UNIVERSIDAD DE COSTA RICA SISTEMA DE ESTUDIOS DE POSGRADO

MODELADO HIDROLÓGICO DE LA CUENCA DEL RÍO ABANGARES POR MEDIO DE ALGORITMOS DE INTELIGENCIA ARTIFICIAL

Tesis sometida a la consideración de la Comisión del Programa de Estudios de Posgrado en Ingeniería Civil para optar al grado y título de Maestría Académica en Ingeniería Hidráulica

LENNY BALDI CHACÓN

Ciudad Universitaria Rodrigo Facio, Costa Rica

2022

Dedicatoria y agradecimientos

A la vida por la oportunidad de experimentarla.

A mi familia por el apoyo incondicional a lo largo del tiempo.

A los profesores que viven genuinamente la labor de compartir el conocimiento.

A las personas que encuentro en el camino y me inspiran.

A la Tierra por brindarnos un lugar donde vivir.

"Esta tesis fue aceptada por la Comisión del Programa de Estudios de Posgrado en Ingeniería Civil de la Universidad de Costa Rica, como requisito parcial para optar al grado y título de Maestría Académica en Ingeniería Hidráulica".

Dr. Hugo Hidalgo León

Representante de la Decana Sistema de Estudios de Posgrado

PhD. Alberto Serrano Pacheco

Profesor Guía

PhD. Rafael Murillo Muñoz

Lector

M.Sc. Juan José Leitón Montero

Lector

Dr. Georges Geovaere Vicarioli

Representante del Director del Programa de Posgrado en Ingeniería Civil

Lenny Baldi Chacón

Sustentante

Tabla de contenidos

edicat	oria	y agradecimientos	ii
oja de	apro	obación	iii
abla d	e cor	ntenidos	iv
esume	en		.vii
ista de	cua	dros	viii
ista de	figu	ıras	х
ista de	abre	eviaturasx	vii
Intr	oduc	cción	1
1.1	Just	lificación	1
1.1.	1	Problema específico	1
1.1.	2	Importancia	1
1.1.	3	Antecedentes del proyecto	3
1.2	Obje	etivos	4
1.2.	1	Objetivo general	4
1.2.	2	Objetivos específicos	4
1.3	Deli	mitación del problema	4
1.3.	1	Alcances	4
1.3.	2	Limitaciones	5
1.4	Met	odología	. 8
Mar	co te	eórico	.11
2.1	Algo	pritmos de inteligencia artificial	.13
2.1.	1	Redes neuronales artificiales (RNA)	.13
2.1.	2	Redes neuronales recurrentes (RNN)	.15
2.2	Tipo	os de problemas	.16
2.2.	1	Problemas de regresión	.16
2.2.	2	Problemas de clasificación	.16
2.2.	3	Problemas de agrupamiento (Clustering)	.17
2.3	Tipo	os de aprendizaje	.17
2.3.	1	Aprendizaje supervisado	.17
	edicat oja de abla de esume sta de sta de sta de ista	edicatoria oja de apro abla de con esumen ista de cua ista de figu ista de abro introduo 1.1 Just 1.1.1 1.1.2 1.1.3 1.2 Objo 1.2.1 1.2.2 1.3 Deli 1.3.1 1.3.2 1.4 Met Marco te 2.1 Algo 2.1.1 2.1.2 2.2 Tipo 2.2.1 2.2.2 2.2.3 2.3 Tipo 2.3.1	edicatoria y agradecimientos oja de aprobación abla de contenidos esumen ista de cuadros ista de cuadros ista de figuras ista de breviaturas xx Introducción 1.1 Justificación 1.1.1 Problema específico 1.1.2 Importancia 1.1.3 Antecedentes del proyecto 1.2 Objetivos 1.2.1 Objetivo general 1.2.2 Objetivo general 1.3.1 Alcances 1.3.2 Limitación del problema 1.3.4 Alcances 1.3.2 Limitaciones 1.3.4 Alcances 1.3.2 Limitaciones 1.3.4 Alcances 1.3.2 Limitaciones 1.3.4 Alcances 2.1.1 Redes neuronales artificials 2.1.1 Redes neuronales recurrentes (RNA) 2.1.2 Redes neuronales recurrentes (RNN) 2.2.1 Problemas de regresión 2.2.2 Problemas de clasificación

	2.3.	2 Aprendizaje no supervisado	17
	2.3.	3 Aprendizaje semisupervisado	18
	2.3.	4 Aprendizaje reforzado	18
3	Des	cripción del área de estudio	19
4	Pre	procesamiento de datos disponibles	26
5	Aná	lisis horario con Redes Neuronales Artificiales (RNA)	37
Ę	5.1	Efecto del tiempo de desfase (∆T) sobre el pronóstico	37
5.2 Efecto de la extensión del registro de horas de las variables de entrada4			45
Ę	5.3	Efecto de la cantidad de estaciones de entrada	47
6	Aná	lisis horario con Redes Neuronales Recurrentes (RNN)	55
6	5.1	Efecto del tiempo de desfase (ΔT) sobre el pronóstico	55
6	5.2	Efecto de la extensión del registro de horas de entrada	60
6	5.3	Efecto de la cantidad de estaciones de entrada	62
7	Aná	lisis diario	70
7	7.1	Análisis diario con redes neuronales artificiales (RNA)	70
7	7.2	Análisis diario con redes neuronales recurrentes (RNN)	74
8	Cor	nparación de resultados	78
8	3.1	Escala horaria	78
	8.1.	1 Evento el día 05 de noviembre de 2015	79
	8.1.	2 Evento el día 11 de noviembre de 2015	83
	8.1.	3 Evento el día 28 de abril de 2016	87
	8.1.	4 Evento el día 27 de mayo de 2016	91
8	3.2	Escala diaria	95
9	Cor	clusiones y recomendaciones	100
ç	9.1	Conclusiones	100
ę	9.2	Recomendaciones	103
10	В	ibliografía	105
11	Α	nexos	107

11.1 Errores RMSE (m) sobre datos de validación para diversas funciones de activación, tiempos de desfase y nodos para el modelo *jucosrma* (RNA)......107

11.3 Errores RMSE (m) sobre conjunto de datos de validación para diversas funciones de activación, tiempos de desfase y nodos para el modelo *jucosrma* (RNN)

118

11.4 Errores RMSE (m) sobre conjunto de datos de validación para modelos RNN
horarios
11.5 Hidrogramas sintéticos para evento del día 05 de noviembre del 2015
11.6 Hidrogramas sintéticos para evento del día 11 de noviembre del 2015
134
11.7 Hidrogramas sintéticos para evento del día 28 de abril del 2016
142
11.8 Hidrogramas sintéticos modelados para evento del día 27 de mayo del 2016.150

Resumen

En el presente estudio se evalúa el uso de modelos regresivos basados en algoritmos de Redes Neuronales Artificiales (RNA) y Redes Neuronales Recurrentes (RNN) del tipo LSTM, con el objetivo de estimar anticipadamente la magnitud del nivel del agua en el cauce del río Abangares a la altura de la estación fluviográfica La Marimba.

La información de insumo proviene de tres estaciones pluviográficas y tres estaciones fluviográficas, localizadas dentro de los límites de la cuenca y que acumula un área de drenaje de 125,1 km² hasta el punto de análisis.

Los modelos son analizados en escalas horaria y diaria, identificando aspectos que intervienen en la calidad de la estimación, tales como; el tiempo de anticipación del pronóstico, número de horas que alimenta el algoritmo, funciones de activación, número de estaciones de entrada, arquitectura de la red neuronal, entre otros aspectos.

El trabajo de investigación es un insumo para desarrollar aplicaciones hidrológicas en condiciones tropicales, por medio de modelos regresivos con base en algoritmos de inteligencia artificial, dentro de las que se pueden destacar aplicaciones como los sistemas de alerta temprana y la optimización de embalses.

Lista de cuadros

Cuadro 3-1. Caracterización física de la cuenca del río Abangares a la altura de estación
La Marimba19
Cuadro 3-2. Tiempo de concentración de la cuenca del río Abangares
Cuadro 4-1. Fechas iniciales y finales de registros de estaciones
Cuadro 4-2. Parámetros generales sobre registro de la estación fluviográfico La Marimba
Cuadro 4-3. Parámetros generales sobre registro crudo de estación fluviográfica Ecomuseo
Cuadro 4-4. Parámetros generales sobre registro modificado de estación fluviográfica Santa Lucía
Cuadro 5-1. Resumen de variables de entrada para cada modelo jucosrma según tiempo de desfase ΔT
Cuadro 5-2. RMSE (m) sobre datos de prueba para modelos RNA con tiempo de desfase de 1 hora40
Cuadro 5-3. RMSE (m) para distintos ΔT y horas de registro de entrada al modelo jucosrma45
Cuadro 5-4. Modelos analizados por medio de RNA a nivel horario
Cuadro 5-5. Resumen de errores mínimos RMSE (m) de modelos RNA en escala horaria
Cuadro 5-6. Agrupamiento de modelos RNA horarios por medio del método ACP51
Cuadro 5-7. Errores y observaciones para los agrupamientos de modelos RNA horarios
con ACP
Cuadro 5-8. Agrupamiento de calidad de modelos RNA horarios por medio del método
UMAP
Cuadro 5-9. Errores y observaciones para los agrupamientos de modelos RNA horarios
con UMAP53
Cuadro 6-1. RMSE (m) para distintos ΔT y horas de registro de entrada al modelo jucosrma
RNN horario61
Cuadro 6-2. Resumen de errores RMSE (m) mínimos de modelos RNN horarios64
Cuadro 6-3. Agrupamiento de calidad de modelos RNN horarios por medio de ACP65
Cuadro 6-4. Errores y observaciones para los agrupamientos de modelos RNN horarios

Cuadro 6-5. Agrupamiento de modelos RNN horarios por medio de UMAP67
Cuadro 6-6. Errores y observaciones para los agrupamientos de modelos RNN horarios
por medio de UMAP68
Cuadro 7-1. RMSE (m) del modelo jucosrma (RNA) diario, distintas funciones de activación
y número de nodos70
Cuadro 7-2. RMSE (m) para el modelo jucosrma (RNA) para distintos tiempos de desfase
y días de registro71
Cuadro 7-3. RMSE (m) del modelo jucosrma (RNN) diario, distintas funciones de activación
y número de nodos74
Cuadro 7-4. RMSE (m) del modelo jucosrma (RNN) para distintos tiempos de desfase y
días de registro75
Cuadro 8-1. Modelos seleccionados para generar hidrogramas sintéticos en escala horaria
Cuadro 8-2. Láminas de precipitación para el día 5-11-201580
Cuadro 8-3. Láminas de precipitación para el día 11-11-201584
Cuadro 8-4. Láminas de precipitación para el día 28-04-201688
Cuadro 8-5. Láminas de precipitación para el día 27-05-201692
Cuadro 8-6. Modelos seleccionados para generar hidrogramas sintéticos en escala diaria
Cuadro 11-1. RMSE (m) modelos RNA horarios con tiempo de desfase de 1 hora107
Cuadro 11-2. RMSE (m) modelos RNA horarios con tiempo de desfase de 3 horas108
Cuadro 11-3. RMSE (m) modelos RNA horarios con tiempo de desfase de 6 horas109
Cuadro 11-4. RMSE (m) modelos RNA horarios con tiempo de desfase de 12 horas110
Cuadro 11-5. RMSE (m) modelos RNN horarios con tiempo de desfase de 1 hora118

Lista de figuras

Figura 1-1. Esquema de metodología planteada10
Figura 2-1. Conceptualización de Inteligencia Artificial, Machine Learning y Deep Learning
11
Figura 2-2. Esquema de funcionamiento de un nodo en una red neuronal con una capa
oculta14
Figura 3-1. Ubicación del área de drenaje de la cuenca del río Abangares sobre imagen
satelital de Google20
Figura 3-2. Precipitación promedio anual en el área de estudio21
Figura 3-3. Temperatura media anual en el área de estudio22
Figura 3-4. Evapotransporación potencial anual en el área de estudio23
Figura 3-5. Curva hipsométrica de la cuenca del río Abangares
Figura 4-1. Ubicación de estaciones pluviográficas y fluviográficas utilizadas en la
investigación27
Figura 4-2. Registro de datos originales de la estación La Marimba
Figura 4-3. Varianza del registro original agrupada por mes para estación La Marimba29
Figura 4-4. Registro modificado de la estación La Marimba30
Figura 4-5. Registro de datos originales de la estación Ecomuseo
Figura 4-6. Registro original de datos de la estación Santa Lucía32
Figura 4-7. Registro modificado de la estación Santa Lucía
Figura 4-8. Registro original de datos de la estación pluviográfica Campos de Oro34
Figura 4-9. Registro original de datos de la estación pluviográfica Las Juntas35
Figura 4-10. Registro original de datos de la estación pluviográfica San Rafael
Figura 5-1. Registro horario de estaciones de interés del modelo jucosrma
Figura 5-2. RMSE (m) sobre datos de prueba para modelos RNA con tiempo de desfase
de 1 hora40
Figura 5-3. RMSE mínimo obtenido para cada tiempo de desfase41
Figura 5-4. Comparación para modelo jucosrma (RNA) con tiempo de desfase de una hora
Figura 5-5. Gráfico Cuantil-Cuantil para modelo jucosrma (RNA) con tiempos de desfase
de 1 y 3 horas43
Figura 5-6. Gráfico Cuantil-Cuantil para modelo jucosrma (RNA) con tiempos de desfase
de seis y doce horas44

Figura 5-7. Gráfico Cuantil-Cuantil para modelo jucosrma (RNA) con tiempo de desfase de 24 horas
Figura 5-8. Errores mínimos RMSE (m) obtenidos para distintos tiempos de desfase Δ T46
Figura 5-9. Relación entre errores mínimos y número de observaciones disponibles para
calibrar los modelos
Figura 5-10. Agrupamiento de modelos RNA horarios por medio del método ACP50
Figura 5-11. Agrupamiento de modelos RNA horarios por medio de UMAP
Figura 5-12. Frecuencia relativa de estaciones en modelos RNA horarios con mejores
resultados54
Figura 6-1. RMSE mínimos para el modelo RNN horario jucosrma56
Figura 6-2. Comparación de serie sintética RNN y original para tiempo de desfase de 1
hora57
Figura 6-3. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempos de desfase
de 1 y 3 horas58
Figura 6-4. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempos de desfase
de 6 y 12 horas59
Figura 6-5. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempo de desfase
de 24 horas59
Figura 6-6. Errores mínimos y número de observaciones disponibles para calibrar los
modelos RNN63
Figura 6-7. Agrupamiento de modelos RNN horarios por medio de ACP65
Figura 6-8. Agrupamiento de modelos RNN horarios por medio de UMAP67
Figura 6-9. Conteo de estaciones utilizadas en modelos RNN horarios con mejores
resultados69
Figura 7-1. Series sintética y observada del nivel medio diario del cauce en la estación La
Marimba, utilizando el modelo jucosrma (RNA) con un tiempo de desfase de 1 día72
Figura 7-2. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNA) con tiempo de desfase
de 1 y 2 días72
Figura 7-3. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNA) con tiempo de desfase
de 3 días73
Figura 7-4. Serie sintética diaria de modelo jucosrma (RNN) diario para tiempo de desfase
de 1 día y valores medios diarios registrados en estación La Marimba76
Figura 7-5. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempos de desfase
de 1 y 2 días76

Figura 7-6. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempo de desfase
de 3 días77
Figura 8-1. Precipitación horaria registrada del día 05-11-201580
Figura 8-2. Evento del día 05-11-2015 visto con una hora de anticipación al inicio de la
crecida81
Figura 8-3. Evento del día 05-11-2015 visto con dos horas de anticipación al inicio de la
crecida82
Figura 8-4. Evento del día 05-11-2015 visto con tres horas de anticipación al inicio de la
crecida82
Figura 8-5. Precipitación horaria del día 11-11-201584
Figura 8-6. Evento del día 11-11-2015 visto con una hora de anticipación al inicio de la
crecida85
Figura 8-7. Evento del día 11-11-2015 visto con dos horas de anticipación al inicio de la
crecida
Figura 8-8. Evento del día 11-11-2015 visto con tres horas de anticipación al inicio de la
crecida
Figura 8-9. Precipitación horaria del día 28-04-201688
Figura 8-10. Evento del día 28-04-2016 visto con una hora de anticipación al inicio de la
crecida
Figura 8-11. Evento del día 28-04-2016 visto con dos horas de anticipación al inicio de la
crecida90
Figura 8-12. Evento del día 28-04-2016 visto con tres horas de anticipación al inicio de la
crecida91
Figura 8-13. Precipitación horaria del día 27-05-201592
Figura 8-14. Evento del día 27-05-2016 visto con una hora de anticipación al inicio de la
crecida93
Figura 8-15. Evento del día 27-05-2016 visto con dos horas de anticipación al inicio de la
crecida94
Figura 8-16. Evento del día 27-05-2016 visto con tres horas de anticipación al inicio de la
crecida94
Figura 8-17. Comparación en escala diaria para periodo del 5-11-2015 al 10-11-201596
Figura 8-18. Comparación en escala diaria para periodo del 11-11-2015 al 16-11-2015.97
Figura 8-19. Comparación en escala diaria para periodo del 30-04-2016 al 05-05-2016. 98
Figura 8-20. Comparación en escala diaria para periodo del 27-05-2016 al 01-06-2016 .98

Figura 11-1. RMSE (m) modelos RNA horarios con tiempo de desfase de 1 hora107 Figura 11-2. RMSE (m) modelos RNA horarios con tiempo de desfase de 3 horas108 Figura 11-3. RMSE (m) modelos RNA horarios con tiempo de desfase de 6 horas109 Figura 11-4. RMSE (m) modelos RNA horarios con tiempo de desfase de 12 horas110 Figura 11-5. RMSE (m) modelos RNN horarios con tiempo de desfase de 1 hora......118 Figura 11-6. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de -3 Figura 11-7. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de -2 Figura 11-8. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de -1 hora127 Figura 11-9. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 0 Figura 11-10. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 1 Figura 11-11. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 2 Figura 11-12. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 3 Figura 11-13. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 4 Figura 11-14. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 5 Figura 11-15. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 6 Figura 11-16. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 7 Figura 11-17. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 8 Figura 11-18. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 9 Figura 11-19. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 10

Figura 11-20. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 11
Figure 11.21. Llidrogromos hororise para el día 05.11.2015 con tiempos de desface de 12
Figura 11-21. Hidrogramas norarios para el día 05-11-2015 con tiempos de destase de 12
noras
Figura 11-22. Hidrogramas horarios para el dia 11-11-2015 con tiempos de destase de -3
horas
Figura 11-23. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de -2
horas
Figura 11-24. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de -1
hora
Figura 11-25. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 0
horas
Figura 11-26. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 1
hora136
Figura 11-27. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 2
horas
Figura 11-28. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 3
horas
Figura 11-29. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 4
horas
Figura 11-30. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 5
horas
Figura 11-31. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 6
horas
Figura 11-32 Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 7
horas
Figura 11-33. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 8
horac
Figure 11.24. Hidrogromes bergriss para al día 11.11.2015 con tiampos de destase de 0
Figura 11-34. Hidrogramas horanos para el día 11-11-2015 con tiempos de desiase de 9
Figura 11-35. Hidrogramas norarios para el dia 11-11-2015 con tiempos de desfase de 10
noras
Figura 11-36. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 11
horas141

Figura 11-37. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 12 horas
Figura 11-38. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de -3 horas
Figura 11-39. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de -2 horas
Figura 11-40. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de -1 hora143
Figura 11-41. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 0 horas143
Figura 11-42. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 1 hora144
Figura 11-43. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 2 horas
Figura 11-44. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 3 horas
Figura 11-45. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 4 horas
Figura 11-46. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 5 horas
Figura 11-47. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 6 horas
Figura 11-48. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 7 horas
Figura 11-49. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 8 horas
Figura 11-50. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 9 horas
Figura 11-51. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 10 horas
Figura 11-52. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 11 horas
Figura 11-53. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 12 horas

Figura 11-54. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de -	3
horas150	C
Figura 11-55. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de -	2
horas150	C
Figura 11-56. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de -	1
hora15 [.]	1
Figura 11-57. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de (С
horas15 [.]	1
Figura 11-58. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de	1
hora152	2
Figura 11-59. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 2	2
horas152	2
Figura 11-60. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 3	3
horas153	3
Figura 11-61. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de	4
horas153	3
Figura 11-62. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de s	5
horas154	4
Figura 11-63. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de (6
horas154	4
Figura 11-64. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de	7
horas15	5
Figura 11-65. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de a	8
horas15	5
Figura 11-66. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de s	9
horas156	3
Figura 11-67. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 10	0
horas156	3
Figura 11-68. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 1	1
horas15	7
Figura 11-69. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 12	2
horas15	7

Lista de abreviaturas

- ACP Análisis de componente principales
- AI Artificial Intelligence
- ANN Artificial Neural Network
- BPPT Back propagation through time
- CIEDES Centro de Investigaciones en Desarrollo Sostenible
- CN Curve Number
- CNN Convolutional Neural Network
- CTP Colegio Técnico Profesional de Abangares
- DL Deep Learning
- DNN Deep Neural Network
- ELU Expontential Linear Unit
- ETP Evapotranspiración potencial anual
- IA Inteligencia Artificial
- IMN Instituto Meteorológico Nacional
- LSTM- Redes neuronales recurrentes del tipo Long Short-Term Memory
- ML Machine Learning
- MSE Mean Squared Error
- PPA Precipitación promedio anual
- RMSE Root Mean Squared Error o Raíz del Error Cuadrático Medio
- ReLU Rectified Linear Unit
- RNA Red Neuronal Artificial
- RNN Recurrent Neural Network o Red Neuronal Recurrente
- SCS Soil Conservation Service
- SIG Sistemas de Información Geográficas
- SSD Solid State Drive

- SVM Support Vector Machine
- Tanh Tangente hiperbólica
- UCR Universidad de Costa Rica

UMAP – Uniform Manifold Approximation and Projection





Sistema de Estudios de Posgrado

Autorización para digitalización y comunicación pública de Trabajos Finales de Graduación del Sistema de Estudios de Posgrado en el Repositorio Institucional de la Universidad de Costa Rica.			
Yo,	_, con cédula de identidad, en mi		
Autorizo a la Universidad de Costa Rica para digitali a través del Repositorio Institucional u otro medio el establezca el Sistema de Estudios de Posgrado SI	izar y hacer divulgación pública de forma gratuita de dicho TFG ectrónico, para ser puesto a disposición del público según lo que		
*En caso de la negativa favor indicar el tiempo de restricción	año (s).		
Este Trabajo Final de Graduación será publicado en	formato PDF, o en el formato que en el momento se establezca,		
de tal forma que el acceso al mismo sea libre, con el	fin de permitir la consulta e impresión, pero no su modificación.		
Manifiesto que mi Trabajo Final de Graduación fue	e debidamente subido al sistema digital Kerwá y su contenido		
corresponde al documento original que sirvió para	la obtención de mi título, y que su información no infringe ni		

violenta ningún derecho a terceros. El TFG además cuenta con el visto bueno de mi Director (a) de Tesis o Tutor (a) y cumplió con lo establecido en la revisión del Formato por parte del Sistema de Estudios de Posgrado.

