales).
    distancia_5000(i)=distancia_p5000*(masa_equivalente^(1/3));
    % Zona de Intervención (12500 Pascales).
    distancia_12500(i)=distancia_p12500*(masa_equivalente^(1/3));
    % Zona de Efecto Dominó (16000 Pascales).
    distancia_16000(i)=distancia_p16000*(masa_equivalente^(1/3));
end

figure()
plot (vector_masa,distancia_5000,'x');
title 'Zona de Alerta';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

figure()
plot (vector_masa,distancia_12500,'x');
title 'Zona de Intervencion';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

figure()
plot (vector_masa,distancia_16000,'x');
title 'Zona de Efecto Domino';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;
% Escritura del fichero con los resultados.

train=round(length(vector_masa)*0.6); % Diferencia entre conjunto de entrenamiento...
test=length(vector_masa)-train;      % ... y conjunto de test.
```

```
fID=fopen('solucionesTrain.txt','wt'); % Crea fichero de salida "Train"
formato='%5.5f %5.5f %5.5f %5.5f\n'; % Define formato.
    for i=1:train % Para cada masa inserta...
        fprintf(fID,'%5.5f, ',vector_masa(i)); % ... masa, ...
        fprintf(fID,'%5.5f, ',distancia_5000(i)); % ... Zona de Alerta, ...
        fprintf(fID,'%5.5f, ',distancia_12500(i)); % ... Zona de Intervención, ...
        fprintf(fID,'%5.5f \n',distancia_16000(i)); % ... Zona de Efecto Dominó.
    end

fclose(fID);

formato='%5.5f %5.5f %5.5f %5.5f\n'; % Define formato.
    for i=1:train+test % Para cada masa inserta...
        fprintf(fID,'%5.5f, ',vector_masa(i)); % ... masa, ...
        fprintf(fID,'%5.5f, ',distancia_5000(i)); % ... Zona de Alerta, ...
        fprintf(fID,'%5.5f, ',distancia_12500(i)); % ... Zona de Intervención, ...
        fprintf(fID,'%5.5f \n',distancia_16000(i)); % ... Zona de Efecto Dominó.
    end

fclose(fID);
```

7.2. Normalización de datos de entrada y salida (MATLAB).

```
% Lectura del fichero SOLUCIONES generado previamente.
% masa, zona de alerta, zona de intervención, zona efecto dominó.

fID = fopen('solucionesTrain.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTrain(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
    zaTrain(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTrain(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTrain(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

fID = fopen('solucionesTest.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTest(i)=str2double(lin(1:posB(1)-1)); % Extrae masa (termina en coma -1).
    zaTest(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTest(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTest(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

% Normalización entre 0.1 y 0.9 (aproximadamente).

masa_minima=min(min(masaTrain),min(masaTest)); % Busca el mín y máx de variable
masa_maxima=max(max(masaTrain),max(masaTest));
za_minima=min(min(zaTrain),min(zaTest));
za_maxima=max(max(zaTrain),max(zaTest));
zi_minima=min(min(ziTrain),min(ziTest));
zi_maxima=max(max(ziTrain),max(ziTest));
zd_minima=min(min(zdTrain),min(zdTest));
zd_maxima=max(max(zdTrain),max(zdTest));

nuevoIntervalo=0.8;                          % 0.9 - 0.1

%Normaliza en conjunto de entrenamiento.
masaEscaladaTrain=0.1+(masaTrain-masa_minima)*nuevoIntervalo/(masa_maxima-masa_minima);
zaEscaladaTrain=0.1+(zaTrain-za_minima)*nuevoIntervalo/(za_maxima-za_minima);
ziEscaladaTrain=0.1+(ziTrain-zi_minima)*nuevoIntervalo/(zi_maxima-zi_minima);
zdEscaladaTrain=0.1+(zdTrain-zd_minima)*nuevoIntervalo/(zd_maxima-zd_minima);