FIRMA ESTUDIANTE

Nota: El presente documento constituye una declaración jurada, cuyos alcances aseguran a la Universidad, que su contenido sea tomado como cierto. Su importancia radica en que permite abreviar procedimientos administrativos, y al mismo tiempo genera una responsabilidad legal para que quien declare contrario a la verdad de lo que manifiesta, puede como consecuencia, enfrentar un proceso penal por delito de perjurio, tipificado en el artículo 318 de nuestro Código Penal. Lo anterior implica que el estudiante se vea forzado a realizar su mayor esfuerzo para que no sólo incluya información veraz en la Licencia de Publicación, sino que también realice diligentemente la gestión de subir el documento correcto en la plataforma digital Kerwá.

1 Introducción

1.1 Justificación

1.1.1 Problema específico

Durante el ejercicio profesional de la Ingeniería Hidrológica se pueden encontrar una gran variedad de problemas; típicamente, la solución a esos problemas se logra con la ayuda de modelos o algoritmos de los cuales se dispone y, que además, su correcta aplicación ha sido previamente validada.

La disponibilidad de modelos hidrológicos es variada y específica para los problemas que se abarcan desde la ingeniería. Actualmente, los problemas de hidrología son resueltos en su mayoría por medio de modelos agregados, modelos distribuidos o modelos semidistribuidos.

Además, existen problemas específicos que requieren de modelos con un elevado nivel de confiabilidad, versatilidad y que también sean capaces de interpretar apropiadamente variables muy complejas, como pueden ser los casos de la distribución espacial y temporal de la precipitación para determinar condiciones de flujo en escalas pequeñas de tiempo.

Modelar la complejidad del fenómeno de precipitación-escorrentía en toda su amplitud por métodos determinísticos o estocásticos convencionales puede resultar muy retador, con especial complejidad si se toma en cuenta el efecto de la distribución espacial y temporal de la precipitación; por ejemplo, no tiene el mismo efecto sobre las condiciones de flujo del cauce una precipitación en la parte alta, media o baja de la cuenca, en conjunto con las condiciones previas de humedad, entre otras variables.

Los modelos hidrológicos convencionales pueden verse limitados para estimar de manera precisa las condiciones de flujo en un cauce para escalas temporales pequeñas; alternativamente, pueden utilizarse modelos basados en algoritmos de inteligencia artificial (*IA* o *AI* por sus siglas en inglés) que han demostrado gran capacidad en aplicaciones hidrológicas de esta naturaleza (Vahid Nourani, 2014).

1.1.2 Importancia

Todos los fenómenos hidrológicos que ocurren en la naturaleza intervienen directa o indirectamente en las actividades desarrolladas por el ser humano, tales como aquellas destinadas a garantizar la seguridad alimentaria, consumo de agua potable, el transporte de bienes y personas, actividades industriales, generación de energía eléctrica, recreación,

conservación de ecosistemas, entre otras numerosas actividades antropogénicas relacionadas al recurso hídrico del planeta.

Costa Rica, como país que forma parte de la región centroamericana y al igual que otros países a lo largo de todo el mundo, enfrenta grandes retos para desarrollarse social y económicamente mientras hace una gestión integrada del recurso hídrico (Global Water Partnership, 2011); el desarrollo de nuevas metodologías puede facilitar el análisis hidrológico requerido en actividades de gran relevancia para el desarrollo sostenible de las comunidades y, especialmente, de países en vías de desarrollo.

Modelos como los analizados en la presente investigación tienen un uso directo sobre algunas aplicaciones hidrológicas como la optimización de la operación de embalses existentes, diseño de obras hidráulicas, análisis de crecientes como los requeridos en sistemas de alerta temprana para prevención de inundaciones, entre otras posibles aplicaciones relacionadas al recurso hídrico.

Modelos hidrológicos con predicciones más precisas en la escala horaria y con un determinado periodo de anticipación permitirían una operación más eficiente en los embalses de proyectos hidroeléctricos, así también en otros usos como el riego y el consumo humano de agua potable, haciendo posible adelantarse a la creciente e intentar guardar total o parcialmente el volumen del evento dentro del sistema de almacenamiento.

Los sistemas de alerta temprana para el manejo de emergencias podrían hacer uso de modelos basados en algoritmos de inteligencia artificial para obtener pronósticos de mayor precisión y exactitud en escalas temporales pequeñas, aspecto que resulta sumamente retador para los modelos utilizados convencionalmente en este tipo de aplicación.

Disponer de mejor información sobre el comportamiento del recurso hídrico conduce a un manejo más apropiado por parte de los tomadores de decisiones, comunidades y distintos actores relacionados a una cuenca hidrológica.

Adicionalmente, es posible utilizar algoritmos de inteligencia artificial para comprender aspectos instrínsecos y complejos del comportamiento de una cuenca hidrológica; por ejemplo, el trabajo realizado para configurar una red neuronal recurrente sobre 531 cuencas de los Estados Unidos, posteriormente la red puede utilizarse para estimar condiciones con base en distintas características físicas e incluso superando modelos calibrados para las cuencas específicas (Kratzert et al., 2019).

1.1.3 Antecedentes del proyecto

El acelerado avance tecnológico vivido a finales del siglo XX e inicios del siglo XXI ha permitido un mayor acercamiento hacia elevadas capacidades computacionales, esto, a su vez, ha permitido el desarrollo de nuevas metodologías en las ramas de la ciencia y la ingeniería, en este caso específico la inteligencia artificial (*IA* o *AI* por sus siglas en inglés).

Actualmente, las computadoras de uso doméstico poseen suficiente capacidad de procesamiento como para realizar labores de entrenamiento de algoritmos de inteligencia artificial en un gran número de aplicaciones, por lo tanto, es razonablemente factible incorporar una "nueva" herramienta de trabajo a la resolución de problemas de ingeniería y en este caso específico de hidrología.

El balance hídrico de una cuenca es un proceso físico de alta complejidad, tanto por el gran número de variables que se involucran, como por el tipo de relaciones que existen en los fenómenos a lo largo del ciclo hidrológico de la cuenca, dificultando la aplicación de modelos analíticos y determinísticos convencionales.

En el caso específico de los algoritmos de inteligencia artificial, gran parte de su fortaleza yace en la capacidad de representar relaciones complejas sin limitarse a comportamientos lineales o patrones definidos; por el contrario, muchas veces están basados en la no linealidad de los fenómenos para construir la arquitectura interna del algoritmo.

Existen casos de estudio previos de modelado hidrológico, dentro de los que se puede mencionar modelos de regionalización (Kratzert et al., 2019), precipitación-escorrentía (Veintimilla, 2015), aporte de sedimentos (Misra et al., 2009), flujo subterráneo (Sahoo et al., 2017), calidad de agua (Isiyaka et al., 2018), entre otros.

1.2 Objetivos

1.2.1 Objetivo general

Pronosticar las condiciones de flujo en el cauce del río Abangares por medio de modelos precipitación-escorrentía basados en algoritmos de inteligencia artificial para escalas horaria y diaria.

1.2.2 Objetivos específicos

- Pronosticar el nivel del agua en el cauce del río Abangares para escalas horaria y diaria por medio de modelos regresivos basados en Redes Neuronales Artificiales (RNA) y Redes Neuronales Recurrentes (RNN).
- Analizar el efecto de la variación en la escala temporal del pronóstico sobre la calidad de la estimación realizada por los modelos de regresión.
- Analizar el efecto de la variación en el número de estaciones de entrada sobre la calidad de las estimaciones realizadas por los modelos de regresión.

1.3 Delimitación del problema

- 1.3.1 Alcances
 - La investigación se desarrolla con base en la información recopilada dentro del área de estudio por medio de tres estaciones pluviográficas (Las Juntas, San Rafael y Campos de Oro) y tres estaciones fluviográficas (La Marimba, Ecomuseo y Santa Lucía), administradas por el Centro de Investigaciones en Desarrollo Sostenible (CIEDES-UCR).
 - El área de estudio abarca la superficie de drenaje de la cuenca del río Abangares hasta el punto más abajo con medición fluviográfica disponible, siendo esta la estación La Marimba, que acumula un área de drenaje de aproximadamente 125,1 km².
 - Las series de datos fueron tratadas y preparadas en un entorno computacional, descartando así datos incongruentes con el fenómeno, periodos faltantes y valores negativos.
 - Los modelos fueron desarrollados para estimar de manera anticipada las condiciones de flujo en el cauce a la altura de la estación fluviográfica La Marimba en escalas horaria y diaria, por lo tanto, no corresponden a modelos de balance hídrico para determinar la disponibilidad del recurso hídrico en escala mensual o anual.

- La estimación del nivel de agua se realiza con base en registros de precipitación y/o nivel de las estaciones disponibles, tomando como base los datos registrados de instancias previas al horizonte temporal deseado para el pronóstico, estimando el nivel con tiempos de anticipación desde una hora hasta varios días, analizando los respectivos errores y comparando los resultados de los distintos modelos.
- Los algoritmos utilizados en la investigación corresponden a Redes Neuronales Artificiales (RNA) y Redes Neuronales Recurrentes (RNN); estos, a su vez, son entrenados por medio de distintas técnicas iterativas como el Descenso de Gradiente Alimentado Hacia Atrás o también conocido como *Backpropagation*, optimizadores (Adam, Adagrad, Adadelta, RMSProp) y estructura de red neuronal superficial (*shallow neural network*).
- Los modelos fueron optimizados minimizando el Error Cuadrático Medio (MSE) durante el entrenamiento de los algoritmos, esta función da mayor peso a las colas de la distribución (Géron, 2017) y se considera apropiada para el fenómeno que se busca modelar. No obstante, el parámetro de referencia utilizado para comparar los ajustes en la investigación fue la Raíz del Error Cuadrático Medio (RMSE) porque conserva las mismas unidades que el nivel en la estación La Marimba y permite una interpretación más simple del modelado.
- La optimización de los algoritmos ha sido realizada por medio de un proceso de aprendizaje iterativo sobre el conjunto de datos de entrenamiento, este corresponde al 70% de la extensión del registro disponible para cada modelo; posteriormente, se ha validado el modelo contra el 30% de los datos restantes y corresponde a un subconjunto de la serie de datos que no fue observada por los modelos previamente.
- Una vez finalizada la validación, algunos modelos son utilizados para construir hidrogramas sintéticos con longitud de 12 horas (escala horaria) y 5 días (escala diaria) de anticipación, lo que permite comparar eventos de precipitación y nivel registrados contra las estimaciones anticipadas de los modelos de inteligencia artificial.

1.3.2 Limitaciones

 Debido a la logística de recolección de los datos en sitio en la cuenca del río Abangares, solamente fue posible obtener datos de las estaciones hasta el mes de julio del año 2019, por lo que datos más recientes no estaban disponibles al dar inicio al trabajo de investigación.

- Las extensiones de los registros de datos de las estaciones disponibles se consideran cortos. En el caso de las estaciones pluviográficas los registros no superan los 7 años de mediciones subhorarias, estas son las estaciones San Rafael, Las Juntas (CTP) y Campos de Oro; por otra parte, los registros de las estaciones fluviográficas no superan los 6 años de mediciones subhorarias, estas son las estaciones Santa Lucía, Ecomuseo y La Marimba. Además, los registros mencionados no son necesariamente coincidentes entre sí.
- El registro más reciente de los datos alcanza hasta el mes de julio del año 2019. No se tuvo acceso a datos más recientes debido a la frecuencia de recolección de los datos en campo en cada una de las estaciones; no obstante, investigaciones futuras en la cuenca del río Abangares podrán consultar por datos adicionales para las estaciones que se encuentren operativas.
- El análisis se limita al fenómeno de escorrentía superficial. La escorrentía subsuperficial y subterránea corresponden a procesos implícitos dentro de los patrones a identificar con los algoritmos de inteligencia artificial; no obstante, estos no se modelan explícitamente en esta investigación.
- El entrenamiento de los algoritmos se ha realizado optimizando únicamente una función de costo para evaluar la calidad de los ajustes sobre el conjunto de datos de validación; se ha limitado a la función MSE, cuyo uso es el más extendedido en problemas de regresión y recomendada por la literatura en aplicaciones de *Machine Learning* (Géron, 2017).
- El computador utilizado para el proyecto corresponde a un equipo con un procesador i7-4710 HQ @ 2.50 GHz, 16 GB RAM DDR3 y 256 GB SSD. Estas especificaciones son relevantes en la medida que determinan los tiempos de entrenamiento de los algoritmos, así como la complejidad de modelos a evaluar. No se ha utilizado procesamiento gráfico para el entrenamiento de los algoritmos, estimando un tiempo de cálculo del entrenamiento de al menos 100 horas netas para todos los modelos evaluados.
- El tiempo de entrenamiento de cada modelo osciló entre los 5 y 150 segundos para algoritmos RNA y entre 30 y 240 segundos para algoritmos RNN-LSTM, demostrando que entre más compleja es la arquitectura del modelo (número de estaciones, horas de registro, número de nodos en capa oculta, entre otros aspectos) mayor es el tiempo de entrenamiento. Estos tiempos de entrenamiento son tomando en cuenta mecanismos de parada anticipada para detener el

entrenamiento en caso de haber encontrado el error mínimo, evitando el sobre aprendizaje y tiempos de cálculo adicionales; no obstante, una vez que el algoritmo es calibrado se puede evaluar o utilizar en fracciones de segundo.

- La complejidad de la arquitectura de los modelos puede crecer de manera muy acelerada respecto al número de estaciones de registro e información que alimenta el modelo, para este caso específico se encontró el límite del computador para modelos RNN-LSTM que utilizaron las últimas 120 horas de registro para tres estaciones pluviográficas y una estación fluviográfica, agotando la memoria del computador e impidiendo el entrenamiento del algoritmo.
- Los modelos desarrollados estiman solamente una variable de salida, de modo que se requiere un modelo calibrado por cada instancia temporal. En investigaciones futuras, podrán contemplarse modelos que puedan estimar múltiples variables de salida (por ejemplo, varias horas o días), lo que puede resultar beneficioso durante el proceso de entrenamiento.
- Las redes neuronales artificiales (RNA) y recurrentes (RNN-LSTM) evaluadas no contemplan el principio de conservación de la masa para realizar las estimaciones, aspecto que recientemente ha sido incorporado en modelos del tipo *Mass-Conserving Long-Short-Term*-Memory (MC-LSTM) con resultados prometedores (Hoedt et al., 2021); no obstante, no son resultados categóricamente mejores a los de modelos LSTM para las distintas condiciones de flujo.
- La evaluación del efecto del número de estaciones sobre la calidad de las estimaciones de los modelos se realiza exclusivamente sobre los modelos en escala horaria, esto por la significativa mayor disponibilidad de datos que hay respecto al análisis en escala diaria, lo cual resulta limitante en los modelos diarios.

1.4 Metodología

El proceso para desarrollar un modelo predictivo con base en algoritmos de inteligencia artificial, sigue una secuencia estratégica de pasos que concluyen una vez que el modelo matemático ha sido calibrado y validado satisfactoriamente. Estos pasos pueden variar; sin embargo, en esencia se pueden definir de la siguiente manera (Géron, 2017):

- Comprender el panorama general del problema.
- Obtener los datos.
- Explorar y visualizar los datos para mayor comprensión.
- Preparar los datos para usarlos en algoritmos de inteligencia artificial.
- Seleccionar un modelo y entrenarlo.
- Optimizar el entrenamiento.
- Modelo calibrado y validado.

El panorama general se enmarca con los objetivos planteados en la investigación, buscando generar modelos predictivos con la capacidad de estimar el nivel de agua en el cauce a la altura de la estación fluviográfica La Marimba para distintas escalas temporales, comparando sus errores e identificando el efecto que tienen las variables de interés sobre la calidad de la estimación.

Los datos utilizados en la investigación fueron suministrados por el Centro de Investigaciones en Desarrollo Sostenible (CIEDES) de la Universidad de Costa Rica. La cuenca del río Abangares ha sido previamente instrumentada y sus registros han permitido el desarrollo de múltiples trabajos de investigación.

Los datos originales son cargados en el programa RStudio, donde por medio de rutinas específicas se realiza la preparación y tratamiento de los mismos, además de agregar o interpolar los datos a la escala temporal de interés para las variables de precipitación y nivel en el cauce, respectivamente.

Posteriormente, la arquitectura interna de los algoritmos es definida por medio del uso de herramientas como *TensorFlow* y *Keras*, siendo estas extendidas herramientas de trabajo en código abierto para algoritmos de inteligencia artificial y *machine learning*.

La serie de datos con la que se realiza el entrenamiento de cada modelo es definida por los periodos de registros coincidentes entre las estaciones utilizadas de insumo. Del total de la serie disponible, el 70% corresponden a los datos para el entrenamiento del algoritmo y el 30% restante corresponde a los datos para realizar la validación del modelo.

Únicamente se almacenan los errores obtenidos sobre el conjunto de datos de validación, esto porque lo errores de entrenamiento no son pertinentes para los fines de la investigación y no se justifica duplicar el número de resultados a exponer en el trabajo.

La optimización de los algoritmos de inteligencia artificial se realizó por medio de técnicas iterativas como el descenso de gradiente alimentado hacia atrás (*backpropagation*), donde, además, se definen los distintos parámetros que modifican el proceso de aprendizaje del algoritmo sobre el conjunto de datos de entrenamiento.

Algunas de las variables que intervienen en el entrenamiento del algoritmo son la tasa de aprendizaje, el número de épocas de aprendizaje, la inicialización de las variables, algoritmo optimizador, número de nodos, número de épocas de espera después de encontrar el costo mínimo, número de capas ocultas, entre otros aspectos.

De este modo se configuran, entrenan y validan múltiples modelos de inteligencia artificial basados en algoritmos RNA y RNN-LSTM, con el objetivo de estimar el nivel horario y el nivel medio diario a la altura de la estación fluviográfica La Marimba.

Una vez que se dispone de los modelos validados, se procede a generar hidrogramas sintéticos con los algoritmos de inteligencia artificial, analizando su capacidad para realizar estimaciones de manera anticipada a la ocurrencia de los eventos.

Finalmente se realiza el análisis de resultados, desarrollo de conclusiones y redacción del documento escrito. A continuación, se muestra de manera esquemática la metodología planteada.



Figura 1-1. Esquema de metodología planteada

2 Marco teórico

La inteligencia artificial es una rama del conocimiento que abarca una gran diversidad de problemas y posibles soluciones. Un algoritmo de inteligencia artificial puede comprenderse como un modelo con la capacidad de mejorar sus resultados por medio de un proceso de aprendizaje:

"Se dice que una computadora aprende de una experiencia E con respecto a una tarea T y una medida de desempeño D, si su desempeño D respecto a la tarea T se mejora con la experiencia E" (Mitchell, 1997).

La inteligencia artificial (IA o AI) engloba, además, los conceptos de *Machine Learning* (ML) y *Deep Learning* (DL), una manera de visualizar los conceptos es por medio de círculos concéntricos donde una rama se ubica dentro de la otra (Gutierrez, 2017). A continuación se presenta un esquema para ejemplificar estos conceptos.





Para fines de la presente investigación, se trabaja con el concepto global de inteligencia artificial y específicamente con los algoritmos de interés para desarrollar los alcances delimitados.

La variedad de algoritmos dentro de la inteligencia artificial es extensa, típicamente se caracterizan por distintas fortalezas y debilidades relacionadas a la naturaleza específica de los problemas.

Asimismo, para fines de esta investigación se ha limitado al uso de Redes Neuronales Artificiales (RNA o ANN) y Redes Neuronales Recurrentes del tipo LSTM (RNN-LSTM). Los algoritmos RNA "son versátiles, poderosos y escalables, lo que los hace perfectos para abordar problemas altamente complejos" (Géron, 2017); por otra parte, los algoritmos RNN incorporan un concepto de "memoria temporal" que brinda una gran capacidad inductiva sobre variables en el tiempo (Hoedt et al., 2021), tal cual es el caso del fenómeno precipitación-escorrentía que ocurre en una cuenca.

Complementariamente a los modelos RNA y RNN planteados dentro del trabajo de investigación, se pueden mencionar otros algoritmos como los siguientes:

- Redes neuronales profundas (DNN).
- Redes neuronales convolucionales (CNN).
- Support vector machines (SVM).
- Árboles de decisión.
- Random Forests.
- Redes bayesianas.
- Sistemas de lógica difusa.
- Clustering.

La preferencia de utilizar un algoritmo en específico sobre otros ha variado a lo largo del tiempo y del tipo de problemas en cuestión, naturalmente existen métodos diferenciados para la resolución de problemas (Contreras, 2018).

Actualmente existen múltiples lenguajes computacionales en los que se puede realizar análisis de datos; sin embargo, existen dos entornos ampliamente utilizados en el desarrollo de algoritmos de inteligencia artificial que son el Código R y Python.

Python es un lenguaje robusto construido con un fin multipropósito; por otra parte, el código R es un lenguaje desarrollado para análisis de datos con un enfoque estadístico y se encuentra en auge desde su comienzo.

Ambos entornos de trabajo son utilizados a lo largo de las distintas actividades para lograr los objetivos con apoyo de paquetes de información y rutinas predefinidas desarrollados por múltiples actores de la comunidad informática internacional.

2.1 Algoritmos de inteligencia artificial

Tal como ha sido mencionado anteriormente, existen numerosos algoritmos relacionados con la inteligencia artificial y su aplicación depende del problema a resolver.

Para el desarrollo de la investigación se propone el uso de los siguientes algoritmos.

2.1.1 Redes neuronales artificiales (RNA)

Las redes neuronales artificiales (RNA o también conocidas como ANN por sus siglas en inglés) son un algoritmo que busca simular, en buena medida, el comportamiento del cerebro para la resolución de problemas matemáticos. Haykin (2009) define que

Una red neuronal es un procesador masivo distribuido en paralelo, formado por unidades simples de procesamiento con una tendencia natural a almacenar conocimiento experimental y tenerlo disponible para su uso. Se parece al cerebro en dos aspectos:

1. El conocimiento es adquirido desde el ambiente por medio de un proceso de aprendizaje.

2. La fuerza de conexión entre neuronas también conocida como pesos sinápticos, es usada para almacenar el conocimiento aprendido (p. 2).

Se puede entender entonces que una red neuronal artificial tiene similitudes con el funcionamiento del cerebro humano; además, es importante definir sus diferentes elementos y la manera en que interactúan.

Una red neuronal está constituida por nodos (neurona o elemento de procesamiento), los cuales son elementos de cálculo interconectados con muchos otros elementos, imitando así la sinapsis nerviosa (Castellano, 2009).

Típicamente, a un nodo llegan múltiples entradas y de cada uno se realiza una única salida, ya sea para conectar hacia otro nodo en una capa oculta siguiente, o bien, como nodo de salida del algoritmo. En algoritmos RNA, la información avanza únicamente en la dirección hacia adelante, desde la capa de entrada hasta finalmente la salida.

Se muestra a continuación un esquema para ejemplificar el funcionamiento de una red neuronal artificial (RNA).



Figura 2-2. Esquema de funcionamiento de un nodo en una red neuronal con una capa oculta

Fuente: Neural Networks and Learning Machines (p. 22), por Simon Haykin, 2009, Pearson.

El vínculo que existe entre las capas de nodos se conoce como función de transferencia o función de activación. Típicamente se utilizan diversas funciones y algunas comunes son: umbral, lineal, tangente hiperbólica, RELU, ELU, logística, gaussiana, entre otras (Castellano, 2009).

Una red neuronal además se puede caracterizar por medio de la dimensión de sus diversos elementos, por ejemplo, se tienen también las siguientes clasificaciones:

- Número de capas ocultas.
- Número de nodos en la capa de entrada.
- Número de nodos en la capa oculta.
- Número de nodos en la capa de salida.
- Variables de entrada.
- Variables de salida.

La teoría relacionada con el análisis por medio de una RNA es extensa y no se limita únicamente a lo mencionado previamente. Sin embargo, permite una idea general del funcionamiento de una red neuronal y cómo se aplica al análisis de datos.

En la presente investigación se desarrollan únicamente modelos superficiales o *shallow networks*, los cuales son modelos con una única capa oculta de nodos. Alternativamente, modelos con numerosas capas ocultas se engloban dentro de los modelos *Deep Learning* y están fuera de los alcances definidos.

2.1.2 Redes neuronales recurrentes (RNN)

Las redes neuronales recurrurentes (*Recurrent Neural Networks* o RNN) utilizan fundamentos similares a las redes neuronales artificiales, con la particularidad que este algoritmo tiene la capacidad de obtener información de toda la serie temporal de análisis.

Este tipo de red opera sobre las señales de toda la serie o subconjuntos de la misma, calibrando pesos tanto para funciones en el paso temporal de interés como para funciones de "desfase" (Sherstinsky, 2020).

Su entrenamiento, típicamente, se puede realizar por medio de las metodologías de *Error back propagation* o más apropiadamente por *Back propagation through time* (BPTT), algoritmo desarrollado para trabajar sobre fenómenos de naturaleza continua tanto como discreta.

Algunos algoritmos RNN tienen limitaciones respecto a la cantidad de pasos de tiempo que pueden observar sin que su capacidad de "memorizar" se vea atenuada. En el caso de redes neuronales recurrentes del tipo LSTM (*Long Short-Term Memory*) pueden ser capaces de aprender de más de 1000 pasos temporales previos (Staudemeyer & Morris, 2019), por este motivo se ha considerado este algoritmo para el análisis.

En el pasado reciente, han existido grandes avances en el campo del reconocimiento de imágenes gracias a las redes neuronales convolucionales (CNN), esto debido a la fuerte

capacidad inductiva (*inductive bias*) de estos algoritmos para generalizar lo aprendido en el espacio físico de las imágenes durante su entrenamiento; de una manera análoga, las redes recurrentes LSTM poseen esta capacidad inductiva pero sobre las variables en el tiempo (Hoedt et al., 2021) y no en el espacio, por este motivo son algoritmos de gran interés para el análisis de series temporales como es el caso del análisis hidrológico.

2.2 Tipos de problemas

2.2.1 Problemas de regresión

Los problemas de regresión son aquellos en los que se desea estimar una variable continua a partir del conocimiento de otros parámetros de entrada, los cuales pueden ser tanto del tipo continuos como discretos; los problemas de regresión son también conocidos como extrapolación o interpolación de números reales.

Este es el tipo de problema pertinente a la presente investigación, los modelos se construyen tomando como base información de precipitación registrada en las estaciones pluviográficas y el nivel del agua registrado en las estaciones fluviográficas; ambos parámetros son del tipo continuo y de igual manera la salida de los modelos.

2.2.2 Problemas de clasificación

Los problemas de clasificación son aquellos en los que se busca estimar una variable categórica con base en los parámetros de entrada; la o las salidas del modelo pueden ser tanto de tipo discreto como de tipo nominal.

Una variable de tipo nominal es aquella que solamente establece relación de igualdad o desigualdad respecto a una condición determinada; además, la variable no sigue un orden lógico.

Por otra parte, una variable discreta es aquella que solamente puede tomar valores finitos dentro de un determinado rango del conjunto. Al igual que en el caso de problemas de regresión, es posible asignar probabilidades de ocurrencia a los resultados del modelo.

No obstante, por la naturaleza y alcances del análisis propuesto, este tipo de problemas no son abarcados en la presente investigación.

2.2.3 Problemas de agrupamiento (Clustering)

Los métodos de agrupamiento poseen ciertas similitudes respecto a los métodos de clasificación; sin embargo, en tareas de agrupamiento se desea identificar estructuras en los datos de entrada y no necesariamente relaciones de causa y efecto.

Un algoritmo de agrupamiento permite que a partir de una serie de datos con atributos se determinen similitudes entre grupos de datos; debido a la naturaleza de los problemas planteados en el proyecto de investigación, este tipo de método solamente se utiliza para identificar grupos de modelos con las técnicas de reducción dimensional de ACP y UMAP.

2.3 Tipos de aprendizaje

Los algoritmos de inteligencia artificial también pueden ser clasificados de acuerdo al tipo y cantidad de supervisión que requieren durante el proceso de entrenamiento. En esta línea, existen cuatro categorías principales: aprendizaje supervisado, aprendizaje no supervisado, aprendizaje semisupervisado y aprendizaje reforzado (Géron, 2017).

2.3.1 Aprendizaje supervisado

El aprendizaje supervisado consiste en técnicas que usan ejemplos de datos de entrada y etiquetas (respuestas correctas) para mejorar su experiencia de aprendizaje y posteriormente realizar pronósticos (Segaran, 2007).

Debido a la naturaleza de los análisis hidrológicos propuestos, los algoritmos que se trabajarán en la presente investigación fundamentalmente serán técnicas de aprendizaje supervisado, basados en las series de datos meteorológicas e hidrológicas para realizar el entrenamiento del algoritmo.

En el caso específico de los modelos desarrollados en este trabajo, se utilizan tanto estaciones pluviográficas como fluviográficas para estimar el nivel del agua en la estación fluviográfica La Marimba, el entrenamiento de los modelos se lleva a cabo sobre el conjunto de datos de entrenamiento que corresponde al 70% de los datos disponibles; posteriormente, la validación se realiza con el 30% de los datos disponibles restantes.

2.3.2 Aprendizaje no supervisado

A diferencia de las técnicas de aprendizaje supervisado, el aprendizaje no supervisado no utiliza datos donde se tienen ejemplos de respuestas correctas, también conocidas como etiquetas. Estas técnicas son utilizadas en mayor medida para encontrar estructuras en los datos de interés (Segaran, 2007).
Las técnicas no supervisadas permiten al algoritmo encontrar patrones o estructuras en los datos, sin explícitamente limitarle a relaciones causa y efecto especificadas como es el caso del aprendizaje supervisado.

El aprendizaje no supervisado tiene aplicaciones muy diversas, por ejemplo, podría ser utilizado en el análisis hidrológico para identificar y cuantificar patrones que afectan el ciclo hidrológico de una cuenca, distribución espacial de precipitación, entre otros.

En la presente investigación, únicamente se utiliza el algoritmo K-medias para agrupar o generar *clusters* de la calidad de los modelos horarios, considerado como un algoritmo con aprendizaje no supervisado.

2.3.3 Aprendizaje semisupervisado

Esta técnica de entrenamiento se utiliza en algoritmos capaces de recibir datos y etiquetas de manera parcial, de modo que no todos los datos de entrenamiento forman un conjunto entrada-etiqueta; este tipo de aprendizaje suele ser una combinación de técnicas no supervisadas y supervisadas (Géron, 2017).

Un ejemplo de este tipo de algoritmo se usa en servicios web que albergan imágenes como *Google Photos*, donde por medio de técnicas no supervisadas se identifica una misma persona en varias fotos, necesitando exclusivamente que el usuario indique la identidad del individuo, lo que corresponde al componente de aprendizaje supervisado.

Debido a la naturaleza de la presente investigación, este tipo de aprendizaje no es requerido en los algoritmos y está fuera de los alcances.

2.3.4 Aprendizaje reforzado

El aprendizaje reforzado opera considerablemente distinto a los otros tipos de aprendizaje, pues este hace uso de la experiencia percibida por el sistema para definir cómo actuar ante el próximo evento, asignando experiencias positivas o negativas que desarrollan el proceso de aprendizaje de manera iterativa (Géron, 2017).

Este tipo de técnica de aprendizaje es utilizada, por ejemplo, en robots que aprenden a caminar, donde el sistema tiene la potestad de generar estrategias de solución y es compensado de manera positiva o negativa según corresponda la experiencia.

Debido a la naturaleza de la investigación, este tipo de aprendizaje no es utilizado y está fuera de los alcances.

Descripción del área de estudio 3

El área de estudio de la presente investigación corresponde a la cuenca del río Abangares a la altura de la estación fluviográfica La Marimba. En la Figura 3-1 se muestra la delimitación de la cuenca sobre una imagen satelital de Google.

Por medio de análisis en SIG se realiza una caracterización física general de la cuenca y se detalla en el siguiente cuadro.

Cuadro 3-1. C	Caracterización	física de la	a cuenca	del río	Abangares	a la altura	a de	estación
La Marimba								

Parámetro	Río Abangares
Área (km²)	125,1
Perímetro (km)	61,5
Elevación máxima (msnm)	1182
Elevación media (msnm)	498
Elevación mínima (msnm)	108
Índice de compacidad (kc)	1,54
Pendiente media de la cuenca (%)	29,6%
Pendiente media de la cuenca (°)	16,5
Orden máximo de cauce	3
Longitud del cauce principal (km)	16,2
Longitud de red de drenaje (km)	110,5
Densidad de drenaje (km/km ²)	0,88
Pendiente media del cauce principal (%)	6,63%

Complementariamente, en la Figura 3-2 se muestra la lámina de precipitación promedio anual determinada por el Instituro Meteorológico Nacional (IMN) en su Atlas Climatológico para el territorio nacional, identificando así una lámina de precipitación promedio anual (PPA) de 2589 mm.

De igual manera, se verificó la temperatura media anual y la evapotranspiración potencial anual de la cuenca en el Atlas Climatológico, obteniendo una temperatura media anual de 24,4 °C y una ETP anual de 1532 mm para la cuenca.



Figura 3-1. Ubicación del área de drenaje de la cuenca del río Abangares sobre imagen satelital de Google

Nota. Adaptado de Baldi, 2022. Fuente: Google, 2022.



Figura 3-2. Precipitación promedio anual en el área de estudio

Nota. Adaptado de Baldi, 2022. Fuente: IMN, 2005.



Figura 3-3. Temperatura media anual en el área de estudio Nota. Adaptado de Baldi, 2022. Fuente: IMN, 2005.



Figura 3-4. Evapotransporación potencial anual en el área de estudio

Nota. Adaptado de Baldi, 2022. Fuente: IMN, 2005.



Figura 3-5. Curva hipsométrica de la cuenca del río Abangares

La Figura 3-5 muestra la curva hipsométrica. La forma de esta sugiere que el proceso de transporte de material de la cuenca ha ocurrido en buena medida; la concavidad se observa principalmente en las partes altas mientras que en las partes bajas empieza a tener una forma convexa, indicando acumulación del material proveniente de la parte alta.

El tiempo de concentración de la cuenca ha sido determinado por medio de varias metodologías buscando congruencia entre las mismas, la primera metodología se conoce como el tiempo de concentración de Kirpich y sigue la siguiente expresión (Debo & Reese, 2003):

$$t_c = 0.0078 L^{0.77} S^{-0.385}$$

Donde *L* y *S* representan la longitud (pies) del canal y pendiente respectivamente, evaluando una longitud de 17190 m y una pendiente del 62% se obtiene un t_c de 106 minutos.

La segunda metodología evaluada es la propuesta por el SCS, siguiendo la relación (Chow, 1994):

$$t_c = \frac{100L^{0.8}[(1000/CN) - 9]^{0.7}}{1900S^{0.5}}$$

Donde *L*, *S y CN* representan la longitud (pies) del recorrido, pendiente del terreno y número de curva respectivamente, evaluando una longitud de 17190 m, una pendiente aproximada del 29,6%, un CN de 79 para pastos en condiciones medias, se obtiene un t_c de 156 minutos La tercera metodología es la propuesta por Kerby y sigue la siguiente expresión (Mays, 2004):

$$t_c = \left(\frac{0.67*n*L}{\sqrt{S}}\right)^{0.467}$$

Donde *L* representa la longitud del plano a recorrer en pies, *S* la pendiente del recorrido y *n* es el coeficiente de rugosidad. Valorando una pendiente del 0,062 m/m medida de la topografía, una longitud del recorrido de 16190 m y un coeficiente de rugosidad de n=0,4 s/m^{1/3}, se obtuvo un *t*_c de 169 minutos.

En el Cuadro 3-2 se detalla el tiempo de concentración en minutos para las tres metodologías analizadas, así como el valor promedio mostrado en la última fila. Se determinó un tiempo de concentración de 2,5 horas o 150 minutos como representativo de la cuenca a la altura la estación fluviográfica La Marimba.

Cuadro 3-2. Tiempo de concentración de la cuenca del río Abangares

Metodología	Tc (min)
Kirpich	106,2
SCS	156,1
Kerby	169,2
Promedio	143,8

4 Preprocesamiento de datos disponibles

Los datos de insumo son facilitados por el Centro de Investigaciones en Desarrollo Sostenible (CIEDES) de la Universidad de Costa Rica (UCR). Las estaciones meteorológicas e hidrológicas son operadas por dicha entidad y han servido para múltiples trabajos de investigación en la cuenca del río Abangares a lo largo de varios años.

Específicamente, se dispone de información de tres estaciones pluviográficas y tres estaciones fluviográficas; además, estas estaciones se ubican en lugares estratégicos de la cuenca y la red de drenaje. En la Figura 4-1 se muestra la ubicación de las estaciones disponibles respecto a la cuenca del río Abangares.

Los registros de las estaciones no son continuos desde su puesta en marcha hasta la última recolección que se tuvo acceso; esta discontinuidad de los registros es valorada en el tratamiento de los datos. En el Cuadro 4-1 se detallan las fechas iniciales y finales de cada estación.

Estación	Inicio de registro	Fin de registro
Ecomuseo	2014-10-22 08:15:00	2019-07-29 08:40:00
Marimba	2014-10-22 09:40:00	2019-07-30 03:25:00
Santa Lucia	2015-06-11 04:20:00	2019-07-29 08:05:00
Campos de Oro	2015-03-05 11:00:00	2018-07-18 04:15:00
San Rafael	2014-02-10 15:20:00	2018-12-04 02:15:00
Las Juntas	2012-02-08 11:00:00	2018-01-08 03:00:00

Cuadro 4-1. Fechas iniciales y finales de registros de estaciones

El intervalo de medición de todas las estaciones es de 5 minutos; sin embargo, existen periodos donde el dato se almacenó cada 20 minutos o, incluso, desfasados de manera no simétrica a lo largo de una hora. El manejo y preparación de los datos es un componente esencial para que los modelos trabajen adecuadamente.



Figura 4-1. Ubicación de estaciones pluviográficas y fluviográficas utilizadas en la investigación

Nota. Adaptado de Baldi, 2022. Fuente: Google, 2022.

El manejo y preparación de los datos de entrada para los modelos se realiza por medio del programa RStudio, con rutinas desarrolladas en código R para los propósitos específicos, donde cada una de las series originales es inspeccionada en búsqueda de incongruencias.

En el caso de la estación fluviográfica La Marimba, una fracción de su registro fue capturado a intervalos no simétricos dentro de cada hora, por ejemplo, capturas a la 1:00, 1:05, 1:20, 1:25, 1:40 y 1:45; el resto del registro sí presenta captura de datos cada 5 minutos.

En la Figura 4-2 se muestra la serie original de datos en la estación La Marimba. La serie original incumple con las premisas de una serie estacionaria; en particular, se observa un cambio significativo de la varianza en los datos a partir de julio del año 2017. Los datos son agrupados a nivel mensual y estimadas sus varianzas como se muestran en la Figura 4-3.



Figura 4-2. Registro de datos originales de la estación La Marimba



Figura 4-3. Varianza del registro original agrupada por mes para estación La Marimba

El cambio en la varianza de los datos se evidencia a partir del mes de julio del año 2017, periodo en el que también se presentan repetidos valores negativos y saltos impropios del fenómeno de escorrentía, por este motivo se descartan los datos a partir de julio del 2017 (incluyente).

En el Cuadro 4-2 se detallan algunos indicadores generales de interés para el registro original y modificado de la estación La Marimba.

La Figura 4-4 detalla la serie de datos modificada de la estación La Marimba.

Cuadro 4-2. Parámetros g	generales sobre	registro de la	estación fluviog	gráfico La Marimba

Parámetro	Serie original	Serie modificada
Nivel mínimo (m)	-1,17	0,24
Nivel medio (m)	0,60	0,55
Nivel máximo (m)	3,03	2,16
Número de observaciones	236832	146248



Figura 4-4. Registro modificado de la estación La Marimba

En el caso de la estación fluviográfica Ecomuseo, una fracción de su registro fue capturado a intervalos no simétricos dentro cada hora, por ejemplo, capturas a la 1:10, 1:15, 1:30, 1:35, 1:50 y 1:55. El resto del registro sí presenta captura de datos cada 5 minutos.

En la Figura 4-5 se muestra la serie original de datos de la estación fluviográfica Ecomuseo.



Figura 4-5. Registro de datos originales de la estación Ecomuseo

En el Cuadro 4-3 se detallan algunos indicadores generales de interés en el registro original de la estación fluviográfica Ecomuseo.

Cuadro 4-3. Parámetros	generales sobre	registro crudo de estac	ión fluviográfica Ecomuseo
------------------------	-----------------	-------------------------	----------------------------

Parámetro	Magnitud
Nivel mínimo (m)	0,0
Nivel medio (m)	0,46
Nivel máximo (m)	2,81
Número de observaciones	424280

El registro de la estación Ecomuseo se observa apropiado, con la excepción del inicio del último periodo de medición que muestra unas primeras lecturas incongruentes con el fenómeno y posiblemente responde al reinicio de una adquisición de datos.

La estación fluviográfica Santa Lucía inicia la toma de datos a partir de junio del 2015, con medición cada 5 minutos y se muestra en la Figura 4-6 el registro original disponible.



Figura 4-6. Registro original de datos de la estación Santa Lucía

Por medio de una inspección visual de los datos se puede comprobar que existen algunos valores negativos. Además, posterior al mes de mayo del año 2017 los registros no se consideran apropiados, esto porque no presentan una variabilidad propia del fenómeno de escorrentía y hay múltiples periodos faltantes; por lo tanto, son descartados y se genera la serie modificada mostrada en la Figura 4-7.

En el Cuadro 4-4 se detallan los parámetros generales para la serie de Santa Lucía modificada al descartar datos posteriores a abril 2017.

La estación pluviográfica Campos de Oro posee un registro de datos cada 15 minutos. En este no se encontraron incongruencias como números negativos o patrones inadecuados en los datos, tal como se aprecia en la Figura 4-8.



Figura 4-7. Registro modificado de la estación Santa Lucía

Cuadro 4-4. Parámetros generales sobre registro modificado de estación fluviográfica Santa Lucía

Parámetro	Magnitud
Nivel mínimo (m)	0
Nivel medio (m)	0,36
Nivel máximo (m)	1,98
Número de observaciones	180299



Figura 4-8. Registro original de datos de la estación pluviográfica Campos de Oro

En la estación pluviográfica Campos de Oro se dispone de un total de 109441 observaciones. Es importante recalcar que estas observaciones contabilizan mediciones de 0 mm y no se contabilizan periodos faltantes de registro, es decir que se diferencia un valor nulo de uno faltante.

En la Figura 4-9 se muestra el registro completo de la estación pluviográfica Las Juntas.



Figura 4-9. Registro original de datos de la estación pluviográfica Las Juntas

La estación pluviográfica Las Juntas posee un registro de 619567 observaciones, los datos se visualizan congruentes con el fenómeno de precipitación y, por lo tanto, no se realizan correcciones a la serie de datos.

En la Figura 4-10 se muestra el registro original de la estación pluviográfica San Rafael.



Figura 4-10. Registro original de datos de la estación pluviográfica San Rafael

La estación pluviográfica San Rafael posee un registro de 472097 observaciones. Los datos se consideran congruentes con el fenómeno de precipitación y, por lo tanto, no se realizan correcciones a la serie de datos.

La escala temporal mínima para la investigación se define a nivel horario, por este motivo los datos de precipitación son agregados a una escala horaria, mientras que los datos del nivel son interpolados, obteniendo así las series de datos horarios para la calibración de los modelos.

Es importante recalcar que según las estaciones utilizadas en cada modelo con algoritmos RNA y RNN, se descartan los periodos no coincidentes entre las estaciones de interés para cada respectivo modelo.

En el caso del análisis en escala diaria, los datos son agregados para cada día. Los datos de precipitación contemplan todos los registros del día, mientras que los datos de nivel del agua en el cauce corresponden al valor promedio diario.