%Normaliza el conjunto de test.
masaEscaladaTest=0.1+(masaTest-masa_minima)*nuevoIntervalo/(masa_maxima-masa_minima);
zaEscaladaTest=0.1+(zaTest-za_minima)*nuevoIntervalo/(za_maxima-za_minima);
ziEscaladaTest=0.1+(ziTest-zi_minima)*nuevoIntervalo/(zi_maxima-zi_minima);
zdEscaladaTest=0.1+(zdTest-zd_minima)*nuevoIntervalo/(zd_maxima-zd_minima);

% Escritura del fichero con los resultados.

fID=fopen('solucionesNormalTrain.txt','wt'); % Crea fichero de salida
formato='%5.5f %5.5f %5.5f %5.5f\n';        % Define formato.
for i=1:length(masaTrain)                   % Para cada masa inserta...
    fprintf(fID,'%5.5f ',masaEscaladaTrain(i)); % ... masa, ...
    fprintf(fID,'%5.5f ',zaEscaladaTrain(i));  % ... Zona de Alerta, ...
    fprintf(fID,'%5.5f ',ziEscaladaTrain(i));  % ... Zona de Intervención, ...
    fprintf(fID,'%5.5f \n',zdEscaladaTrain(i)); % ... Zona de Efecto Dominó.
end
```

```
fclose(fID);

fID=fopen('solucionesNormalTest.txt','wt');
formato='%5.5f %5.5f %5.5f %5.5f\n';
for i=1:length(masaTest)
    fprintf(fID,'%5.5f, ',masaEscaladaTest(i));
    fprintf(fID,'%5.5f, ',zaEscaladaTest(i));
    fprintf(fID,'%5.5f, ',ziEscaladaTest(i));
    fprintf(fID,'%5.5f \n',zdEscaladaTest(i));
end
fclose(fID);
```

% Crea fichero de salida
% Define formato.
% Para cada masa inserta...
% ... masa, ...
% ... Zona de Alerta, ...
% ... Zona de Intervención, ...
% ... Zona de Efecto Dominó.

7.3. Entrenamiento, validación y test de la Red Neuron (Python).

```
# ++++++
# LECTURA DEL FICHERO CSV.
# ++++++

import csv, operator

with open('solucionesNormalTrain.txt') as csvarchivo:
    entrada = csv.reader(csvarchivo)

    # Crea listas de datos.
    masaTrain = []
    zaTrain = []
    ziTrain = []
    zdTrain = []

    # Integra datos en listas separadas.
    for reg in entrada:
        masaTrain.append(float(reg[0]))
        zaTrain.append(float(reg[1]))
        ziTrain.append(float(reg[2]))
        zdTrain.append(float(reg[3]))

with open('solucionesNormalTest.txt') as csvarchivo:
    entrada = csv.reader(csvarchivo)

    # Crea listas de datos.
    masaTest = []
    zaTest = []
    ziTest = []
    zdTest = []

    # Integra datos en listas separadas.
    for reg in entrada:
        masaTest.append(float(reg[0]))
        zaTest.append(float(reg[1]))
        ziTest.append(float(reg[2]))
        zdTest.append(float(reg[3]))

with open('solucionesNormalFinalTest.txt') as csvarchivo:
    entrada = csv.reader(csvarchivo)

    # Crea listas de datos.
    masaTestFinal = []
    zaTestFinal = []
    ziTestFinal = []
    zdTestFinal = []

    # Integra datos en listas separadas.
    for reg in entrada:
        masaTestFinal.append(float(reg[0]))
        zaTestFinal.append(float(reg[1]))
        ziTestFinal.append(float(reg[2]))
        zdTestFinal.append(float(reg[3]))

# Impresión para punto de ruptura.
print ("Cargué los datos")

# ++++++
# KERAS - MODELO SECUENCIAL.
# ++++++

from keras.models import Sequential
```

```
from keras.layers import Dense, Dropout, Activation
from keras import optimizers

# Especificaciones para la capa de entrada.
model=Sequential()
model.add(Dense(32, input_dim=1))
model.add(Activation('tanh'))
model.add(Dense(32))
model.add(Activation('tanh'))
model.add(Dense(1))
model.add(Activation('tanh'))

initial_weights= model.get_weights()