5 Análisis horario con Redes Neuronales Artificiales (RNA)

5.1 Efecto del tiempo de desfase (△T) sobre el pronóstico

Se desarrolló un modelo que utiliza cuatro estaciones de entrada, en este caso específico son las estaciones pluviográficas Las Juntas, Campos de Oro, San Rafael y la estación fluviográfica La Marimba (modelo *jucosrma*); siendo el nivel horario del cauce a la altura de la estación La Marimba la variable objetivo a estimar por el modelo.

Se descartan los periodos de datos no coincidentes entre los registros de las estaciones de interés, obteniendo un total de 11846 observaciones horarias por cada estación, los cuales se muestran en la Figura 5-1.



Figura 5-1. Registro horario de estaciones de interés del modelo jucosrma

El modelo planteado estima el nivel del agua en el cauce con un número determinado de horas de anticipación o tiempo de desfase (Δ T), teniendo como insumos los registros de una determinada cantidad de horas previas (D) a la instancia de interés.

El número de horas de registro D utilizadas en este modelo se consideró con una magnitud fija de 24 horas. El efecto de este parámetro es analizado individualmente en la sección 5.2 del documento, la cual puede consultarse para mayor detalle.

En el Cuadro 5-1 se muestran las variables de entrada utilizadas para los modelos de acuerdo a su respectivo tiempo de desfase.

Cuadro 5-1. Resumen de variables de entrada para cada modelo jucosrma según tiempo de desfase ΔT

Estación	∆T 1 hora	∆T 3 horas	∆T 6 horas	∆T 12 horas	∆T 24 horas
San Rafael	sr_1, \cdots, sr_{24}	sr ₃ , …, sr ₂₆	sr_6, \cdots, sr_{29}	sr_{12}, \cdots, sr_{35}	sr_{24}, \cdots, sr_{47}
Campos de Oro	co_1, \cdots, co_{24}	co ₃ , …, co ₂₆	co ₆ , …, co ₂₉	co ₁₂ , , co ₃₅	co_{24},\cdots,co_{47}
Las Juntas	ju_1, \cdots, ju_{24}	ju_3, \cdots, ju_{26}	ju_6, \cdots, ju_{29}	ju_{12}, \cdots, ju_{35}	ju_{24},\cdots,ju_{47}
La Marimba	n_1 , \cdots , n_{24}	n_{3}, \cdots, n_{26}	n_{6}, \cdots, n_{29}	n_{12}, \cdots, n_{35}	n_{24}, \cdots, n_{47}

El modelo contempla exclusivamente una variable de salida n_0 que representa el nivel del agua en el cauce a las 0 horas en la estación fluviográfica La Marimba, visto desde un marco de referencia temporal que ubica el origen sobre la instancia temporal de interés.

Las redes neuronales son evaluadas para múltiples configuraciones de nodos, funciones de activación, tasas de aprendizaje, regularización y entre otros aspectos, idenficando así los parámetros que brindan mejores resultados durante la calibración.

Los modelos son optimizados con relación a una función de costo objetivo, en este caso se definió la función Error Cuadrático Medio o *Mean Squared Error* (MSE), la cual es recomendada por la literatura para problemas de regresión (Géron, 2017), además su uso es ampliamente extendido en la práctica del análisis de datos en *Machine Learning*; no obstante, el parámetro almacenado es la Raíz del Error Cuadrático Medio o *Root Mean Squared Error* (RMSE) debido a que resulta más intuitivo al conservar las unidades de la variable (metros) y es más barata computacionalmente de calcular la función MSE.

En el caso del análisis en escala horaria con redes neuronales artificiales, la totalidad de la serie de datos fue segregada en dos segmentos que son los datos entrenamiento y los datos de validación.

Los datos de validación corresponden a un 30% de las series disponibles, los datos de entrenamiento corresponden al 70% restante; en el caso de algoritmos con redes neuronales artificiales (RNA), los datos son seleccionados de manera aleatoria a lo largo de toda la serie.

El entrenamiento de los algoritmos se realiza sobre los datos de entrenamiento, de modo que se optimiza y calibra contra estos datos. Finalmente, los modelos son evaluados sobre el conjunto de datos de validación, los cuales nunca fueron previamente observados durante el proceso de entrenamiento.

Durante el proceso de aprendizaje del algoritmo se modifican automáticamente los pesos de los nodos o neuronas de manera iterativa. Es de particular interés documentar la variación de la función de costo evaluada tanto sobre el conjunto de datos de entrenamiento como también sobre los datos de validación.

Estudiar el historial de entrenamiento de un algoritmo permite no alcanzar el punto del sobreaprendizaje del mismo, evitando así que el modelo pierda la capacidad de generalizar una vez que es evaluado sobre los datos de validación que no han sido previamente observados.

En el Cuadro 5-2 se muestra el RMSE de la variable de salida n₀ (que representa el nivel del agua en el cauce a las 0 horas en la estación fluviográfica La Marimba) evaluado sobre el conjunto de datos de validación. Estos datos corresponden a un 30% de la extensión de la totalidad del registro disponible, son independientes de los datos de entrenamiento; además, son un subconjunto sobre el cual el algoritmo nunca fue entrenado; se detallan los valores para distintos números de nodos, funciones de activación (*ELU*, *Relu* y *Tanh*) y tiempos de desfase.

En la Figura 5-2 se observa un sutil incremento del error respecto a la cantidad de nodos o neuronas. Se evaluaron desde 1 hasta 1000 nodos en la capa oculta del modelo RNA, donde los mejores resultados se observan para el menor número de nodos; además, cabe destacar que en este caso la calidad del ajuste fue ligeramente mejor para la función de activación *ELU* (*Exponential Linear Unit*).

Los errores para tiempos de desfase de 1 hasta 24 horas, diversas funciones de activación y número de nodos se detallan en el Anexo 11.1.

Cuadro 5-2. RMSE (m) sobre datos de prueba para modelos RNA con tiempo de desfase de 1 hora

DT 1 hora						
Neuronas	Relu	ELU	Tanh			
1	0,0269	0,0234	0,0288			
3	0,0274	0,0243	0,0282			
10	0,0275	0,0258	0,0278			
50	0,0265	0,0246	0,0271			
250	0,0290	0,0258	0,0309			
1000	0,0255	0,0313	0,0304			



Figura 5-2. RMSE (m) sobre datos de prueba para modelos RNA con tiempo de desfase de 1 hora

Con base en los distintos modelos analizados, se observa un deterioro generalizado de la calidad de los modelos respecto al incremento del número de nodos, específicamente, los modelos con un número de nodos por debajo de 10 fueron los que obtuvieron mejores resultados.

Las funciones de activación *ReLU* y *ELU* fueron las que de manera general presentaron mejores ajustes para las pruebas realizadas.

Se valoraron distintos tiempos de desfase determinando que, entre mayor sea el tiempo de desfase (horas de anticipación al pronóstico) se incrementa el error de la estimación. En la



Figura 5-3 se muestra el RMSE para el mejor ajuste en cada uno de los tiempos de desfase analizados.

Figura 5-3. RMSE mínimo obtenido para cada tiempo de desfase

Una vez que se tienen calibrados los modelos, se procede al ejercicio de generar las series sintéticas equivalentes a la extensión del registro completo y compararlos con los valores observados en la estación fluviográfica La Marimba. La Figura 5-4 muestra la comparación de la serie registrada y la serie sintética con una hora de anticipación o tiempo de desfase de 1 hora.



Figura 5-4. Comparación para modelo jucosrma (RNA) con tiempo de desfase de una hora

Se puede apreciar en la Figura 5-4 una gran similitud entre la serie original y la serie sintética generada con el modelo RNA. Los datos mostrados poseen una escala horaria y el pronóstico se realiza en este caso con una hora de anticipación.

Complementariamente, se muestra en la Figura 5-5 un gráfico Cuantil-Cuantil o gráfico Q-Q, comparando la distribución de los cuantiles de los datos originales observados en la estación fluviográfica La Marimba y los datos sintéticos del modelo RNA para tiempos de desfase de una y tres horas.

Para la comparación con un tiempo de desfase de una hora, los datos presentan un ajuste muy aproximado para la mayor parte de la serie, observándose una ligera tendencia a subestimar la magnitud del nivel durante los eventos cuyo registro fue mayor a 0,92 m.



Figura 5-5. Gráfico Cuantil-Cuantil para modelo jucosrma (RNA) con tiempos de desfase de 1 y 3 horas

Es importante notar que la cantidad de observaciones disponibles es menor entre mayor es la magnitud del nivel observado, por lo que durante el entrenamiento de los algoritmos esto es un aspecto que puede tener influencia sobre el ajuste del algoritmo.

Para el caso del modelo con tiempo de desfase de 3 horas, el umbral para el cual se empieza a subestimar la magnitud se ubica alrededor de los 0,88 m, ligeramente menor al del modelo con desfase de 1 hora, también se observa que la magnitud estimada es más distante respecto al valor registrado y empieza a notarse una ligera oscilación alrededor de la línea de 45 grados "ideal".

El modelo con tiempo de desfase de 6 horas muestra un ajuste bastante cercano a la línea de 45 grados, sin embargo se observa que el ajuste se desprende en mayor medida de la línea "ideal" y de manera más anticipada en comparación a los modelos con 1 y 3 horas de tiempo de desfase.

El gráfico Cuantil-Cuantil evidencia que los modelos con tiempos de desfase de 12 y 24 horas, subestiman considerablemente los valores de nivel de mayor magnitud, mientras que los valores de menor magnitud muestran un mejor ajuste respecto a los datos observados.

Los gráficos Cuantil-Cuantil para tiempos de desfase de 6, 12 y 24 horas, se muestran en la Figura 5-6 y la Figura 5-7.



Figura 5-6. Gráfico Cuantil-Cuantil para modelo jucosrma (RNA) con tiempos de desfase de seis y doce horas



Figura 5-7. Gráfico Cuantil-Cuantil para modelo jucosrma (RNA) con tiempo de desfase de 24 horas

Entre mayor es la magnitud del nivel y el tiempo de desfase se subestima en mayor medida, esto puede deberse a que son datos menos frecuentes en las observaciones y a la condición inherente de que los modelos desconocen el periodo antes de la creciente.

5.2 Efecto de la extensión del registro de horas de las variables de entrada

Para evaluar el efecto que tiene la extensión del registro de horas de las variables de entrada del modelo, se han calibrado y validado modelos RNA que utilizan la información de las estaciones pluviográficas San Rafael, Las Juntas, Campos de Oro y la estación fluviográfica La Marimba.

El tiempo de desfase (Δ T) del modelo se varió desde 1 hasta las 72 horas. Por otra parte, el número de horas de registro que se utilizan como variables de entrada se analizaron desde 1 hora hasta las 240 horas previas al marco de referencia temporal del pronóstico.

La arquitectura de la red neuronal artificial consiste en una capa oculta con tres nodos, función de activación ELU y regularización tipo L2.

El modelo se evalúa comparando los registros del nivel del agua en el cauce a la altura de la estación fluviográfica La Marimba, contra las estimaciones realizadas de manera sintética por cada uno de los modelos RNA con tiempos de anticipación o desfase de 1 hasta 72 horas.

Horoo do rogistro				ΔT			
	1 hora	3 horas	6 horas	12 horas	24 horas	48 horas	72 horas
1	0,0289	0,0434	0,0614	0,0651	0,0636	0,0703	0,0718
2	0,0294	0,0401	0,0610	0,0625	0,0659	0,0678	0,0699
3	0,0279	0,0396	0,0542	0,0611	0,0631	0,0655	0,0760
6	0,0280	0,0427	0,0495	0,0564	0,0608	0,0626	0,0704
12	0,0227	0,0416	0,0505	0,0573	0,0563	0,0674	0,0654
24	0,0263	0,0400	0,0506	0,0530	0,0560	0,0676	0,0692
48	0,0292	0,0334	0,0550	0,0581	0,0572	0,0645	0,0675
72	0,0296	0,0397	0,0560	0,0562	0,0558	0,0631	0,0731
96	0,0285	0,0385	0,0543	0,0539	0,0648	0,0669	0,0722
120	0,0304	0,0449	0,0569	0,0553	0,0639	0,0669	0,0689
240	0,0347	0,0501	0,0543	0,0550	0,0640	0,0703	0,0792
	0.0347	0.0501	0.0614	0.0651	0.0659	0.0703	0.0792

Simbología	0,0347	0,0501	0,0614	0,0651	0,0659	0,0703	0,0792
	0,0289	0,0401	0,0543	0,0564	0,0631	0,0669	0,0704
	0,0227	0,0334	0,0495	0,0530	0,0558	0,0626	0,0654

En el Cuadro 5-3 se muestran los errores RMSE evaluados sobre el conjunto de datos de validación, el cual corresponde a un subconjunto del 30% del total del registro disponible y que es seleccionado de manera aleatoria. Cada error mostrado proviene de una configuración de modelo específica de tiempo de desfase y extensión del registro que se utiliza para las variables de entrada.

El Cuadro 5-3 detalla, además, una coloración para diferenciar en cada columna los valores máximos (rojo) de los mínimos (azul), permitiendo identificar que conforme se incrementan las horas de registro también se reduce el error hasta alcanzar un valor mínimo; posteriormente, el error empieza a crecer respecto a la cantidad de variables de entrada.

Los modelos con muy pocas horas de registro pueden tener dificultades para representar toda la complejidad del fenómeno, mientras que modelos con una gran cantidad de horas de registro tienen mayores dificultades para generalizar los resultados sobre el conjunto de datos de validación; por lo tanto, se puede identificar que existe un rango en el cual los modelos brindan mejores resultados sobre el conjunto de datos de validación.

Los modelos con tiempos de desfase ∆T menores son los que presentan mejores resultados en los ajustes, corresponde entonces que entre más cercano sea en el tiempo el pronóstico, la estimación es más exacta.

Es congruente que un modelo que realiza pronósticos a un futuro más distante, también tenga inherentemente un mayor error, esto porque existe un mayor número de información desconocida para el modelo y, por lo tanto, mayor incertidumbre en el fenómeno que se desea analizar.

De los mismos resultados también se pueden extraer los errores mínimos obtenidos para cada tiempo de desfase. Estos se muestran en la Figura 5-8 de manera gráfica.



Figura 5-8. Errores mínimos RMSE (m) obtenidos para distintos tiempos de desfase ΔT

5.3 Efecto de la cantidad de estaciones de entrada

El efecto de la variación en el número y tipo de estaciones de entrada al modelo es analizado combinando las estaciones pluviográficas y fluviográficas disponibles, desarrollando modelos que estiman el nivel del agua en la estación fluviográfica La Marimba con un determinado tiempo de anticipación.

Los modelos contemplan la información de las últimas 24 horas de registro para las estaciones respectivas, la arquitectura de la red consiste en una capa oculta con tres nodos, función de activación ELU y regularización L2.

En el Cuadro 5-4 se detallan los modelos y estaciones de insumo, además del número total de observaciones disponibles para cada modelo según la combinación de estaciones.

Estaciones de entrada	ID modelo	Observaciones
La Marimba	ma	15665
La Marimba+Las Juntas	ju+ma	15504
La Marimba+Campos de Oro	co+ma	12220
La Marimba+San Rafael	sr+ma	15453
La Marimba+Santa Lucía	sl+ma	8488
La Marimba+Ecomuseo	eco+ma	8880
La Marimba+Las Juntas+Campos de Oro	ju+co+ma	13938
La Marimba+Las Juntas+San Rafael	ju+sr+ma	15292
La Marimba+Las Juntas+Santa Lucía	ju+sl+ma	8326
La Marimba+Las Juntas + Ecomuseo	ju+eco+ma	8719
La Marimba+Campos de Oro+San Rafael	sr+co+ma	12007
La Marimba+Campos de Oro+Santa Lucía	sl+co+ma	8373
La Marimba+Campos de Oro+Ecomuseo	eco+co+ma	8652
La Marimba+Santa Lucía+San Rafael	sl+sr+ma	8275
La Marimba+Santa Lucía+Ecomuseo	sl+eco+ma	7265
La Marimba+San Rafael+ Ecomuseo	eco+sr+ma	8667
La Marimba+Las Juntas+San Rafael+ Campos de Oro	ju+co+sr+ma	11846
La Marimba+Las Juntas+San Rafael+ Santa Lucía	ju+sl+sr+ma	8114
La Marimba+Las Juntas +Ecomuseo+Santa Lucía	Ju+eco+sl+ma	7104
La Marimba+Las Juntas+Santa Lucía+ Campos de Oro	ju+co+sl+ma	8212
La Marimba+ Las Juntas +Ecomuseo+Campos de Oro	ju+co+eco+ma	8491
La Marimba+Campos de Oro+Santa Lucía+San Rafael	co+sr+sl+ma	8160
La Marimba+San Rafael+Ecomuseo+Campos de Oro	co+sr+eco+ma	8439
La Marimba+Campos de Oro+Santa Lucía+Ecomuseo	co+sl+eco+ma	7150
La Marimba+Santa Lucía+San Rafael+Ecomuseo	sl+sr+eco+ma	7052
La Marimba+Las Juntas+Campos de Oro+San	iutcoterteltma	7000
Rafael+Santa Lucía	jutcotsitsitilla	1999
La Marimba+Las Juntas+Campos de Oro+San	iutcotertocotma	8278
Rafael+Ecomuseo	jurcorsirecorlia	0270
La Marimba+Las Juntas+ Campos de Oro+San	ju+co+sr+sl+eco+m	6776
Rafael+Santa Lucía+Ecomuseo	а	0110

Una vez que se realiza el entrenamiento y validación de todos los modelos, se documentan los errores RMSE evaluados sobre el subconjunto de datos de validación que equivale al 30% de la extensión total disponible. En el Cuadro 5-5 se detalla el resumen de errores RMSE mínimos obtenidos para los modelos RNA horarios.

De manera general, se observa que el modelo con mejores resultados fue el modelo *jucosrma*, con buenos resultados tanto para pronósticos a pocas horas como hasta las 12 horas.

ID	Obs	∆T=1	∆T=3	∆T=6	∆T=12	Promedio	
ju+co+sr+ma	11846	0,0234	0,0362	0,0447	0,0516	0,0390	
ju+co+ma	13938	0,0232	0,0396	0,0511	0,0606	0,0436	
ju+ma	15504	0,0267	0,0378	0,0443	0,0516	0,0401	
ju+sr+ma	15292	0,0277	0,0385	0,0518	0,0621	0,0450	
ma	15665	0,0287	0,0438	0,0494	0,0506	0,0431	
ju+co+eco+ma	8491	0,0300	0,0436	0,0557	0,0595	0,0472	
ju+co+sl+ma	8212	0,0262	0,0441	0,0511	0,0568	0,0445	
ju+eco+sl+ma	7104	0,0292	0,0460	0,0514	0,0602	0,0467	
ju+sr+sl+ma	8114	0,0376	0,0447	0,0523	0,0554	0,0475	
co+ma	12220	0,0279	0,0364	0,0537	0,0541	0,0430	
sr+ma	15453	0,0243	0,0418	0,0457	0,0518	0,0409	
sl+ma	8488	0,0327	0,0460	0,0493	0,0600	0,0470	
eco+ma	8880	0,0330	0,0484	0,0541	0,0702	0,0514	
sl+eco+ma	7265	0,0255	0,0453	0,0472	0,0561	0,0435	
sr+co+ma	12007	0,0263	0,0439	0,0515	0,0569	0,0447	
sl+co+ma	8373	0,0339	0,0415	0,0429	0,0533	0,0429	
ju+sl+ma	8326	0,0324	0,0349	0,0495	0,0557	0,0431	
ju+eco+ma	8719	0,0226	0,0463	0,0587	0,0558	0,0458	
eco+co+ma	8652	0,0292	0,0449	0,0596	0,0637	0,0493	
eco+sr+ma	8667	0,0287	0,0516	0,0542	0,0662	0,0502	
sr+sl+ma	8275	0,0353	0,0418	0,0485	0,0504	0,0440	
co+sr+sl+ma	8160	0,0358	0,0416	0,0461	0,0509	0,0436	
co+sr+eco+ma	8439	0,0328	0,0416	0,0504	0,0588	0,0459	
co+sl+eco+ma	7150	0,0302	0,0481	0,0499	0,0532	0,0454	
sr+sl+eco+ma	7052	0,0375	0,0444	0,0584	0,0566	0,0492	
ju+co+sr+sl+ma	7999	0,0323	0,0459	0,0522	0,0579	0,0471	
ju+co+sr+eco+ma	8278	0,0305	0,0389	0,0475	0,0578	0,0437	
ju+co+sr+sl+eco+ma	6776	0,0291	0,0459	0,0528	0,0637	0,0479	
		0.0376	0,0516	0,0596	0,0702	0,0514	
Simbología		0.0292	0,0439	0,0511	0,0567	0,0449	
		0.0226	0.0349	0.0429	0.0504	0.0390	

En contraposición, el modelo con el mayor error corresponde al modelo *ecoma*, modelo que utiliza información únicamente de las estaciones fluviográficas Ecomuseo y La Marimba. Además, cabe destacar que es un modelo con un número limitado de observaciones para realizar el entrenamiento.

Con los resultados de este análisis, se pudo corroborar una ligera tendencia de que los modelos presentan mejores resultados a un mayor número de observaciones disponibles. La Figura 5-9 muestra las líneas de tendencia para los errores RMSE mínimos de los obtenidos, agrupados para tiempos de desfase de 1, 3, 6 y 12 horas.

El número de observaciones para los distintos modelos van desde las 7104 horas (0,8 años) hasta las 15665 horas (1,8 años) de medición continua.



Figura 5-9. Relación entre errores mínimos y número de observaciones disponibles para calibrar los modelos

Es importante recalcar que hubo modelos que, a pesar de disponer de una menor cantidad de datos para el entrenamiento, lograron de los mejores resultados, de modo que existen combinaciones de estaciones que permiten describir de mejor manera el fenómeno de precipitación-escorrentía en la cuenca.

La calidad de los modelos es comparada por medio de técnicas de agrupamiento o *clustering*, utilizando el método de reducción dimensional de Análisis de Componentes Principales (ACP) en combinación de K-medias. Es posible visualizar en un espacio bidimensional los resultados de los modelos mostrados en el Cuadro 5-5. Cabe mencionar que ACP tiene el supuesto de que los componentes principales son combinaciones lineales de las variables originales.

La Figura 5-10 muestra el agrupamiento realizado con base en el método ACP para los resultados de modelos RNA con tiempos de desfase de 1, 3, 6 y 12 horas. Para este análisis en específico, los dos componentes principales mostrados describen el 72.45% de la variabilidad de los datos originales.



Figura 5-10. Agrupamiento de modelos RNA horarios por medio del método ACP

Agrupando en 4 *clusters,* se pueden diferenciar distintas calidades de ajustes según un número determinado de observaciones disponibles. Se detallan en el Cuadro 5-6 los modelos correspondientes a cada uno de los agrupamientos utilizando el método ACP.

El Cuadro 5-7 detalla los errores RMSE medios de cada cluster (grupo de modelos) para los distintos tiempos de desfase.

C1	C2	C3	C4
ju+co+eco+ma	eco+ma	sl+co+ma	ju+co+sr+ma
ju+co+sl+ma	ju+eco+ma	ju+sl+ma	ju+co+ma
ju+eco+sl+ma	eco+co+ma	sr+sl+ma	ju+ma
ju+sr+sl+ma	eco+sr+ma	co+sr+sl+ma	ju+sr+ma
sl+ma	ju+co+sr+sl+eco+ma	ju+co+sr+eco+ma	ma
sl+eco+ma			co+ma
co+sr+eco+ma			sr+ma
co+sl+eco+ma			sr+co+ma
sr+sl+eco+ma			
ju+co+sr+sl+ma			

Cuadro 5-6. Agrupamiento de modelos RNA horarios por medio del método ACP

Cuadro 5-7. Errores y observaciones para los agrupamientos de modelos RNA horarios con ACP

Grupo	# Obs	RMSE (m) ∆T=1 h	RMSE (m) ∆T=3 h	RMSE (m) ∆T=6 h	RMSE (m) ∆T=12 h	RMSE medio (m)	∆RMSE (%)
C1	7831	0,0314	0,0450	0,0518	0,0574	0,0464	9,4%
C2	8339	0,0285	0,0474	0,0559	0,0639	0,0489	15,3%
C3	8282	0,0336	0,0397	0,0469	0,0536	0,0435	2,4%
C4	13991	0,0260	0,0398	0,0490	0,0549	0,0424	0,0%

De manera general, los mejores resultados se obtuvieron con los modelos del Grupo 4, coincidiendo también con los modelos que en promedio disponían de un mayor número de observaciones para su entrenamiento.

El Grupo 3 es el siguiente conjunto con menor error RMSE, con un incremento del error medio de un 2,4% respecto al Grupo 4. Cabe recalcar que estos modelos fueron entrenados con un número considerablemente menor de observaciones, lo que evidencia su elevada capacidad de predicción a pesar de las mayores limitaciones en los datos disponibles para calibrar cada modelo.

Además, se puede observar que los modelos del Grupo 4 fueron notablemente mejores para estimar el nivel con una hora de anticipación respecto a los del Grupo 3; no obstante, para los demás tiempos de desfase mostraron resultados similares. Los modelos de los grupos 1 y 2 corresponden a los que tuvieron un mayor error promedio; al mismo tiempo, fueron modelos con mayores limitaciones en la disponibilidad de datos para el entrenamiento, aspecto considerado esencial para la calibración.

De manera complementaria, se contrasta el agrupamiento de los modelos con una segunda técnica de reducción dimensional. Específicamente se utilizó la metodología de *Uniform Manifold Approximation and Projection* (UMAP), identificando también 4 *clusters* o grupos, tal como se muestra Figura 5-11.



Figura 5-11. Agrupamiento de modelos RNA horarios por medio de UMAP

C1 C2 C3 C4 ju+co+ma ju+co+eco+ma sl+co+ma ju+co+sr+ma ju+sr+ma ju+co+sl+ma sr+sl+ma ju+ma ju+eco+sl+ma co+sr+sl+ma co+ma ma ju+sl+ma ju+sr+sl+ma sr+ma co+sr+eco+ma sl+ma ju+co+sr+eco+ma eco+ma sl+eco+ma sr+co+ma ju+eco+ma eco+co+ma eco+sr+ma co+sl+eco+ma sr+sl+eco+ma ju+co+sr+sl+ma ju+co+sr+sl+eco+ma

Cuadro 5-8. Agrupamiento de calidad de modelos RNA horarios por medio del método UMAP

Cuadro 5-9. Errores y observaciones para los agrupamientos de modelos RNA horarios con UMAP

Grupo	# Obs	RMSE (m) ∆T=1 h	RMSE (m) ∆T=3 h	RMSE (m) ∆T=6 h	RMSE (m) ∆T=12 h	RMSE medio (m)	∆RMSE (%)
C1	11082	0,0291	0,0383	0,0507	0,0582	0,0441	8,1%
C2	8238	0,0300	0,0460	0,0532	0,0595	0,0472	15,7%
C3	8269	0,0350	0,0416	0,0458	0,0515	0,0435	6,7%
C4	14617	0,0258	0,0399	0,0460	0,0514	0,0408	0,0%

En el caso del agrupamiento por medio de la técnica de reducción dimensional UMAP, el grupo con los mejores resultados posee un promedio de 14617 observaciones y un RMSE medio de 0,0408 m.

El segundo grupo con mejores resultados es el C1 y muestra un incremento del error del 6,7% respecto al grupo C4; no obstante, fueron modelos que en promedio tuvieron significativamente menor cantidad de datos para el entrenamiento y, por lo tanto, se considera que tienen un gran potencial para pronosticar las condiciones hidrológicas.

Una vez que se realiza el agrupamiento de los modelos con ambas técnicas de reducción dimensional, se realiza un conteo del uso de cada estación dentro de los modelos con mejores resultados (RMSE medio menor a 0,047 m). Se muestra en la Figura 5-12 un histograma de frecuencia relativo tanto para ACP como para UMAP.


Figura 5-12. Frecuencia relativa de estaciones en modelos RNA horarios con mejores resultados

Debido a que la estación fluviográfica La Marimba forma parte de todos los modelos evaluados, esta presenta una frecuencia relativa de uso significativamente mayor a las demás estaciones.

Exceptuando el caso de la estación fluviográfica La Marimba, las estaciones pluviográficas tuvieron una mayor presencia en los modelos RNA horarios con mejores resultados, siendo las estaciones Santa Lucía y Ecomuseo las estaciones menos presentes dentro de los modelos con mejores ajustes.

Es importante mencionar que los resultados se basan en la calibración sobre los datos disponibles al momento de la investigación, pero no excluye la posibilidad que teniendo una mayor cantidad de datos los resultados puedan variar, permitiendo que algunos modelos mejoren sus resultados.

Del análisis se desprende que utilizar un ensamble de modelos podría permitir una construcción más precisa del hidrograma, utilizando los mejores modelos para cada tiempo de desfase y logrando así una disminución del error del pronóstico para varias horas.

6 Análisis horario con Redes Neuronales Recurrentes (RNN)

6.1 Efecto del tiempo de desfase (ΔT) sobre el pronóstico

De manera análoga al análisis realizado en la sección 5.1 con redes neuronales artificiales (RNA), se estima el efecto del tiempo de desfase respecto a la calidad del pronóstico para modelos basados en redes neuronales recurrentes del tipo *Long Short-Term Memory* (LSTM).

Las estaciones evaluadas corresponden a la estación fluviográfica La Marimba y pluviográficas Campos de Oro, San Rafael y Las Juntas, siendo el nivel del agua en el cauce a la altura de La Marimba la variable objetivo para determinar con el modelo *AI*.

Se descartan los periodos de datos no coincidentes entre los registros de las estaciones de interés, obteniendo un total de 11846 observaciones horarias para cada estación, las ubicaciones de las estaciones se muestran en el mapa de la Figura 5-1.

Los modelos basados en RNN-LSTM fueron evaluados con la función de activación *ELU*. El Anexo 11.3 muestra los errores para distintas funciones de activación de los modelos con redes neuronales recurrentes en escala horaria para distintos números de nodos, determinándose que la función *ELU* tuvo el menor error RMSE medio, además de brindar mejores resultados para un mayor rango de número de nodos.

En el Anexo 11.3 también puede verificarse que existe un rango de número de nodos en el que se obtienen menores errores, esto ha sido tomado en consideración para evaluar los modelos RNN horarios con distintos números de nodos, cuyos errores se detallan en el Anexo 11.4.

En la Figura 6-1 se muestran los errores RMSE mínimos obtenidos para tiempos de desfase de 1 hasta 24 horas, con números de nodos de 1 hasta 1000, teniendo de insumo la información de las últimas 24 horas de precipitación y nivel en el cauce.



Figura 6-1. RMSE mínimos para el modelo RNN horario jucosrma

En la Figura 6-1 se puede corroborar que al igual que con los modelos RNA horarios, el error de la estimación se incrementa respecto al tiempo de anticipación o desfase del pronóstico, de modo que estimaciones a un futuro más distante poseen un error mayor respecto a instancias más cercanas en el tiempo.

El Anexo 11.4 detalla los errores RMSE para los distintos modelos RNN en escala horaria, para tiempos de desfase desde una hasta doce horas, números de nodos desde 1 hasta 25, función de activación tipo *ELU*.

Una vez que se calibran los modelos, se procede al ejercicio de generar series sintéticas con los modelos RNN horarios y compararlos con los registros totales disponibles en la estación fluviográfica La Marimba. En la Figura 6-2 se muestra la comparación de la serie registrada en La Marimba y la serie sintética para un tiempo de desfase de 1 hora.



Figura 6-2. Comparación de serie sintética RNN y original para tiempo de desfase de 1 hora

La Figura 6-2 detalla la gran similitud entre los datos registrados en la estación fluviográfica La Marimba y las estimaciones del modelo *jucosrma* RNN realizadas con 1 hora de anticipación.

El modelo realiza la estimación con base en la información de las últimas 24 horas de precipitación (Las Juntas, San Rafael y Campos de Oro) y nivel registrado (La Marimba), determinando el nivel del agua en el cauce con 1 hora de anticipación.

Las series de datos sobrepuestas se aprecian muy similares entre sí, complementariamente se muestran en la Figura 6-3 gráficos Cuantil-Cuantil o gráficos Q-Q para comparar las series sintéticas para múltiples tiempos de desfase y la serie observada en la estación fluviográfica La Marimba.



Figura 6-3. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempos de desfase de 1 y 3 horas

En los gráficos Cuantil-Cuantil mostrados en la Figura 6-3, se comparan los cuantiles ordenados de la serie sintética respecto a los datos ordenados de la serie original observada en La Marimba, de modo que entre más se aproxime a una línea de 45 grados mejor es el ajuste del modelo.

Para el caso del tiempo de desfase de 1 hora, se observa un ajuste muy próximo para niveles menores a 0,90 m, sobre este umbral el modelo tiende a subestimar la magnitud del nivel; no obstante, incluso para los mayores cuantiles el ajuste no se aleja drásticamente del ajuste ideal de 45°.

El modelo con tiempo de desfase de 3 horas presenta resultados que se ajustan bien a los datos observados para magnitudes de nivel bajas e intermedias, sin embargo, las estimaciones para magnitudes altas son subestimadas en mayor medida en comparación con el modelo con un tiempo de desfase de una hora.

De manera análoga, se muestran en la Figura 6-4 y Figura 6-5 los gráficos Cuantil-Cuantil para modelos con tiempos de desfase de 6, 12 y 24 horas.



Figura 6-4. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempos de desfase de 6 y 12 horas

Los resultados para el modelo con tiempo de desfase de 6 horas se observan muy similares a los del modelo de 3 horas, adicionalmente presenta una ligera oscilación del ajuste alrededor de la línea "ideal" de 45°.



Figura 6-5. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempo de desfase de 24 horas

En la Figura 6-3, Figura 6-4 y Figura 6-5 se puede apreciar que conforme mayor es el tiempo de desfase, los valores picos son subestimados en una mayor medida, esto se puede corroborar con el incremento en los errores RMSE mostrados en la Figura 6-1; no obstante, se considera que el ajuste logra representar sustancialmente el fenómeno, a pesar de ser realizado con numerosas horas de anticipación.

Los modelos basados en redes neuronales recurrentes LSTM-RNN evidenciaron mejores resultados que los modelos RNA para tiempos de desfase mayores, especialmente en el aspecto que subestiman en menor medida los valores picos.

6.2 Efecto de la extensión del registro de horas de entrada

La extensión del registro (D) utilizado como horas de entrada y también conocido como *loockback* es la cantidad de horas previas al evento que conoce el modelo para estimar con un determinado tiempo de anticipación el nivel del agua en la estación fluviográfica La Marimba.

El tiempo de desfase (Δ T) del modelo se varió desde 1 hasta las 24 horas, el número de horas de registro se analizaron desde 1 hora hasta las 120 horas previas al marco de referencia temporal del pronóstico.

Se ha desarrollado un modelo LSTM-RNN que utiliza la información de las estaciones pluviográficas San Rafael, Las Juntas, Campos de Oro y fluviográfica La Marimba, estimando con anticipación el nivel del agua en el cauce a la altura de la estación La Marimba. En el Cuadro 6-1 se muestran los errores RMSE mínimos obtenidos para las distintas configuraciones del modelo RNN horario *jucosrma*.

Horos do rogistro	ΔΤ									
Horas de regisiro	1 hora	3 horas	6 horas	12 horas	24 horas					
1	0,0422	0,0511	0,0617	0,1839	0,0649					
2	0,0388	0,0527	0,0595	0,0682	0,0655					
3	0,0434	0,0494	0,0633	0,0642	0,0642					
6	0,0388	0,0477	0,0598	0,0614	0,0653					
12	0,0352	0,0524	0,0549	0,0574	0,0653					
24	0,0380	0,0505	0,0527	0,0602	0,0676					
48	0,0342	0,0543	0,0548	0,0604	0,0659					
72	0,0350	0,0451	0,0539	0,0609	0,0667					
96	0,0658	0,0506	0,0542	0,0622	0,0628					
120	0,0902	0,0581	0,0634	0,0615	0,0639					

Cuadro 6-1. RMSE (m) para distintos ΔT y horas de registro de entrada al modelo jucosrma RNN horario

	0,0902	0,0581	0,0634	0,1839	0,0676
Simbología	0,0388	0,0508	0,0572	0,0614	0,0653
	0,0342	0,0451	0,0527	0,0574	0,0628

El cuadro anterior detalla una coloración para diferenciar en cada columna los valores máximos (rojo) de los mínimos (azul), facilitando identificar algún patrón en el cual se agrupen los valores mínimos.

Se observa que para tiempos de desfase entre 1 y 12 horas, el registro de entrada resulta conveniente en el rango de las 12 a 72 horas previas, para pronósticos a un futuro más distante (24 horas o más) se obtienen errores menores brindando al modelo de más información (hasta las últimas 120 horas).

Cabe mencionar que entre mayor es el registro de información que recibe el modelo, mayor es la cantidad de variables a calibrar. Además, el crecimiento de la cantidad de variables es muy acelerado y rápidamente se puede agotar la memoria del computador. Para este caso específico, se observó que 120 horas de registro para 3 estaciones pluviográficas y 1 estación fluviográfica es la máxima complejidad factible para el ordenador utilizado.

6.3 Efecto de la cantidad de estaciones de entrada

El efecto de la variación en el número y tipo de estaciones de entrada al modelo es analizado combinando las estaciones pluviográficas y fluviográficas disponibles, desarrollando modelos que estiman el nivel del agua en el cauce a la altura de la estación fluviográfica La Marimba con un determinado tiempo de anticipación.

Los distintos modelos evaluados se detallan en el Cuadro 5-4, estos corresponden a los mismo modelos evaluados con redes neuronales artificiales (RNA) y también poseen los mismos números de observaciones para el entrenamiento y validación de los algoritmos.

Realizando todas las posibles combinaciones para predecir el nivel en la estación La Marimba se obtienen 28 modelos, para los cuales se realizaron las debidas calibraciones y validaciones. Para detalle de los errores se puede consultar el Anexo 11.4.

Las horas de registro (D) o *lookback* para este análisis se definieron en 48 horas, es decir, el modelo hace uso de las últimas 48 horas de información para realizar el pronóstico, para mayor detalle se puede consultar la sección 6.2 donde se justifica este valor como apropiado para este rango de tiempos de desfase.

En la Figura 6-6 se muestra un gráfico de dispersión y un ajuste lineal del error RMSE respecto al número total de observaciones disponibles para modelos RNN horarios con tiempos de desfase de 1 hasta 12 horas.

Existe una ligera tendencia general de que entre mayor sea el número de observaciones menor es el error RMSE obtenido y, por lo tanto, el modelo logra un mejor ajuste. Sin embargo, debe recalcarse la presencia de algunos modelos que a pesar de tener un número menor de observaciones lograron ajustes dentro de los mejores resultados.

El Cuadro 6-2 detalla el resumen de los errores RMSE mínimos obtenidos para los distintos modelos RNN horarios y respectivos tiempos de desfase.



Figura 6-6. Errores mínimos y número de observaciones disponibles para calibrar los modelos RNN

ID	Obs	ΔT=1	∆T=3	∆T=6	∆T=12	Promedio
ju+co+sr+ma	11846	0,0344	0,0428	0,0521	0,0569	0,0465
ju+co+ma	13938	0,0329	0,0414	0,0515	0,0552	0,0453
ju+ma	15504	0,0361	0,0467	0,0543	0,0568	0,0485
ju+sr+ma	15292	0,0274	0,0324	0,0425	0,0498	0,0380
ma	15665	0,0537	0,0599	0,0623	0,0628	0,0597
ju+co+eco+ma	8491	0,0277	0,0387	0,0492	0,0524	0,0420
ju+co+sl+ma	8212	0,0773	0,0792	0,0823	0,1175	0,0891
ju+eco+sl+ma	7104	0,0582	0,0706	0,0632	0,0626	0,0637
ju+sr+sl+ma	8114	0,0832	0,0888	0,1001	0,1408	0,1032
co+ma	12220	0,0360	0,0419	0,0486	0,0515	0,0445
sr+ma	15453	0,0378	0,0448	0,0505	0,0543	0,0468
sl+ma	8488	0,0663	0,0666	0,0903	0,1065	0,0824
eco+ma	8880	0,0375	0,0475	0,0507	0,0522	0,0470
sl+eco+ma	7265	0,0755	0,0891	0,0984	0,1171	0,0950
sr+co+ma	12007	0,0418	0,0424	0,0505	0,0545	0,0473
sl+co+ma	8373	0,0564	0,0638 0,0724		0,1017	0,0736
ju+sl+ma	8326	0,0878	0,1014	0,1062	0,1246	0,1050
ju+eco+ma	8719	0,0352	0,0460	0,0531	0,0565	0,0477
eco+co+ma	8652	0,0298	0,0390	0,0470	0,0514	0,0418
eco+sr+ma	8667	0,0348	0,0453	0,0478	0,0523	0,0451
sr+sl+ma	8275	0,0427	0,0848	0,0993	0,0943	0,0803
co+sr+sl+ma	8160	0,0483	0,0562	0,0675	0,0660	0,0595
co+sr+eco+ma	8439	0,0384	0,0410	0,0472	0,0524	0,0448
co+sl+eco+ma	7150	0,0489	0,0704	0,0760	0,0731	0,0671
sr+sl+eco+ma	7052	0,0405	0,0442	0,0447	0,0488	0,0446
ju+co+sr+sl+ma	7999	0,0574	0,0629	0,1076	0,1099	0,0845
ju+co+sr+eco+ma	8278	0,0314	0,0409	0,0499	0,0530	0,0438
ju+co+sr+sl+eco+ma	6776	0,0639	0,0708	0,0819	0,0982	0,0787

Cuadro 6-2. Resumen de errores RMSE (m) mínimos de modelos RNN horarios

	0.0878	0,1014	0,1076	0,1408	0,1050
Simbología	0.0412	0,0471	0,0537	0,0569	0,0481
	0.0274	0,0324	0,0425	0,0488	0,0380

La calidad de los modelos es comparada por medio de técnicas de agrupamiento o *clustering*, específicamente usando el método K-medias en conjunto con la técnica de reducción dimensional de Análisis de Componentes Principales o ACP. En la Figura 6-7 se muestra el agrupamiento realizado para los resultados de modelos con tiempos de desfase de 1, 3, 6 y 12 horas en el programa RStudio.



Figura 6-7. Agrupamiento de modelos RNN horarios por medio de ACP

Para este análisis en específico, los dos componentes principales mostrados describen el 94.06% de la variabilidad de los datos.

Agrupando en cinco *clusters,* se pueden diferenciar calidades de ajustes según un número determinado de observaciones totales disponibles. En el Cuadro 6-3 se detallan los modelos correspondientes a cada uno de los agrupamientos utilizando el método de ACP.

C1	C2	C3	C4	C5
ju+co+sr+ma	ju+ma	ju+eco+sl+ma	ju+co+sl+ma	ju+co+eco+ma
ju+co+ma	ma	sl+co+ma	ju+sr+sl+ma	eco+ma
ju+sr+ma	sr+ma	sr+sl+ma	sl+ma	ju+eco+ma
co+ma		co+sr+sl+ma	sl+eco+ma	eco+co+ma
sr+co+ma		co+sl+eco+ma	ju+sl+ma	eco+sr+ma
		ju+co+sr+sl+eco+ma	ju+co+sr+sl+ma	co+sr+eco+ma
				sr+sl+eco+ma
				ju+co+sr+eco+ma

Grupo	# Obs	RMSE (m) ∆T=1 h	RMSE (m) ∆T=3 h	RMSE (m) ∆T=6 h RMSE (m ∆T=12 h		RMSE medio (m)	∆RMSE (%)
C1	13061	0,0345	0,0402	0,0490	0,0536	0,0443	0,0%
C2	15541	0,0425	0,0505	0,0557	0,0580	0,0517	16,6%
C3	7640	0,0531	0,0694	0,0767	0,0827	0,0705	59,0%
C4	8067	0,0746	0,0813	0,0975	0,1194	0,0932	110,3%
C5	8397	0,0344	0,0428	0,0487	0,0524	0,0446	0,6%

Cuadro 6-4. Errores y observaciones para los agrupamientos de modelos RNN horarios por medio de ACP

En el Cuadro 6-4 se detallan los errores RMSE promedio de cada grupo para los distintos tiempos de desfase, además del error promedio y la variación porcentual respecto al grupo que obtuvo el error RMSE promedio mínimo.

El Grupo 1 presenta el error RMSE promedio mínimo, que a su vez corresponde a los modelos con un mayor número de observaciones disponibles para el entrenamiento, en comparación con el Grupo 5 que presenta una calidad de ajustes muy similar pero con una cantidad considerablemente menor de observaciones.