# ++++++
# Caso TEST_FINAL.
# OPTIMIZADOR: ADAM.
# PÉRDIDAS: ERROR CUADRÁTICO MEDIO.
# EPOCH: 20000.
# ++++++

# Configuro pesos iniciales.
model.set_weights(initial_weights)

# Configuración del proceso de aprendizaje.
model.compile(optimizer='adam', loss='mean_squared_error')

# Entrenamiento con datos de entrada en "batches" de 1000 muestras.
model.fit(masaTrain, zaTrain, epochs=20000, batch_size=1000)
print("Fin del entrenamiento")

# Evaluación de la solución: Error cuadrático medio cometido.
score = model.evaluate(masaTest, zaTest, batch_size=1000)
print("")
print("Para FINAL_TEST el error cometido es ...", score)
print("")

# Evaluación de la solución: Predicción de datos de salida de la red.
predicciones = model.predict(masaTestFinal, batch_size=100)

# ESCRITURA DEL FICHERO CSV.

csvsalida = open("salidaPrediccionesFINAL_TEST.csv", "w")
for elemento in predicciones:
    csvsalida.write('%f \n' % elemento)
csvsalida.close()

print("El proceso de ha terminado")
```

7.4. Desnormalización y Test de Student (MATLAB).

```
clear all

% Lectura del fichero SOLUCIONES de Test generado previamente.
% masa, zona de alerta, zona de intervención, zona efecto dominó.

fID = fopen('solucionesTrain.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTrain(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
    zaTrain(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTrain(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTrain(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

fID = fopen('solucionesTest.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTest(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
    zaTest(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTest(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTest(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

% Desnormalización.

masa_minima=min(min(masaTrain),min(masaTest)); % Busca el mínimo y máximo de cada variable.
masa_maxima=max(max(masaTrain),max(masaTest));
za_minima=min(min(zaTrain),min(zaTest));
za_maxima=max(max(zaTrain),max(zaTest));
zi_minima=min(min(ziTrain),min(ziTest));
zi_maxima=max(max(ziTrain),max(ziTest));
zd_minima=min(min(zdTrain),min(zdTest));
zd_maxima=max(max(zdTrain),max(zdTest));

Intervalo=0.8;                               % 0.9 - 0.1

% Lectura del fichero de soluciones aportado por la red.

fID = fopen('salidaPrediccionesID24v2_200000.csv'); % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    prediccion(i)=str2double(lin);           % Extrae las predicciones de la red.
end

% Desnormaliza el conjunto de test.
prediccionZa=((prediccion-0.1)*(za_maxima-za_minima)+(za_minima*(Intervalo)))/(Intervalo);
prediccionZi=((prediccion-0.1)*(zi_maxima-zi_minima)+(zi_minima*(Intervalo)))/(Intervalo);
prediccionZd=((prediccion-0.1)*(zd_maxima-zd_minima)+(zd_minima*(Intervalo)))/(Intervalo);

% Grafica los resultados.

figure()
plot (masaTest,zaTest,'x');
hold on
```



```
plot (masaTest,prediccionZa,'or');
title 'Zona de Alerta';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

figure()
plot (masaTest,ziTest,'x');
hold on
plot (masaTest,prediccionZi,'or');
title 'Zona de Intervencion';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

figure()
plot (masaTest,zdTest,'x');
hold on
plot (masaTest,prediccionZd,'or');
title 'Zona de Efecto Domino';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

% Test de Student.

[hZa,pZa]=TTEST2(zaTest,prediccionZa,0.05);
[hZi,pZi]=TTEST2(ziTest,prediccionZi,0.05);
[hZd,pZd]=TTEST2(zdTest,prediccionZd,0.05);

InvPZa=1-pZa;
InvPZi=1-pZi;
InvPZd=1-pZd;
```

7.5. Test de Student para las 100 primeras masas (MATLAB).