El Grupo 2 corresponde a los modelos con mayor número de datos totales y, por lo tanto, también para el entrenamiento (70% del número total de observaciones); no obstante, presentaron errores ligeramente superiores (+16.6%) a los del Grupo 1.

Los modelos de los Grupos 3 y 4 poseen la menor cantidad de observaciones disponibles para el entrenamiento, además presentan los mayores errores RMSE y se considera que no lograron representar apropiadamente el fenómeno deseado.

Cabe mencionar que durante el entrenamiento de algoritmos RNN del tipo LSTM, fue notablemente más difícil de lograr convergencia en los modelos con menor cantidad de observaciones en comparación al entrenamiento de los modelos RNA, en algunos casos incluso sin lograr un ajuste satisfactorio y que represente apropiadamente el fenómeno de escorrentía expresado a través de la variación del nivel del agua en el cauce.

De manera complementaria, se analizan los resultados con una segunda técnica de reducción dimensional UMAP. En la Figura 6-8 se muestra el agrupamiento por medio de UMAP para los modelos RNN horarios.

Utilizando la técnica de reducción dimensional UMAP se identificó un mayor número de agrupaciones respecto a ACP. En el Cuadro 6-5 se detallan los siete *clusters* identificados.



Figura 6-8. Agrupamiento de modelos RNN horarios por medio de UMAP

Cuadro 6-5. Agrupamiento de modelos RNN horarios por medio de UMAP

C1	C2	C3	C4	C5	C6	C7
eco+ma	ju+co+sl+m	ju+co+ma	ju+eco+sl+	ju+co+eco	ju+co+sr+	sl+ma
	а		ma	+ma	ma	
ju+eco+ma	ju+sr+sl+ma	ju+ma	co+sr+sl+m	eco+co+m	co+ma	sl+co+ma
			а	а		
eco+sr+ma	sl+eco+ma	ju+sr+ma	co+sl+eco+	ju+co+sr+	sr+co+ma	sr+sl+ma
			ma	eco+ma		
co+sr+eco	ju+sl+ma	ma				ju+co+sr+sl+
+ma						ma
sr+sl+eco+		sr+ma				ju+co+sr+sl+
ma						eco+ma

Grupo	# Obs	RMSE (m) ∆T=1 h	RMSE (m) ∆T=3 h	RMSE (m) ∆T=6 h	RMSE (m) ∆T=12 h	RMSE medio (m)	∆ RMSE (%)
C1	8351	0,037	0,045	0,049	0,052	0,046	7,7%
C2	7979	0,081	0,090	0,097	0,125	0,098	130,7%
C3	15170	0,038	0,045	0,052	0,056	0,048	12,1%
C4	7471	0,052	0,066	0,069	0,067	0,063	49,1%
C5	8474	0,030	0,040	0,049	0,052	0,043	0,0%
C6	12024	0,037	0,042	0,050	0,054	0,046	8,4%
C7	7982	0,057	0,070	0,090	0,102	0,080	87,9%

Cuadro 6-6. Errores y observaciones para los agrupamientos de modelos RNN horarios por medio de UMAP

Para el caso del agrupamiento con UMAP los errores se muestran en el Cuadro 6-6. El grupo con menor error medio no corresponde a los modelos con mayor cantidad de observaciones, el grupo 5 obtuvo un número de observaciones promedio de 8474 y un error RMSE promedio de 0,043 m.

Los grupos 1, 7 y 3 registraron un incremento del error de 7,7%, 8,4% y 12,1% respectivamente; para los demás modelos se considera que no lograron estimar apropiadamente el nivel en la estación fluviográfica La Marimba, asociado a los errores significativamente mayores que presentaron.

Una vez que se agruparon los modelos por medio de ambas técnicas de reducción dimensional, se realizó un conteo de la aparición de cada estación dentro de los modelos con mejores resultados (RMSE promedio menor a 0,047 m), tanto para ACP (Grupos 1 y 5) como para UMAP (Grupos 1, 5 y 6) A continuación se detalla la frecuencia relativa del uso de estaciones dentro de los modelos RNN horarios con mejores resultados.



Figura 6-9. Conteo de estaciones utilizadas en modelos RNN horarios con mejores resultados

Cabe recalcar que la estación La Marimba se utilizó de insumo en todos los modelos, lo que hace que esta estación tenga una frecuencia de uso significativamente mayor respecto a las demás estaciones.

Es notable que, dentro de los modelos con mejores resultados, la estación fluviográfica Santa Lucía fue la menos utilizada y esto puede estar relacionado a que el registro de esta estación es poco coincidente con el de las demás estaciones, teniendo como resultado que se disponga de una menor cantidad de datos para realizar el entrenamiento cuando se utiliza la estación Santa Lucía.

El proceso de entrenamiento de una red neuronal recurrente es significativamente más complejo que el de una red neuronal artificial y una mayor limitación en los datos puede tener un impacto significativo sobre los errores, de esta manera la estación Santa Lucía tuvo una mayor presencia en los mejores resultados dentro de los modelos RNA que dentro de los modelos RNN.

En términos generales y excluyendo el caso de la estación fluviográfica La Marimba, en los mejores modelos se observa una mayor presencia de estaciones pluviográficas que fluviográficas, implicando que el uso de un mayor número de estaciones fluviográficas no representó una mejora sustancial en la calidad de las estimaciones del nivel del agua en el cauce.

7 Análisis diario

Promedio

7.1 Análisis diario con redes neuronales artificiales (RNA)

En la presente sección se analiza la implementación de un modelo regresivo basado en redes neuronales artificiales (RNA), el cual estima el nivel medio diario en el cauce a la altura de la estación fluviográfica La Marimba.

Con base en los resultados del análisis de modelos regresivos en escala horaria expuesto en el capítulo 5, se selecciona el modelo *jucosrma* que utiliza la información de las tres estaciones pluviográficas y de la estación fluviográfica La Marimba, pronosticando el nivel en la estación La Marimba con un determinado tiempo de anticipación.

En el Cuadro 7-1 se muestran los errores RMSE (m) obtenidos sobre el conjunto de datos de validación que corresponde a un 30% de la extensión del registro total disponible; la estimación se realizó con un día de anticipación y utilizando los últimos 30 días de información para alimentar el modelo.

Nodos	Relu	ELU	Tanh			
3	0,0468	0,0495	0,0476			
10	0,0595	0,0471	0,0445			
25	0,0442	0,0466	0,0454			
50	0,0588	0,0486	0,0484			
100	0,0501	0,0488	0,0474			
250	0,0508	0,0499	0,0506			
500	0,0508	0,0496	0,0515			
	•					

Cuadro 7-1. RMSE (m) del modelo jucosrma (RNA) diario, distintas funciones de activación y número de nodos

-																	
La función	de	ac	tivad	ción	con	un	error	RMSE	pror	nec	dio	menor	fue	la	tangente	hiperb	ólica,

0.0486

0.0479

con un rango de 10 a 25 nodos en la capa oculta de la RNA.

0.0516

Posteriormente, se procede a evaluar el número de días de registro (D) más apropiado para cada tiempo de desfase (Δ T) o anticipación. En el Cuadro 7-2 se muestran los errores RMSE (m) determinados para distintas configuraciones de tiempos de desfase y de 1 a 45 días de registro, considerando una RNA con 25 nodos en su capa oculta y la función de activación *tanh*.

Días do rogistro	ΔΤ										
Dias de registro	1 día	2 días	3 días	4 días	5 días						
1	0,0325	0,0489	0,0622	0,0550	0,0568						
2	0,0384	0,0500	0,0453	0,0553	0,0578						
3	0,0366	0,0396	0,0541	0,0522	0,0688						
5	0,0320	0,0475	0,0582	0,0546	0,0697						
10	0,0483	0,0529	0,0571	0,0682	0,0660						
15	0,0623	0,0566	0,0444	0,0554	0,0696						
30	0,0544	0,0749	0,0828	0,0736	0,0687						
45	0,0748	0,0959	0,0910	0,0862	0,0677						
	0,0748	0,0959	0,0910	0,0862	0,0697						
Simbología	0,0434	0,0514	0,0576	0,0553	0,0682						
	0.0320	0.0396	0.0444	0.0522	0.0568						

Cuadro 7-2. RMSE (m) para el modelo jucosrma (RNA) para distintos tiempos de desfase y días de registro

Analizando los modelos RNA en escala diaria, al igual que con los modelos a escala horaria, el error se incrementa si el tiempo de desfase también se incrementa, es decir, que entre mayor sea la anticipación del pronóstico, mayor es el error de la estimación del nivel en el cauce.

Los mejores ajustes se encontraron para una menor cantidad de días de registro que alimentan al modelo, entre 1 y 5 días fue el rango que permitió disminuir el error; esto, a su vez, sugiere que la precipitación ocurrida muchos días atrás no está aportando calidad a la capacidad de predicción del modelo RNA.

En el caso de la estimación del nivel realizada con un tiempo de desfase de 1 día por el modelo *jucosrma*, en el gráfico de dispersión mostrado en la Figura 7-1 se observa que se logra modelar la variable de una manera bastante aproximada al registro de la estación fluviográfica La Marimba, con un error RMSE de 0,032 m sobre los datos de validación que corresponden al 30% del total de los datos disponibles.

Complementariamente al gráfico de dispersión, en la Figura 7-2 y la Figura 7-3 se muestran gráficos Cuantil-Cuantil que comparan la serie media diaria observada en la estación fluviográfica La Marimba con los datos sintéticos estimados con 1, 2 y 3 días de anticipación.



Figura 7-1. Series sintética y observada del nivel medio diario del cauce en la estación La Marimba, utilizando el modelo jucosrma (RNA) con un tiempo de desfase de 1 día



Figura 7-2. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNA) con tiempo de desfase de 1 y 2 días



Figura 7-3. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNA) con tiempo de desfase de 3 días

Para la estimación con un tiempo de desfase de 1 día, los datos sintéticos y los datos medios diarios registrados en La Marimba se observan con una gran similitud, esto se representa como una línea de 45° en el gráfico Cuantil-Cuantil de la Figura 7-2; no obstante, también se observan algunas variaciones para algunos rangos de eventos, de modo que tampoco puede considerarse que el modelo predice la variable con total precisión con un tiempo de desfase de 1 día.

Para las estimaciones realizadas con dos días de anticipación y mostradas en el segundo gráfico de la Figura 7-2, el modelo subestimó ligeramente cuando la magnitud del nivel medio diario del cauce fue mayor a 0,80 m, además de que sobreestimó los valores en el rango de 0,40 m a 0,80 m, presentando un error RMSE de 0,040 m sobre el conjunto de datos de validación.

En la Figura 7-3 se detalla el gráfico Cuantil-Cuantil del modelo con un tiempo de desfase de tres días, el ajuste se observa aproximado a los datos registrados, con una tendencia a oscilar respecto a la línea ideal de 45° para magnitudes del nivel mayores 0,50 m.

En la sección 8.2 del presente informe se elaboran estimaciones con los modelos RNA de escala diaria, comparando eventos o periodos de varios días entre las estimaciones sintéticas y los registros, lo que a su vez representa una aplicación práctica como es el pronóstico "a tiempo real" con varios días de anticipación.

7.2 Análisis diario con redes neuronales recurrentes (RNN)

En esta sección se analiza la implementación de un modelo regresivo en escala diaria basado en redes neuronales recurrentes del tipo LSTM.

Se considera el modelo *jucosrma* el cual utiliza la información de las tres estaciones pluviográficas y de la estación fluviográfica La Marimba, estimando el nivel del agua en el cauce a la altura de la estación La Marimba con un determinado tiempo de desfase o anticipación.

La calidad de las estimaciones de los modelos entrenados se evalúa sobre los datos de validación (30% de los datos disponibles) para distintas funciones de activación, números de neuronas en la capa oculta desde 1 hasta 250 y teniendo de insumo la información de los últimos 5 días, en el Cuadro 7-3 se detallan los errores RMSE (m) obtenidos.

Neuronas	Relu	ELU	Tanh
1	0,1586	0,1581	0,0569
3	0,0450	0,0557	0,0666
5	0,0447	0,0573	0,0572
10	0,0474	0,0459	0,0476
25	0,0521	0,0481	0,0456
50	0,0536	0,0446	0,0454
100	0,0515	0,0457	0,0460
250	0,0511	0,0455	0,0449
Promedio	0,0630	0,0626	0,0513

Cuadro 7-3. RMSE (m) del modelo jucosrma (RNN) diario, distintas funciones de activación y número de nodos

La función de activación con el menor error RMSE medio fue la tangente hiperbólica; además, el error mínimo se obtuvo para un número de 250 neuronas en la capa oculta.

En el caso del entrenamiento de algoritmos RNN cuya capa oculta tenía menos de tres nodos, fue especialmente difícil lograr una calibración exitosa y esto se refleja en los grandes errores obtenidos sobre los datos de validación que se muestran en el Cuadro 7-3.

Complementariamente, se evalúa el efecto de los días de registro (*lookback*) que alimentan al modelo jucosrma RNN diario, en el Cuadro 7-4 se muestran los errores RMSE (m) obtenidos sobre el conjunto de datos de validación en la estación fluviográfica La Marimba.

Días do registro	ΔΤ				
Dias de registro	1 día	2 días	3 días	4 días	5 días
1	0,0464	0,0523	0,0518	0,0642	0,0561
2	0,0464	0,0525	0,0560	0,0585	0,0593
3	0,0451	0,0515	0,0545	0,0557	0,0553
5	0,0473	0,0509	0,0519	0,0554	0,0542
10	0,0477	0,0525	0,0536	0,0559	0,0578
15	0,0503	0,0491	0,0541	0,0508	0,0527
30	0,0495	0,0494	0,0495	0,0523	0,0516
45	0,0509	0,0525	0,0507	0,0532	0,0538

Cuadro 7-4. RMSE (m) del modelo jucosrma (RNN) para distintos tiempos de desfase y días de registro

	0,0509	0,0525	0,0560	0,0642	0,0593
Simbología	0,0475	0,0519	0,0528	0,0555	0,0548
	0,0451	0,0491	0,0495	0,0508	0,0516

La arquitectura de la red evaluada consiste en una capa oculta con 250 nodos, función de activación *Tanh*, regularización L2, tiempos de desfase de uno a cinco días y registro de 1 a 45 días previos.

Para un tiempo de desfase de 1 día se observa que los mejores resultados se obtuvieron con pocos días de registro, para tiempos de desfase mayores los modelos operaron mejor con registros de 15 a 45 días.

El entrenamiento de los modelos basados en LSTM-RNN son computacionalmente más complejos que los RNA, de modo que el tamaño de la serie diaria puede tener efecto en la calidad del entrenamiento, lo que a su vez puede dificultar una convergencia de los modelos y depende en mayor medida de la aleatoriedad intrínseca de cada entrenamiento.

En la Figura 7-4 se muestra un gráfico de dispersión con la estimación del nivel medio diario realizada por el modelo jucosrma (RNN) con un día de anticipación, en conjunto con los valores medios diarios del registro de la estación fluviográfica La Marimba.

Complementariamente, en la Figura 7-5 y Figura 7-6 se muestran gráficos Cuantil-Cuantil para modelos con tiempos de desfase de 1, 2 y 3 días respecto a los valores medios diarios registrados en la estación fluviográfica La Marimba.



Figura 7-4. Serie sintética diaria de modelo jucosrma (RNN) diario para tiempo de desfase de 1 día y valores medios diarios registrados en estación La Marimba



Figura 7-5. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempos de desfase de 1 y 2 días



Figura 7-6. Gráfico Cuantil-Cuantil para el modelo jucosrma (RNN) con tiempo de desfase de 3 días

En el gráfico de disperión de la Figura 7-4 se observa que el ajuste realizado con un tiempo de desfase de 1 día es considerablemente cercano al registro de la estación La Marimba. Esto también se representa como aproximadamente una línea en 45° del primer gráfico Cuantil-Cuantil de la Figura 7-5.

Los modelos con tiempos de desfase de 2 y 3 días mostraron mayores dificultades para simular apropiadamente la distribución de los datos, con una tendencia a subestimar los valores de nivel más altos como se puede verificar en el segundo gráfico de la Figura 7-5 y el gráfico de la Figura 7-6.

8 Comparación de resultados

8.1 Escala horaria

Con base en los resultados obtenidos y expuestos en los capítulos 5 y 6, en los cuales se evaluaron en una escala horaria los modelos basados en algoritmos RNA y RNN respectivamente, se desarrolla una comparación de resultados para algunos de los modelos de ambos tipos de redes neuronales.

Debido a que entre los dos tipos de algoritmos se acumulan 56 modelos para el análisis en escala horaria, para realizar una comparación se van a seleccionar los cuatro modelos con menor error medio RMSE; dos basados en RNA y dos en RNN.

Para los cuatro algoritmos seleccionados, se utilizan los modelos que permiten estimar el nivel del agua en la estación fluviográfica La Marimba para cada una de las próximas 12 horas de manera anticipada, generando así hidrograma sintético a futuro.

El desglose de errores para modelos basados en RNA y RNN se puede consultar en el Anexo 11.2 y Anexo 11.4, respectivamente.

En el Cuadro 8-1 se detallan los modelos seleccionados y una breve descripción de las características generales de cada modelo.

Modelo	Descripción
ju+co+sr+ma (RNA)	Modelo que utiliza información de 1 estación fluviográfica (La Marimba) y 3 pluviográficas (Las Juntas, Campos de Oro y San Rafael). El número de observaciones totales disponibles es de 11846 y corresponde al modelo RNA con menor error medio.
ju+ma (RNA)	Modelo que utiliza información de 1 estación fluviográfica (La Marimba) y 1 pluviográfica (Las Juntas). El número de observaciones totales disponibles es de 15504 y corresponde al segundo menor error evaluado en algoritmos RNA.
ju+sr+ma (RNN)	Modelo que utiliza información de 1 estación fluviográfica (La Marimba) y 2 pluviográficas (Las Juntas y San Rafael). El número de observaciones totales disponibles es de 15292 y corresponde al modelo RNN con menor error medio.
eco+co+ma (RNN)	Modelo que utiliza información de 2 estaciones fluviográficas (Ecomuseo y La Marimba) y una pluviográfica (Campos de Oro). El número de observaciones totales disponibles es de 8652 y corresponde al segundo modelo RNN con menor error medio.

En el caso de los modelos basados en algoritmos RNA, se observan las últimas 24 horas de los registros para realizar la estimación. Este parámetro fue evaluado en la sección 5.2 y se encontró como apto para esta aplicación específica.

Por otra parte, los modelos basados en algoritmos RNN observan las últimas 48 horas de los registros. En la sección 6.2 se expone la mejora de los modelos RNN al incrementar la información que observan para realizar la estimación.

De los registros compartidos por los cuatro modelos, se seleccionaron cuatro eventos de precipitación para comparar los hidrogramas sintéticos con el registro de la estación fluviográfica La Marimba.

Las fechas de los eventos son las siguientes:

- 05 de noviembre de 2015.
- 11 de noviembre de 2015.
- 28 de abril de 2016.
- 27 de mayo de 2016.

El modelado contempla un marco temporal que ubica el "cero" una vez que inicia la creciente, de modo que un tiempo de desfase de 1 hora corresponde a un pronóstico realizado 1 hora antes de que se aprecie un incremento significativo del nivel en el cauce, análogamente para otros tiempos de desfase.

8.1.1 Evento el día 05 de noviembre de 2015

Este evento ocurre durante la época típicamente lluviosa, en el cual se registró un incremento del nivel en la estación La Marimba de 0,60 m hasta los 1,60 m. La precipitación se produce durante 8 horas y es captada por las tres estaciones pluviográficas disponibles dentro de la cuenca.

La Figura 8-1 muestra el hietograma horario registrado durante el evento; además, el Cuadro 8-2 detalla las láminas de precipitación acumuladas durante las 24 horas del día del evento.



Figura 8-1. Precipitación horaria registrada del día 05-11-2015

Cuadro 8-2.	Láminas	de prec	ipitación	para el	l día	5-11-2015
-------------	---------	---------	-----------	---------	-------	-----------

Estación	Precipitación (mm)
San Rafael	18,8
Campos de oro	29,2
Las Juntas	14,4

La mayor parte de la precipitación fue detectada por la estación Campos de Oro; además, en la estación Las Juntas se presenta la mayor intensidad de lluvia poco antes del pico del hidrograma.

A continuación se muestran las estimaciones de los modelos para las próximas 12 horas y visto desde 1 hora antes de que inicie la variación del nivel en el cauce, de modo que para el momento en que el modelo realiza la estimación, falta al menos 1 hora para el inicio del incremento del nivel en el punto de control.



Figura 8-2. Evento del día 05-11-2015 visto con una hora de anticipación al inicio de la crecida

Analizando el evento con 1 hora de anticipación a la llegada de la creciente, se observa que los modelos jucosrma (RNA) y juma (RNA) lograron captar satisfactoriamente la mayor parte del hidrograma, con presencia de una oscilación inadecuada una vez pasado el pico del evento.

En el caso de los dos modelos basados en RNN, sí lograron identificar la creciente; no obstante, subestimaron en buena medida la magnitud del pico del evento. Cabe recalcar que el modelo jusrma (RNN) no observa la precipitación de la estación pluviográfica Campos de Oro, en la cual también se registró una lámina de precipitación significativa durante este evento.

Los hidrogramas mostrados en la Figura 8-2 fueron estimados con 1 hora antes de que inicie el incremento del nivel en la estación La Marimba. Complementariamente, los hidrogramas también pueden ser construidos observando con mayor anticipación, lo que resulta aún más exigente para los modelos.

En la Figura 8-3 y la Figura 8-4 se muestran los hidrogramas sintéticos estimados con 2 horas y 3 horas de anticipación a la llegada de la crecida en el punto de control respectivamente.



Figura 8-3. Evento del día 05-11-2015 visto con dos horas de anticipación al inicio de la crecida



Figura 8-4. Evento del día 05-11-2015 visto con tres horas de anticipación al inicio de la crecida

En el Anexo 11.5 se detallan los hidrogramas sintéticos modelados para otros tiempos de desfase, mostrando tanto antes del inicio de la creciente como posterior al pico del evento.

Pudo corroborarse que la magnitud del pico es subestimada en mayor medida conforme el tiempo de desfase es mayor, aspecto que fue demostrado en las secciones 5.1 y 6.1.

Complementariamente al punto recién mencionado en el párrafo anterior, los hietogramas mostrados en la Figura 8-1 detallan el pico de intensidad de lluvia cerca de las 15:00 horas, mientras que el nivel máximo se alcanza a las 16:00 horas. Esto implica que si se observa con una anticipación mayor a 1 hora, aún no ha ocurrido la mayor parte de la precipitación; por lo tanto, no se dispone de la información que describe la totalidad del evento.

Los modelos con mayores tiempos de desfase tienen una limitación implícita a recalcar, estos no disponen de la información que describe en mayor medida el evento porque este aún no ha ocurrido; no obstante, se observa que los modelos logran identificar el acercamiento de la creciente pero de manera atenuada.

8.1.2 Evento el día 11 de noviembre de 2015

Este evento ocurre durante la época lluviosa, la precipitación se prolonga durante aproximadamente 5 horas y ocasiona un incremento del nivel en la estación La Marimba desde los 0,60 m hasta cerca de 1,0 m.

En la Figura 8-5 se muestra el hietograma registrado para este evento. Además, en el Cuadro 8-3 se detallan las láminas de precipitación registradas el día 11 de noviembre de 2015.



Figura 8-5. Precipitación horaria del día 11-11-2015

Cuadro 8-3. Láminas	de precipitación	para el día 11-11-2015
---------------------	------------------	------------------------

Estación	Precipitación (mm)
San Rafael	11,2
Campos de oro	37,8
Las Juntas	1,6

Este evento registró la mayor parte de la precipitación en la estación Campos de Oro, seguido por la estación San Rafael y en la estación Las Juntas prácticamente no se registró precipitación ese día.

En la Figura 8-6 se muestran los hidrogramas estimados por los modelos para un periodo de 12 horas, con 1 hora de anticipación al instante que inicia el incremento del nivel en la estación La Marimba.



Figura 8-6. Evento del día 11-11-2015 visto con una hora de anticipación al inicio de la crecida

Este evento fue descrito de manera muy precisa por los modelos basados en RNN, acertando tanto la magnitud como el tiempo al pico. También logra describir por algunas horas el decaimiento posterior al pico.

Resulta notable el desempeño del modelo *jusrma* (RNN) porque este no observa la información de la estación que registró la mayor parte de la precipitación; este aspecto sugiere la posibilidad de que la red neuronal pueda inferir la magnitud de la totalidad del evento a partir de patrones de precipitación detectados en las otras estaciones pluviográficas.

Para este evento los modelos RNA lograron estimar de manera apropiada la llegada de la creciente; sin embargo, estos subestimaron de manera consirable la magnitud del nivel durante el pico.

El modelo *juma* (RNA) produjo la estimación más distante de las observaciones. Cabe notar que este modelo no observa información de las estaciones pluviográficas Campos de Oro ni San Rafael, que para este evento en específico fueron las estaciones donde se registraron las mayores láminas de precipitación, tal como se detalla en el Cuadro 8-3.

En la Figura 8-7 y la Figura 8-8 se muestran las estimaciones de los hidrogramas sintéticos con anticipaciones de 2 y 3 horas respectivamente.



Figura 8-7. Evento del día 11-11-2015 visto con dos horas de anticipación al inicio de la crecida



Figura 8-8. Evento del día 11-11-2015 visto con tres horas de anticipación al inicio de la crecida

Con 2 horas de anticipación la totalidad de los modelos lograron identificar la aproximación de la creciente, siendo el modelo *jusrma* (RNN) el que pronosticó en mejor medida la magnitud del evento.

Cabe notar que los modelos muestran oscilaciones posteriores al pico del evento, aproximándose al valor registrado pero con dificultad para estimar la magnitud del decaimiento del hidrograma a lo largo de las 12 horas del hidrograma sintético.

Para este evento en específico y un tiempo de desfase de 3 horas, únicamente el modelo *jucosrma* (RNA) logró identificar la generación de la creciente, determinando de manera muy cercana la magnitud, pero adelantando el tiempo al pico del evento.

En términos generales se observa que los modelos lograron captar, en su mayoría, satisfactoriamente la generación de la creciente con varias horas de anticipación; en algunos casos subestimando la magnitud del evento o variando el tiempo al pico. Los hidrogramas para otros tiempos de anticipación para este evento pueden consultarse en el Anexo 11.6.

8.1.3 Evento el día 28 de abril de 2016

Este evento de precipitación se registró durante la época seca del año 2016. La precipitación se produjo a lo largo de aproximadamente 5 horas, generando un incremento del nivel en la estación La Marimba desde los 0,30 m hasta los 0,45 m.

Se muestra en la Figura 8-9 el hietograma registrado durante este evento y en el Cuadro 8-4 las láminas de precipitación registradas por las tres estaciones pluviográficas el día 28 de abril de 2016.



Figura 8-9. Precipitación horaria del día 28-04-2016

Cuadro 8-4. Lá	áminas de prec	ipitación para	el día 28-04-2016
----------------	----------------	----------------	-------------------

Estación	Precipitación (mm)
San Rafael	0.2
Campos de oro	2.0
Las Juntas	11.0

La mayor lámina de precipitación fue registrada en la estación Las Juntas, por otra parte, en las otras dos estaciones apenas se registró precipitación durante todo el día.

Este evento corresponde a una creciente de magnitud menor, permitiendo también analizar el comportamiento de los modelos sobre eventos pequeños que ocurren durante la época seca. En la Figura 8-10 se muestran las estimaciones de los hidrogramas sintéticos realizadas por los modelos y el registro horario de la estación fluviográfica La Marimba.



Figura 8-10. Evento del día 28-04-2016 visto con una hora de anticipación al inicio de la crecida

Para la estimación del hidrograma con 1 hora de anticipación, el modelo *jusrma* (RNN) es el que obtuvo un mejor ajuste para las primeras 8 horas de la creciente, posterior a esto se observa una caída poco característica del fenómeno precipitación-escorrentía, la cual puede originarse por la independencia de los modelos que construyen el hidrograma, en conjunto con que estos modelos no están restringidos por leyes de conservación de la masa u otras condicionantes físicas.

En futuras investigaciones se podrán evaluar modelos con multiples variables de salida (tiempos de desfase), por ejemplo, que una sola red neuronal estime las próximas 12 horas del nivel en el cauce. Debido a que es un único proceso de entrenamiento, la optimización evaluará los pesos para las distintas variables de salida de manera simultánea e implícitamente buscará mejorar la forma del hidrograma de salida.

Los modelos *jucosrma* (RNA) y *juma* (RNA) también presentaron buenos ajustes con 1 hora de anticipación, en este escenario únicamente el modelo *ecocoma* (RNN) no logró identificar adecuadamente la llegada de la creciente.

Cabe destacar que el modelo *ecocoma* (RNN) no observa información de la estación pluviográfica Las Juntas. Para este caso específico esta fue la estación donde se registró la mayor lámina de precipitación y cerca de la totalidad del evento, este aspecto sugiere
que los modelos pueden tener dificultades para pronosticar incrementos del nivel producto de eventos de precipitación localizados en zonas de la cuenca en las que el modelo no dispone de información.

Las estimaciones de los hidrogramas realizadas con tiempos de anticipación de 2 y 3 horas se muestran en la Figura 8-11 y la Figura 8-12 respectivamente.



Figura 8-11. Evento del día 28-04-2016 visto con dos horas de anticipación al inicio de la crecida



Figura 8-12. Evento del día 28-04-2016 visto con tres horas de anticipación al inicio de la crecida

De manera similar al escenario con tiempo de desfase de 1 hora, con 2 horas de anticipación, tres de los cuatro modelos lograron detectar que se generará una creciente y aproximaron en buena medida su magnitud. Posterior al pico se presentan algunas oscilaciones inadecuadas y que pueden ser posprocesadas en el caso de una aplicación con numerosas horas de anticipación.

Con 3 horas de anticipación los modelos RNA mostraron un mejor desempeño. Los resultados para otros tiempos de desfase se encuentran en el Anexo 11.7

8.1.4 Evento el día 27 de mayo de 2016

Este evento de precipitación ocurre a la salida de la época seca del año 2016, típicamente durante el periodo de transición hacia la época lluviosa.

La distribución temporal de la lluvia se agrupa en dos intervalos de aproximadamente 3 horas cada uno, siendo el primero el que registra la mayor parte de la precipitación del día 27 de mayo del 2016 como se muestra en la Figura 8-13. Las mayores láminas fueron captadas en las estaciones Campos de Oro y Las Juntas, tal como se detalla en el Cuadro 8-5.

Análogamente al análisis realizado para los otros eventos, en la Figura 8-14 se muestran los hidrogramas sintéticos estimados por los modelos con 1 hora de antipación y el nivel registrado en la estación fluviográfica La Marimba.



Figura 8-13. Precipitación horaria del día 27-05-2015

Cuadro 8-5. Láminas de precipitación para el día 27-05-2016

Estación	Precipitación (mm)
San Rafael	5,0
Campos de oro	19,6
Las Juntas	16,4



Figura 8-14. Evento del día 27-05-2016 visto con una hora de anticipación al inicio de la crecida

Con 1 hora de anticipación, el modelo *jucosrma* (RNA) fue el que mejor estimó tanto la magnitud como la distribución temporal del hidrograma, seguido por el modelo *juma* (RNA) que sobreestimó ligeramente las magnitudes.

En este caso, los modelos RNN no detectaron con tanta anticipación la llegada de la creciente; no obstante, en el Anexo 11.8 se puede observar que para el siguiente paso temporal los modelos RNN lograron un mejor ajuste del hidrograma, haciéndolo aún antes de la llegada del pico del hidrograma a la estación La Marimba.

Para tiempos de desfase mayores a 1 hora, ninguno de los modelos logró identificar anticipadamente la llegada de esta creciente; el periodo previo con nula precipitación no brinda suficiente información a los modelos para determinar la presencia del evento.

En la Figura 8-15 y Figura 8-16 se muestran los hidrogramas sintéticos generados con tiempos de anticipación de 2 y 3 horas respectivamente. El Anexo 11.8 detalla los hidrogramas para otros tiempos de desfase.



Figura 8-15. Evento del día 27-05-2016 visto con dos horas de anticipación al inicio de la crecida



Figura 8-16. Evento del día 27-05-2016 visto con tres horas de anticipación al inicio de la crecida

8.2 Escala diaria

Con base en los resultados obtenidos y expuestos en el capítulo 7, donde se evaluaron modelos en escala diaria basados en algoritmos RNA y RNN. En la presente sección se desarrolla una comparación de los resultados respecto a los datos registrados en la estación fluviográfica La Marimba.

Los registros de nivel inicialmente se encuentran en escalas sub-horarias, por lo que los datos son agregados y promediados a nivel diario, contrario al análisis horario en el que los valores son interpolados.

Los modelos evaluados en el análisis diario son los que se muestran en el Cuadro 8-6.

Modelo	Descripción
ju+co+sr+ma (RNA)	Modelo que utiliza información de 1 estación fluviográfica (La Marimba) y 3 pluviográficas (Las Juntas, Campos de Oro y San Rafael). El número total de observaciones disponibles es de 532.
ju+co+sr+ma (RNN)	Modelo que utiliza información de 1 estación fluviográfica (La Marimba) y 3 pluviográficas (Las Juntas, Campos de Oro y San Rafael). El número total de observaciones disponibles es de 532.

Cuadro 8-6. Modelos seleccionados para generar hidrogramas sintéticos en escala diaria

Para cada uno de los modelos se utiliza una red neuronal con tiempos de desfase desde uno hasta cinco días, de modo que se puede observar la estimación del modelo para los próximos cinco días, con una anticipación de un día al inicio del evento en el cauce.

Se han seleccionado algunos intervalos del registro con su respectivo nivel medio diario registrado en la estación fluviográfica La Marimba, comparando los datos observados con las estimaciones de los modelos.

Ambos algoritmos fueron observan los últimos 30 días de información previos al incremento del nivel medio diario en el cauce, parámetro que fue evaluado previamente en la sección 7.

El primer intervalo analizado del registro abarca del 5 al 10 de noviembre del año 2015, siendo el día 4 de noviembre el día que se realiza el pronóstico para los próximos cinco días y se muestra el resultado en la Figura 8-17.



Figura 8-17. Comparación en escala diaria para periodo del 5-11-2015 al 10-11-2015

El primer intervalo muestra un periodo de ocho días del registro de la estación fluviográfica La Marimba durante el mes de noviembre del año 2015, en conjunto con un periodo de seis días (día de origen más cinco días de pronósticos) de los modelos *jucosrma* (RNA) y *jucosrma* (RNN).

Para este intervalo de análisis se observa que los modelos lograron aproximar en buena medida los datos del registro; no obstante, la variación del nivel medio diario registrada en el periodo es de aproximadamente 15 cm, por lo que no representa un gran cambio del nivel medio diario en el cauce.

Ambos modelos parecen identificar la tendencia del cambio del nivel a lo largo del periodo de análisis; sin embargo, la magnitud estimada se aleja perceptiblemente del valor registrado.



Figura 8-18. Comparación en escala diaria para periodo del 11-11-2015 al 16-11-2015

La Figura 8-18 muestra los resultados para el segundo intervalo de análisis que abarca del 11 al 16 de noviembre del año 2015. El modelo RNA mostró un mejor ajuste que el RNN para los primeros cuatro días del pronóstico; para el último día ambos modelos subestimaron el incremento que ocurriría en el cauce.

Los modelos no tienen la información sobre la precipitación que ocurrirá en los próximos cinco días, esto limita en gran medida que pueda pronosticar un incremento ocasionado por lluvias puntuales al final de ese periodo. A su vez, este aspecto está implícitamente relacionado con características físicas de la cuenca como el área de drenaje y el tiempo de concentración.

El tercer intervalo analizado corresponde a lo que típicamente es periodo de transición entre la época seca a la época lluviosa y se muestra en la Figura 8-19, abarcando del día 30 de abril al día 5 de mayo de 2016, en este periodo ambos modelos no tuvieron la capacidad de identificar el incremento del nivel en el cauce al quinto día y mostraron un ajuste similar entre sí, siendo aceptable el pronóstico para los primeros cuatro días de análisis.



Figura 8-19. Comparación en escala diaria para periodo del 30-04-2016 al 05-05-2016.



Figura 8-20. Comparación en escala diaria para periodo del 27-05-2016 al 01-06-2016

El cuarto intervalo de análisis se muestra en la Figura 8-20, este comprende el periodo del 27 de mayo de 2016 al 1 de junio del mismo año, días que típicamente se ubican a la entrada de la época lluviosa. El cauce percibió un incremento del nivel medio diario desde los 0,42 m hasta los 0,62 m en un periodo de cuatro días. En este caso, el modelo *jucosrma* (RNN) pudo determinar que ocurriría el incremento del nivel pero acortó el tiempo al pico; por otra parte, el modelo RNA no estimó ningún cambio significativo del nivel medio diario durante ese mismo periodo.

De acuerdo a los resultados del análisis en la escala horaria, el incremento del nivel en el cauce ocurre en el orden de horas una vez ocurrido el evento de precipitación, de modo que un modelo que estime el nivel con días de anticipación no tiene la información suficiente para pronosticar con precisión los cambios acentuados que ocurran dentro de varios días, aspecto que dificulta la labor de estimar el nivel medio diario con gran anticipación.

Los modelos basados en redes neuronales recurrentes del tipo LSTM tienen una arquitectura capaz de encontrar patrones temporales en la precipitación y nivel en el cauce que posteriormente son considerados en la estimación del nivel en el cauce; no obstante, para que los modelos puedan aprender estos patrones de la mejor manera deben de disponer de numerosos datos para el entrenamiento y este aspecto resulta limitante en la presente investigación.

Cabe mencionar que al realizarse el análisis en una escala diaria la cantidad de datos disponibles se reduce considerablemente, siendo así que para la combinación de estaciones del modelo *jucosrma* se dispone de únicamente 532 observaciones (días), aspecto que puede resultar limitante para el entrenamiento, especialmente para los algoritmos basados en redes neuronales recurrentes (RNN) que son típicamente más complejos de entrenar que las redes neuronales artificiales (RNA).

9 Conclusiones y recomendaciones

9.1 Conclusiones

- El análisis de los modelos en una escala horaria, permite determinar que existe un gran potencial en la implementación de algoritmos de inteligencia artificial para la estimación de variables hidrológicas. En este caso específico se demostró la efectividad de modelos que utilizan de insumo información pluviográfica y/o fluviográfica para determinar anticipadamente el nivel del agua en el cauce del río Abangares a la altura de la estación fluviográfica La Marimba.
- En las secciones 5.1 y 6.1 se expone el efecto del tiempo de desfase o anticipación sobre la calidad de los ajustes en una escala horaria, determinándose que entre mayor es el tiempo de desfase, mayor es el error de la estimación, tanto para modelos basados en redes neuronales artificiales (RNA) como en redes neuronales recurrentes (RNN).
- En las secciones 5.2 y 6.2 se determinó el efecto que tiene la extensión del registro del cual dispone un modelo para estimar el nivel en el cauce en una escala horaria, identificando que el error mínimo se obtiene para un rango determinado de horas; un rango por menor o mayor del indicado tiene como resultado un incremento del error RMSE (ver Cuadro 5-3 y Cuadro 6-1).
- Se identificó que los modelos basados en algoritmos RNN requieren de un registro mayor para un entrenamiento óptimo. Al mismo tiempo, lograron errores menores utilizando un mayor número de variables de insumo y, especialmente, para estimaciones con tiempos de desfase mayores,
- Los modelos basados en algoritmos RNA mostraron ajustes muy satisfactorios para estimar el nivel horario en el cauce, con errores RMSE desde 0,0226 m hasta 0,0504 m para tiempos de desfase o anticipación desde 1 hasta 12 horas (ver Cuadro 5-5).
- Los modelos basados en algoritmos RNN también mostraron resultados muy satisfactorios estimando el nivel horario en el cauce, con errores RMSE desde 0,0274 m hasta 0,0488 m para tiempos de desfase o anticipación desde 1 hasta 12 horas (ver Cuadro 6-2).
- En los gráficos cuantil-cuantil que comparan las series sintéticas con las series observadas, se corrobora que para los niveles de mayor magnitud fue donde los modelos subestimaron en mayor medida; este aspecto puede estar influenciado tanto por el hecho que son eventos menos frecuentes en los datos, como también

porque las estimaciones se realizan a futuro y, por lo tanto, existe una fracción del evento de precipitación que permanece desconocida para el modelo IA.

- Para las estimaciones del nivel del agua en el cauce realizadas con 1 hora de anticipación, los modelos basados en algoritmos RNA mostraron por un margen pequeño mejores resultados; no obstante, los errores de ambos tipos de algoritmos son pequeños y mostraron resultados satisfactorios.
- Para tiempos de desfase mayores a 1 hora, los modelos basados en RNN presentaron mejores resultados, siendo más apropiados para el pronóstico de la variable con un mayor tiempo de anticipación, corroborando el supuesto de que una red neuronal del tipo LSTM con "memoria" opera de mejor manera sobre una serie de tiempo como es el caso del fenómeno precipitación-escorrentía.
- La Figura 5-9 y la Figura 6-6 muestran los errores RMSE obtenidos respecto al número total de observaciones disponibles (70% para el entrenamiento y 30% para la validación) para modelos RNA y RNN, respectivamente. Se identifica una tendencia general que, entre mayor sea el número de observaciones, menor es el error. No obstante, hubo modelos especialmente exitosos que lograron entre los mejores resultados con un menor número de observaciones, así como también lo contrario con modelos cuyos errores fueron mayores y disponían de un mayor número de datos.
- No se identificó ningún beneficio evidente de incorporar un mayor número de estaciones fluviográficas como variables de entrada a los modelos; además, debe considerarse que, para este caso específico, el hacer coincidir el registro de múltiples estaciones fluviográficas también disminuye sensiblemente el número de observaciones disponibles, lo que a su vez limita el proceso de entrenamiento de los algoritmos.
- Exceptuando el caso de la estación fluviográfica La Marimba, las estaciones pluviográficas tuvieron una mayor presencia en los modelos RNA horarios con mejores resultados, siendo las estaciones Santa Lucía y Ecomuseo las estaciones menos presentes dentro de los modelos con mejores ajustes.
- Para el caso de los modelos RNN horarios, la estación fluviográfica Santa Lucía fue la menos utilizada, esto puede estar relacionado con que el registro de esta estación es poco coincidente con el de las demás estaciones, teniendo como resultado que se disponga de una menor cantidad de datos para realizar el entrenamiento cuando se utiliza la estación Santa Lucía.

- En la sección 8.1 se detalla la comparación de las estimaciones horarias de los modelos y el nivel registrado en la estación fluviográfica La Marimba. En esta puede notarse que cuando un modelo no observa una estación que registró una lámina de precipitación significativa durante el evento, el modelo puede subestimar la magnitud del pico del evento. Este aspecto sugiere que la distribución espacial de las estaciones pluviográficas tiene una importancia implícita en la calidad de los modelos.
- La estimación del nivel en una escala media diaria se determinó aceptable para tiempos de desfase de pocos días, logrando una estimación aproximada de los valores registrados pero que no logra detectar un cambio del nivel que ocurre de un día para otro dentro del horizonte de los próximos cinco días, aspecto esperable en una cuenca cuyo tiempo de concentración se ubica en el rango de horas. Esto, a su vez, sugiere que los modelos no disponen de la información suficiente para pronosticar el nivel con tanto tiempo de anticipación de una manera efectiva.
- Los errores RMSE para pronósticar el nivel medio diario con modelos basados en algoritmos RNA con tiempos de desfase desde uno hasta cinco días se estimaron desde los 0,032 m hasta los 0,057 m (ver Cuadro 7-2).
- Los errores RMSE para pronósticar el nivel medio diario con modelos basados en algoritmos RNN con tiempos de desfase desde uno hasta cinco días se estimaron desde los 0,045 m hasta los 0,052 m (ver Cuadro 7-4).
- No se identificó un beneficio evidente de incrementar indiscriminadamente el rango de días a los cuales un modelo tiene acceso para realizar la estimación del nivel medio diario, siendo así que según el tipo de algoritmo y tiempo de desfase se encontró un rango con menores errores.