```
clear all

% Lectura del fichero SOLUCIONES de Test generado previamente.
% masa, zona de alerta, zona de intervención, zona efecto dominó.

fID = fopen('solucionesTrain.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTrain(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
    zaTrain(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTrain(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTrain(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

fID = fopen('solucionesTest.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTest(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
    zaTest(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTest(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTest(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

% Desnormalización.

masa_minima=min(min(masaTrain),min(masaTest)); % Busca el mínimo y máximo de cada variable.
masa_maxima=max(max(masaTrain),max(masaTest));
za_minima=min(min(zaTrain),min(zaTest));
za_maxima=max(max(zaTrain),max(zaTest));
zi_minima=min(min(ziTrain),min(ziTest));
zi_maxima=max(max(ziTrain),max(ziTest));
zd_minima=min(min(zdTrain),min(zdTest));
zd_maxima=max(max(zdTrain),max(zdTest));

Intervalo=0.8;                               % 0.9 - 0.1

% Lectura del fichero de soluciones aportado por la red.

fID = fopen('salidaPrediccionesID24_200000.csv'); % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    prediccion(i)=str2double(lin);           % Extrae las predicciones de la red.
end

% Desnormaliza el conjunto de test.
prediccionZa=((prediccion-0.1)*(za_maxima-za_minima)+(za_minima*(Intervalo)))/(Intervalo);
prediccionZi=((prediccion-0.1)*(zi_maxima-zi_minima)+(zi_minima*(Intervalo)))/(Intervalo);
prediccionZd=((prediccion-0.1)*(zd_maxima-zd_minima)+(zd_minima*(Intervalo)))/(Intervalo);

% Ordeno de menor a mayor para quedarme con los 50 casos más pequeños.

masaTest=sort(masaTest);
masaTest=masaTest(1:100);
zaTest=sort(zaTest);
```

```
zaTest=zaTest(1:100);
ziTest=sort(ziTest);
ziTest=ziTest(1:100);
zdTest=sort(zdTest);
zdTest=zdTest(1:100);
prediccionZa=sort(prediccionZa);
prediccionZa=prediccionZa(1:100);
prediccionZi=sort(prediccionZi);
prediccionZi=prediccionZi(1:100);
prediccionZd=sort(prediccionZd);
prediccionZd=prediccionZd(1:100);

% Grafica los resultados.

figure()
plot (masaTest,zaTest,'x');
hold on
plot (masaTest,prediccionZa,'or');
title 'Zona de Alerta';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

% figure()
% plot (masaTest,ziTest,'x');
% hold on
% plot (masaTest,prediccionZi,'or');
% title 'Zona de Intervencion';
% xlabel 'Masa [kg]';
% ylabel 'Distancia [m]';
% grid on;
%
% figure()
% plot (masaTest,zdTest,'x');
% hold on
% plot (masaTest,prediccionZd,'or');
% title 'Zona de Efecto Domino';
% xlabel 'Masa [kg]';
% ylabel 'Distancia [m]';
% grid on;

% Test de Student.

[hZa,pZa]=TTEST2(zaTest,prediccionZa,0.05);
[hZi,pZi]=TTEST2(ziTest,prediccionZi,0.05);
[hZd,pZd]=TTEST2(zdTest,prediccionZd,0.05);

InvPZa=1-pZa;
InvPZi=1-pZi;
InvPZd=1-pZd;
```

7.6. Modelo TNT y normalización de datos no usados antes (MATLAB).

```
clear;

% Lectura de ficheros generados previamente.
% Nos quedamos con las masas en un único vector.

fID = fopen('solucionesTrain.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                   % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTrain(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
    zaTrain(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTrain(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTrain(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

fID = fopen('solucionesTest.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                   % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTest(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
    zaTest(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTest(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTest(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

masa=[masaTrain masaTest];

% Extrae la masa máxima.

fID = fopen('Informacion.txt');             % Apertura del fichero.
lin=fgetl(fID);                             % Devuelve la siguiente línea.
posB=find(lin==',');                        % Localiza la primera coma.
sustancia=lin(1:posB(1)-1);                 % Extrae el Nombre (termina en coma -1).
equi_TNT=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Masa equivalente.
masa_min=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Masa mínima.
masa_max=str2double(lin(posB(3)+1:posB(4)-1)); % Extrae Masa máxima.
genera_set=str2double(lin(posB(4)+1:end)); % Número de simulaciones para el set.

% El vector masa debe tener todos aquellos números no usados previamente.

% indice=0;
% for i=1:masa_max
%     valor=find(masa==i);
%     if isempty(valor)
%         indice=indice+1;
%         vector_masa(indice)=i;
%     end
% end

indice=0;
for i=1:masa_max
    if ~ismember(i,masa)
        indice=indice+1;
        vector_masa(indice)=i;
    end
end

% Aleatorizo el vector masa
```

```

vector_masa_aleatorio=randsample(vector_masa,length(vector_masa));
vector_masa=vector_masa_aleatorio;

for i=1:length(vector_masa)
    masa_equivalente=vector_masa(i)*equi_TNT;
    % Cálculo z escalada:
    distancia_p5000=exp(log(5000/(1.83*1e5))/-1.16); % Zona de Alerta escalada (5000 Pascales).
    distancia_p12500=exp(log(12500/(1.13*1e6))/-2.01); % Zona de Intervención escalada (12500
Pascales).
    distancia_p16000=exp(log(16000/(1.13*1e6))/-2.01); % Zona de Efecto Dominó escalada (16000
Pascales).
    % Cálculo z:
    distancia_5000(i)=distancia_p5000*(masa_equivalente^(1/3)); % Z de Alerta (5000 Pascales).
    distancia_12500(i)=distancia_p12500*(masa_equivalente^(1/3)); % Z de Int (12500 Pascales).
    distancia_16000(i)=distancia_p16000*(masa_equivalente^(1/3)); % Z de Dominó (16000 Pascales).
end

figure()
plot (vector_masa,distancia_5000,'x');
title 'Alert Zone';
xlabel 'Mass [kg]';
ylabel 'Distance [m]';
grid on;

figure()
plot (vector_masa,distancia_12500,'x');
title 'Zona de Intervencion';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

figure()
plot (vector_masa,distancia_16000,'x');
title 'Zona de Efecto Domino';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

% Escritura del fichero con los resultados.

fID=fopen('solucionesFinalTest.txt','wt'); % Crea fichero de salida "Train"
formato='%5.5f %5.5f %5.5f %5.5f\n'; % Define formato.
for i=1:length(vector_masa) % Para cada masa inserta...
    fprintf(fID,'%5.5f ',vector_masa(i)); % ... masa, ...
    fprintf(fID,'%5.5f ',distancia_5000(i)); % ... Zona de Alerta, ...
    fprintf(fID,'%5.5f ',distancia_12500(i)); % ... Zona de Intervención, ...
    fprintf(fID,'%5.5f \n',distancia_16000(i)); % ... Zona de Efecto Dominó.
end
fclose(fID);

% Normalización entre 0.1 y 0.9 (aproximadamente).

masa_minima=min(min(masaTrain),min(masaTest)); % Busca el mínimo y máximo de cada variable.
masa_maxima=max(max(masaTrain),max(masaTest));
za_minima=min(min(zaTrain),min(zaTest));
za_maxima=max(max(zaTrain),max(zaTest));
zi_minima=min(min(ziTrain),min(ziTest));
zi_maxima=max(max(ziTrain),max(ziTest));
zd_minima=min(min(zdTrain),min(zdTest));
zd_maxima=max(max(zdTrain),max(zdTest));

nuevoIntervalo=0.8; % 0.9 - 0.1

%Normaliza en conjunto de test final.
masaEscalada=0.1+(vector_masa-masa_minima)*nuevoIntervalo/(masa_maxima-masa_minima);
zaEscalada=0.1+(distancia_5000-za_minima)*nuevoIntervalo/(za_maxima-za_minima);

```

```
ziEscalada=0.1+(distancia_12500-zi_minima)*nuevoIntervalo/(zi_maxima-zi_minima);
zdEscalada=0.1+(distancia_16000)*nuevoIntervalo/(zd_maxima-zd_minima);

% Escritura del fichero con los resultados.

fID=fopen('solucionesNormalFinalTest.txt','wt');           % Crea fichero de salida
formato='%5.5f %5.5f %5.5f %5.5f\n';                     % Define formato.
for i=1:length(vector_masa)                                % Para cada masa inserta...
    fprintf(fID,'%5.5f, ',masaEscalada(i));                % ... masa, ...
    fprintf(fID,'%5.5f, ',zaEscalada(i));                   % ... Zona de Alerta, ...
    fprintf(fID,'%5.5f, ',ziEscalada(i));                   % ... Zona de Intervención, ...
    fprintf(fID,'%5.5f \n',zdEscalada(i));                  % ... Zona de Efecto Dominó.
end
fclose(fID);
```

7.7. Desnormalización y Test de Student para datos no usados.