9.2 Recomendaciones

- El análisis en escala horaria mostró una satisfactoria reconstrucción de los hidrogramas para algunos de los mejores modelos; sin embargo, se considera que el tiempo al pico podría ser determinado con mayor precisión por modelos desarrollados en escalas sub-horarias, por lo que se recomienda en futuras investigaciones la posibilidad de evaluar modelos en escalas sub-horarias.
- La optimización de los modelos ha sido realizada minimizando el error de la función objetivo Error Cuadrático Medio (MSE) debido a que da mayor peso a las colas de la distribución (Géron, 2017). Se recomienda evaluar funciones de costo que puedan incluso dar mayor peso a errores grandes, con el objetivo de acentuar el entrenamiento sobre cambios pronunciados en los datos, como es el caso de una creciente.
- Debido a que por naturaleza los eventos extremos ocurren con menos frecuencia, se recomienda evaluar técnicas de muestreo estratificado que permitan un entrenamiento de los algoritmos enfocado en crecientes o eventos extremos, así como también podrán diferenciase tipos de eventos de precipitación y su respectivo efecto en la escorrentía superficial.
- Todos los modelos evaluados están desarrollados para determinar una única variable de salida, esto hace que se requiera de un modelo para determinar cada instancia de tiempo del hidrograma. Alternativamente, se recomienda evaluar modelos con redes neuronales que puedan determinar múltiples variables de salida simultáneamente; esto, además, permitiría que el entrenamiento se efectuara no solamente sobre un valor puntual pero sobre una secuencia temporal de datos, en mayor semejanza con lo que representa un hidrograma.
- Algunos modelos basados en RNN mostraron un gran desempeño para estimar crecientes a pesar de que no observaban la estación pluviográfica que registró mayoritariamente la precipitación del evento. Este aspecto sugiere la posibilidad de que el modelo puede identificar patrones de precipitación con base en la información de otras estaciones; esto se considera como una posible interrogante que podrá desarrollarse en investigaciones futuras.
- La implementación de "ensambles" de algoritmos podría generar mejores ajustes en la estimación del nivel del agua en el cauce, esto porque se evalúan multiples modelos y se utiliza el que mejor aplique para cada intervalo de tiempo específico;

en caso de cuencas ampliamente instrumentadas esta es una opción de gran potencial y podrá evaluarse su efectividad en trabajos posteriores.

- Se recomienda evaluar modelos en escala local que puedan ser apoyados por información generada a una mayor escala espacial, esto con el objetivo de brindar al algoritmo con información de más fácil acceso y que está estrechamente relacionada con el fenómeno de precipitación-escorrentía. Además, puede contemplarse el uso de Redes Neuronales Convolucionales (CNN) en complemento con modelos de mayor escala espacial.
- Trabajos recientes han desarrollados métodos basados en redes RNN-LSTM que, además, contemplan el principio de la conservación de la masa; no obstante, su aplicación está pendiente de evaluar en entornos como las cuencas de Centroamerica.
- Existen antecedentes recientes que demuestran un gran potencial en desarrollar modelos de regionalización de escorrentía basados en algoritmos IA, por lo que se recomienda evaluar la implementación de este tipo de modelos en el entorno centroamericano.
- El desarrollo de aplicaciones hidrológicas Al como la del presente trabajo, pueden realizarse en computadores convencionales; sin embargo, las complejidades de los modelos llevaron rápidamente al límite las capacidades del equipo y, por lo tanto, en modelos más complejos se recomienda evaluar el uso de supercomputadoras disponibles a nivel nacional, además de la posibilidad de utilizar procesamiento gráfico en caso de resultar conveniente para el entrenamiento de los modelos.
- En futuras investigaciones podrán evaluarse modelos hidrológicos conceptualmente diversos con distintos tipos de variables de entrada, para lo cual se recomienda el uso de técnicas como el *Racing* para analizar hiperparámetros de una manera optimizada.
- Se recomienda evaluar el desempeño de este tipo de modelos basados en inteligencia artificial contra una línea base de comparación que son los modelos convencionales.

- Castellano, M. (2009). *Modelización estadística con Redes Neuronales. Aplicaciones a la hidrología, aerobiología y modelización de procesos.* La Coruña: Universidade da Coruña.
- Chow, V. T. (1994). Hidrología Aplicada. Bogotá: McGraw Hill.
- Contreras, F. (2018). Introducción a machine learning. https://sunqu.net/whitepapers/machine-learning/.
- Debo & Reese. (2003). *Municipal Stormwater Management.* United States of America: Lewis Publishers.
- Géron, A. (2017). *Hands-on Machine Learning with Scikit-Learn and TensorFlow.* USA: O'Reilly.
- Global Water Partnership. (2011). Situación de los Recursos Hídricos en Centroamérica -Hacia una Gestión Integrada. Honduras: Tegucigalpa, M.D.C., Honduras.
- Google. (2022). CNES/Airbus.
- Gutierrez, D. D. (2017). Guide to Deep Learning and Artificial Inteligence. InsideBigData.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. United States of America: Pearson.
- Hoedt, P., Kratzert, F., Klotz, D., Halmich, C., Holzleitner, M., Nearing, G., Hochreiter, S., & Klambauer, G. (2021). *MC-LSTM: Mass-Conserving LSTM.* New York: Cornell University.
- Instituto Meteorológico Nacional. (2005). *Atlas climatológico*. San José, Costa Rica: Instituto Meteorológico Nacional.
- Isiyaka, H., Mustapha, A., Juahir, H., & Phil-Eze, P. (2018). *Water quality modelling using artificial neural network and multivariate statistical techniques.* Switzerland: Springer.
- Kratzert, F., Klotz, D., Shalev, G., Klambauer, G., Hochreiter, S., & Nearing, G. (2019).
 Towards learning universal, regional, and local hydrological behavoirs via machine learning applied to large-sample datasets. Linz, Austria: Copernicus Publications.
- Mays, L. (2004). Stormwater Collection Systems Design Handbook. Arizona: McGraw-Hill.

- Misra, D., Oommen, T., Agarwal, A., Mishra, S., & Thompson, A. (2009). Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering*, 527-535.
- Mitchell, T. M. (1997). Machine Learning. McGraw-Hill Science/Engineering/Math.
- Sahoo, S., Russo, T. A., Elliott, J., & Foster, I. (2017). Machine learning algorithms for modeling groundwater level changes in agricultural regions of the U.S. https://agupubs.onlinelibrary.wiley.com/doi/epdf/10.1002/2016WR019933.
- Segaran, T. (2007). *Programming Collective Intelligence*. United States of America: O'Really Media, Inc.
- Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN). *Physica D: Nonlinear Phenomena*, Volume 404.
- Staudemeyer, Ralf & Morris, Eric. (2019). Understanding LSTM a tutorial into Long Short-Term Memory Recurrent Neural Networks. Germany: University of Applied Sciences Schmalkalden.
- Vahid Nourani, A. H. (2014). Applications of hybrid wavelet–Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*, 514.
- Veintimilla J. (2015). Predicción de caudales basados en redes neuronales artificiales (RNA) para periodos de tiempo sub diarios. Cuenca, Ecuador: Revista politécnica.

11 Anexos

11.1 Errores RMSE (m) sobre datos de validación para diversas funciones de activación, tiempos de desfase y nodos para el modelo *jucosrma* (RNA)

Cuadro 11-1. RMSE (m) modelos RNA horarios con tiempo de desfase de 1 hora

DT 1 hora					
Neuronas	Relu	ELU	Tanh		
1	0,027	0,023	0,029		
3	0,027	0,024	0,028		
10	0,027	0,026	0,028		
50	0,026	0,025	0,027		
250	0,029	0,026	0,031		
1000	0,025	0,031	0,030		

Fuente: Baldi, 2022.

Se muestran a continuación los resultados de manera gráfica.



Figura 11-1. RMSE (m) modelos RNA horarios con tiempo de desfase de 1 hora

DT 3 horas					
Neuronas	Relu	ELU	Tanh		
1	0,037	0,036	0,040		
3	0,037	0,039	0,037		
10	0,039	0,037	0,039		
50	0,037	0,037	0,041		
250	0,039	0,039	0,049		
1000	0,038	0,041	0,045		

Cuadro 11-2. RMSE (m) modelos RNA horarios con tiempo de desfase de 3 horas



Figura 11-2. RMSE (m) modelos RNA horarios con tiempo de desfase de 3 horas

DT 6 horas					
Neuronas	Relu	ELU	Tanh		
1	0,043	0,043	0,044		
3	0,045	0,044	0,044		
10	0,045	0,044	0,043		
50	0,046	0,044	0,043		
250	0,045	0,044	0,044		
1000	0,050	0,045	0,045		

Cuadro 11-3. RMSE (m) modelos RNA horarios con tiempo de desfase de 6 horas



Figura 11-3. RMSE (m) modelos RNA horarios con tiempo de desfase de 6 horas

DT 12 horas					
Neuronas	Relu	ELU	Tanh		
1	0,052	0,053	0,055		
3	0,053	0,052	0,054		
10	0,052	0,053	0,056		
50	0,055	0,055	0,056		
250	0,057	0,055	0,056		
1000	0,058	0,055	0,059		

Cuadro 11-4. RMSE (m) modelos RNA horarios con tiempo de desfase de 12 horas



Figura 11-4. RMSE (m) modelos RNA horarios con tiempo de desfase de 12 horas

11.2 Errores RMSE (m) sobre conjunto de datos de validación para modelos RNA horarios

ju+co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,023	0,041	0,051	0,061
3	0,025	0,041	0,051	0,061
10	0,024	0,04	0,051	0,061
25	0,024	0,04	0,052	0,061

ju+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,027	0,038	0,052	0,054
3	0,029	0,039	0,044	0,052
10	0,027	0,039	0,055	0,052
25	0,03	0,045	0,045	0,052

ju+sr+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,029	0,039	0,052	0,056
3	0,028	0,039	0,053	0,055
10	0,028	0,039	0,053	0,064
25	0,029	0,043	0,053	0,062

ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,029	0,044	0,049	0,051
3	0,03	0,045	0,049	0,051
10	0,032	0,044	0,062	0,053
25	0,03	0,045	0,05	0,055

Ju+co+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,03	0,045	0,056	0,061
3	0,031	0,044	0,056	0,06
10	0,03	0,044	0,057	0,061
25	0,031	0,044	0,056	0,059

Ju+sl+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,038	0,049	0,053	0,061
3	0,032	0,05	0,052	0,06
10	0,029	0,046	0,052	0,061
25	0,029	0,047	0,051	0,061

Ju+co+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,027	0,044	0,051	0,059
3	0,026	0,048	0,053	0,069
10	0,026	0,046	0,053	0,057
25	0,027	0,058	0,054	0,057

Ju+sr+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,038	0,053	0,053	0,06
3	0,046	0,062	0,052	0,055
10	0,039	0,045	0,053	0,056
25	0,041	0,048	0,052	0,056

Co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,029	0,049	0,059	0,056
3	0,028	0,036	0,054	0,054
10	0,028	0,038	0,054	0,054
25	0,033	0,037	0,055	0,055

Sr+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,024	0,042	0,047	0,053
3	0,025	0,042	0,047	0,052
10	0,026	0,042	0,046	0,052
25	0,025	0,043	0,047	0,053

SI+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,041	0,046	0,055	0,06
3	0,033	0,048	0,05	0,06
10	0,033	0,047	0,049	0,061
25	0,036	0,049	0,049	0,06

Eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,033	0,048	0,057	0,071
3	0,033	0,055	0,054	0,072
10	0,034	0,051	0,056	0,07
25	0,033	0,049	0,054	0,071

SI+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,025	0,054	0,047	0,056
3	0,026	0,054	0,047	0,056
10	0,027	0,053	0,048	0,058
25	0,028	0,045	0,05	0,061

Sr+co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,027	0,044	0,055	0,057
3	0,027	0,044	0,052	0,057
10	0,03	0,045	0,052	0,058
25	0,026	0,044	0,052	0,057

SI+co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,034	0,046	0,048	0,054
3	0,035	0,041	0,043	0,053
10	0,037	0,042	0,044	0,054
25	0,034	0,044	0,047	0,053

Ju+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,023	0,046	0,059	0,058
3	0,033	0,048	0,06	0,056
10	0,024	0,051	0,059	0,056
25	0,024	0,046	0,059	0,058

Eco+co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,031	0,045	0,061	0,065
3	0,033	0,048	0,06	0,064
10	0,029	0,05	0,06	0,064
25	0,029	0,046	0,06	0,066

Eco+sr+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,029	0,055	0,056	0,067
3	0,038	0,052	0,054	0,08
10	0,029	0,053	0,054	0,067
25	0,029	0,052	0,054	0,066

Sr+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,035	0,052	0,05	0,051
3	0,04	0,042	0,051	0,056
10	0,036	0,051	0,049	0,052
25	0,038	0,042	0,052	0,05

Co+sr+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,036	0,042	0,047	0,057
3	0,036	0,055	0,046	0,051
10	0,037	0,042	0,046	0,059
25	0,039	0,042	0,055	0,052

Co+sr+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,033	0,042	0,051	0,059
3	0,036	0,042	0,05	0,061
10	0,034	0,042	0,05	0,06
25	0,036	0,042	0,052	0,06

Co+sl+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,03	0,051	0,051	0,053
3	0,033	0,048	0,05	0,053
10	0,033	0,051	0,057	0,057
25	0,031	0,056	0,06	0,053

Sr+sl+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,042	0,051	0,059	0,057
3	0,039	0,054	0,058	0,057
10	0,038	0,044	0,06	0,067
25	0,044	0,045	0,059	0,06

Ju+co+sr+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,034	0,046	0,055	0,058
3	0,032	0,046	0,052	0,059
10	0,034	0,047	0,053	0,064
25	0,036	0,046	0,052	0,059

Ju+co+sr+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,031	0,041	0,048	0,058
3	0,033	0,048	0,047	0,059
10	0,032	0,039	0,049	0,06
25	0,035	0,041	0,051	0,067

Ju+co+sr+sl+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,043	0,046	0,061	0,066
3	0,03	0,048	0,059	0,079
10	0,031	0,051	0,069	0,07
25	0,029	0,047	0,053	0,064

Ju+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,033	0,048	0,051	0,058
3	0,036	0,04	0,05	0,056
10	0,032	0,035	0,05	0,058
25	0,048	0,041	0,056	0,059

11.3 Errores RMSE (m) sobre conjunto de datos de validación para diversas funciones de activación, tiempos de desfase y nodos para el modelo *jucosrma* (RNN)

Neuronas	Relu	ELU	Tanh
1	0,179	0,088	0,055
3	0,146	0,041	0,040
10	0,038	0,037	0,035
25	0,034	0,036	0,036
100	0,036	0,036	0,037
1000	0,160	0,042	0,094

Cuadro 11-5. RMSE (m) modelos RNN horarios con tiempo de desfase de 1 hora

Se muestran a continuación los resultados de manera gráfica.



Figura 11-5. RMSE (m) modelos RNN horarios con tiempo de desfase de 1 hora

11.4 Errores RMSE (m) sobre conjunto de datos de validación para modelos RNN horarios

Ju+co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,126	0,049	0,159	0,195
3	0,049	0,047	0,053	0,058
10	0,043	0,054	0,052	0,055
25	0,033	0,041	0,051	0,057

Ju+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,078	0,089	0,173	0,078
3	0,136	0,051	0,055	0,065
10	0,039	0,047	0,054	0,057
25	0,036	0,047	0,056	0,057

Ju+sr+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,057	0,259	0,062	0,232
3	0,046	0,042	0,045	0,056
10	0,027	0,032	0,043	0,05
25	0,029	0,034	0,042	0,051

Ма

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,165	0,243	0,064	0,205
3	0,085	0,074	0,069	0,066
10	0,055	0,061	0,063	0,063
25	0,054	0,06	0,062	0,063

Ju+co+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,082	0,051	0,054	0,056
3	0,034	0,04	0,051	0,076
10	0,031	0,046	0,049	0,053
25	0,028	0,039	0,05	0,052

Ju+sl+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,1	0,135	0,12	0,131
3	0,058	0,071	0,13	0,063
10	0,072	0,106	0,123	0,101
25	0,065	0,071	0,063	0,103

Ju+co+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,166	0,109	0,111	0,198
3	0,112	0,111	0,096	0,118
10	0,077	0,08	0,082	0,122
25	0,148	0,079	0,09	0,123

Ju+sr+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,213	0,107	0,142	0,141
3	0,09	0,204	0,139	0,379
10	0,151	0,089	0,1	0,212
25	0,083	0,115	0,125	0,187

Co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,098	0,149	0,159	0,189
3	0,041	0,045	0,053	0,061
10	0,036	0,048	0,049	0,051
25	0,037	0,042	0,049	0,052

Sr+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,276	0,214	0,279	0,23
3	0,041	0,063	0,053	0,054
10	0,04	0,045	0,051	0,071
25	0,038	0,045	0,051	0,054

SI+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,135	0,11	0,108	0,134
3	0,136	0,097	0,203	0,176
10	0,084	0,074	0,126	0,136
25	0,066	0,067	0,09	0,106

Eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,045	0,082	0,091	0,059
3	0,038	0,057	0,056	0,054
10	0,038	0,048	0,056	0,054
25	0,041	0,048	0,051	0,052

SI+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,132	0,1	0,128	0,252
3	0,076	0,101	0,098	0,12
10	0,084	0,127	0,101	0,117
25	0,083	0,089	0,107	0,142

Sr+co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,207	0,144	0,181	0,061
3	0,057	0,048	0,057	0,055
10	0,044	0,046	0,054	0,055
25	0,042	0,042	0,051	0,055

SI+co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,111	0,09	0,248	0,144
3	0,202	0,064	0,072	0,141
10	0,056	0,164	0,103	0,111
25	0,105	0,088	0,11	0,102

Ju+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,093	0,093	0,093	0,069
3	0,041	0,047	0,055	0,069
10	0,035	0,052	0,061	0,057
25	0,046	0,046	0,053	0,057

Ju+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,132	0,14	0,122	0,125
3	0,132	0,101	0,106	0,19
10	0,119	0,132	0,122	0,147
25	0,088	0,142	0,127	0,127

Eco+co+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,087	0,079	0,068	0,054
3	0,047	0,044	0,053	0,054
10	0,035	0,042	0,051	0,052
25	0,03	0,039	0,047	0,051

Eco+sr+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,09	0,083	0,055	0,073
3	0,038	0,045	0,053	0,052
10	0,038	0,054	0,048	0,052
25	0,035	0,045	0,048	0,053

Sr+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,175	0,115	0,126	0,169
3	0,043	0,171	0,194	0,114
10	0,104	0,156	0,099	0,094
25	0,103	0,085	0,11	0,125

Co+sr+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,059	0,099	0,126	0,211
3	0,143	0,284	0,067	0,088
10	0,072	0,056	0,194	0,098
25	0,048	0,096	0,158	0,066

Co+sr+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,072	0,09	0,069	0,09
3	0,048	0,048	0,087	0,089
10	0,039	0,041	0,083	0,058
25	0,038	0,046	0,047	0,052

Co+sl+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,052	0,098	0,109	0,123
3	0,068	0,075	0,094	0,073
10	0,049	0,07	0,109	0,084
25	0,078	0,099	0,076	0,088

Sr+sl+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,082	0,068	0,051	0,212
3	0,045	0,063	0,065	0,064
10	0,089	0,06	0,099	0,052
25	0,04	0,044	0,045	0,049

Ju+co+sr+sl+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,184	0,401	0,129	0,132
3	0,191	0,063	0,126	0,144
10	0,123	0,251	0,108	0,187
25	0,057	0,068	0,126	0,11

Ju+co+sr+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,077	0,047	0,087	0,083
3	0,037	0,062	0,059	0,06
10	0,032	0,041	0,059	0,054
25	0,031	0,045	0,05	0,053

Ju+co+sr+sl+eco+ma

Neuronas	DT 1 hora	DT 3 horas	DT 6 horas	DT 12 horas
1	0,087	0,169	0,19	0,122
3	0,139	0,084	0,102	0,111
10	0,072	0,112	0,088	0,098
25	0,064	0,071	0,082	0,099


11.5 Hidrogramas sintéticos para evento del día 05 de noviembre del 2015

Figura 11-6. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de -3 horas



Figura 11-7. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de -2 horas



Figura 11-8. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de -1 hora



Figura 11-9. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 0 horas



Figura 11-10. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 1 hora



Figura 11-11. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 2 horas



Figura 11-12. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 3 horas



Figura 11-13. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 4 horas



Figura 11-14. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 5 horas



Figura 11-15. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 6 horas



Figura 11-16. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 7 horas



Figura 11-17. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 8 horas



Figura 11-18. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 9 horas



Figura 11-19. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 10 horas



Figura 11-20. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 11 horas



Figura 11-21. Hidrogramas horarios para el día 05-11-2015 con tiempos de desfase de 12 horas



11.6 Hidrogramas sintéticos para evento del día 11 de noviembre del 2015

Figura 11-22. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de -3 horas



Figura 11-23. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de -2 horas



Figura 11-24. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de -1 hora



Figura 11-25. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 0 horas



Figura 11-26. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 1 hora



Figura 11-27. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 2 horas



Figura 11-28. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 3 horas



Figura 11-29. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 4 horas



Figura 11-30. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 5 horas



Figura 11-31. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 6 horas



Figura 11-32. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 7 horas



Figura 11-33. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 8 horas



Figura 11-34. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 9 horas



Figura 11-35. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 10 horas



Figura 11-36. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 11 horas



Figura 11-37. Hidrogramas horarios para el día 11-11-2015 con tiempos de desfase de 12 horas



11.7 Hidrogramas sintéticos para evento del día 28 de abril del 2016

Figura 11-38. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de -3 horas



Figura 11-39. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de -2 horas



Figura 11-40. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de -1 hora



Figura 11-41. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 0 horas



Figura 11-42. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 1 hora



Figura 11-43. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 2 horas



Figura 11-44. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 3 horas



Figura 11-45. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 4 horas



Figura 11-46. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 5 horas



Figura 11-47. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 6 horas



Figura 11-48. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 7 horas



Figura 11-49. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 8 horas



Figura 11-50. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 9 horas



Figura 11-51. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 10 horas



Figura 11-52. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 11 horas



Figura 11-53. Hidrogramas horarios para el día 28-04-2016 con tiempos de desfase de 12 horas



11.8 Hidrogramas sintéticos modelados para evento del día 27 de mayo del 2016

Figura 11-54. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de -3 horas



Figura 11-55. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de -2 horas



Figura 11-56. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de -1 hora



Figura 11-57. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 0 horas



Figura 11-58. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 1 hora



Figura 11-59. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 2 horas



Figura 11-60. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 3 horas



Figura 11-61. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 4 horas



Figura 11-62. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 5 horas



Figura 11-63. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 6 horas



Figura 11-64. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 7 horas



Figura 11-65. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 8 horas



Figura 11-66. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 9 horas



Figura 11-67. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 10 horas



Figura 11-68. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 11 horas



Figura 11-69. Hidrogramas horarios para el día 27-05-2016 con tiempos de desfase de 12 horas