```
clear all

% Lectura del fichero SOLUCIONES de Test generado previamente.
% masa, zona de alerta, zona de intervención, zona efecto dominó.

fID = fopen('solucionesTrain.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTrain(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
    zaTrain(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTrain(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTrain(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

fID = fopen('solucionesTest.txt');           % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    posB=find(lin==',');                    % Localiza la primera coma.
    masaTest(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
    zaTest(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
    ziTest(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
    zdTest(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
end

% Desnormalización.

masa_minima=min(min(masaTrain),min(masaTest)); % Busca el mínimo y máximo de cada variable.
masa_maxima=max(max(masaTrain),max(masaTest));
za_minima=min(min(zaTrain),min(zaTest));
za_maxima=max(max(zaTrain),max(zaTest));
zi_minima=min(min(ziTrain),min(ziTest));
zi_maxima=max(max(ziTrain),max(ziTest));
zd_minima=min(min(zdTrain),min(zdTest));
zd_maxima=max(max(zdTrain),max(zdTest));

Intervalo=0.8;                               % 0.9 - 0.1

% Lectura del fichero de soluciones aportado por la red.

fID = fopen('salidaPrediccionesFINAL_TEST.csv'); % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
    i=i+1;                                    % Incrementa contador
    lin=fgetl(fID);                          % Devuelve la siguiente línea.
    prediccion(i)=str2double(lin);           % Extrae las predicciones de la red.
end

% Desnormaliza el conjunto de test.
prediccionZa=((prediccion-0.1)*(za_maxima-za_minima)+(za_minima*(Intervalo)))/(Intervalo);
prediccionZi=((prediccion-0.1)*(zi_maxima-zi_minima)+(zi_minima*(Intervalo)))/(Intervalo);
prediccionZd=((prediccion-0.1)*(zd_maxima-zd_minima)+(zd_minima*(Intervalo)))/(Intervalo);

% Lectura del fichero con los datos del test final.

fID = fopen('solucionesFinalTest.txt');       % Apertura del fichero.
i=0;
while ~feof(fID)                             % Test 'Línea Final'.
```

```

        i=i+1;                                % Incrementa contador
        lin=fgetl(fID);                        % Devuelve la siguiente línea.
        posB=find(lin==',');                  % Localiza la primera coma.
        masaFinal(i)=str2double(lin(1:posB(1)-1)); % Extrae la masa (termina en coma -1).
        zaFinal(i)=str2double(lin(posB(1)+1:posB(2)-1)); % Extrae Zona de Alerta.
        ziFinal(i)=str2double(lin(posB(2)+1:posB(3)-1)); % Extrae Zona de Intervención.
        zdFinal(i)=str2double(lin(posB(3)+1:end)); % Extrae Zona Efecto Dominó.
    end

% Grafica los resultados.

figure()
plot (masaFinal,zaFinal,'x');
hold on
plot (masaFinal,prediccionZa,'or');
title 'Zona de Alerta';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

figure()
plot (masaFinal,ziFinal,'x');
hold on
plot (masaFinal,prediccionZi,'or');
title 'Zona de Intervencion';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

figure()
plot (masaFinal,zdFinal,'x');
hold on
plot (masaFinal,prediccionZd,'or');
title 'Zona de Efecto Domino';
xlabel 'Masa [kg]';
ylabel 'Distancia [m]';
grid on;

% Test de Student.

[hZa,pZa]=TTEST2(zaFinal,prediccionZa,0.05);
[hZi,pZi]=TTEST2(ziFinal,prediccionZi,0.05);
[hZd,pZd]=TTEST2(zdFinal,prediccionZd,0.05);

InvPZa=1-pZa;
InvPZi=1-pZi;
InvPZd=1-pZd;

```