



UNIVERSIDAD
DE PIURA

FACULTAD DE INGENIERÍA

**Pronóstico de la demanda internacional del banano
orgánico de Perú usando algoritmos de Machine Learning**

Tesis para optar el Grado de
Doctor en Ingeniería con mención en: Automatización, Control y
Optimización de Procesos

Estefani Marie Almeyda Almeyda

Asesor:
Dr. Ing. William Ipanaqué Alama

Piura, julio de 2022

NOMBRE DEL TRABAJO

**C. Tesis_Doctorado_Junio2022_Estefani
Almeyda_24-junio_8pm.pdf**

RECUENTO DE PALABRAS

37414 Words

RECUENTO DE CARACTERES

208109 Characters

RECUENTO DE PÁGINAS

154 Pages

TAMAÑO DEL ARCHIVO

4.4MB

FECHA DE ENTREGA

Jul 7, 2022 10:30 AM GMT-5

FECHA DEL INFORME

Jul 7, 2022 10:45 AM GMT-5**● 4% de similitud general**

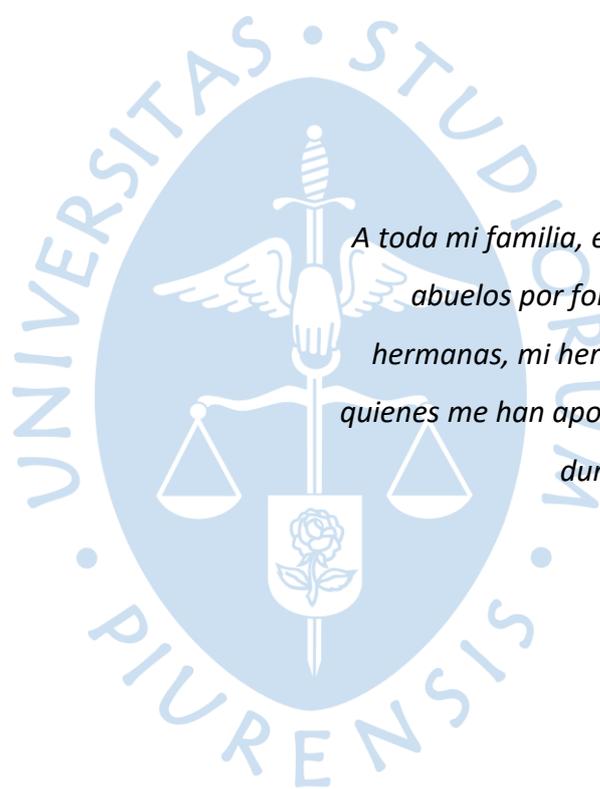
El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos

- 3% Base de datos de Internet
- Base de datos de Crossref
- 2% Base de datos de trabajos entregados
- 2% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● Excluir del Reporte de Similitud

- Material bibliográfico
- Coincidencia baja (menos de 10 palabras)
- Material citado





A toda mi familia, en especial a mis padres y abuelos por formarme en valores. A mis hermanas, mi hermano, amigos, y colegas, quienes me han apoyado incondicionalmente durante mi estadía en Piura.



Agradecimientos

E. Almeyda reconoce el apoyo financiero del Proyecto Concytec – Banco Mundial "Mejoramiento y Ampliación de los Servicios del Sistema Nacional de Ciencia Tecnología e Innovación Tecnológica" 8682-PE, a través de su unidad ejecutora ProCiencia [Contrato Nro. 06-2018-FONDECYT/BM], para esta investigación denominada "Pronóstico de la demanda internacional del banano orgánico de Perú usando algoritmos de Machine Learning", ejecutada como parte del programa de Doctorado en Ingeniería con mención en Automatización, Control, y Optimización de Procesos, desarrollado en el Laboratorio de Sistemas Automáticos de Control de la Universidad de Piura, Perú.

Adicionalmente, agradezco a la Dirección del Doctorado de Ingeniería y al personal (técnico y administrativo) del Laboratorio de Sistemas Automáticos de Control de la Universidad de Piura por el apoyo logístico y las facilidades para el uso de las instalaciones durante el desarrollo de este trabajo de investigación.

Finalmente, un agradecimiento sincero a mis colegas del doctorado, los expertos en Machine Learning, y los revisores anónimos (nacionales e internacionales) por su valioso *feedback*; aprecio sus comentarios constructivos, los cuales ayudaron significativamente a mejorar el estudio.



Resumen

El presente estudio tiene como objetivo entrenar y evaluar el desempeño de un modelo predictivo para pronosticar la demanda del banano orgánico de Perú usando algoritmos de aprendizaje supervisado del tipo Redes Neuronales, tales como: MLP¹, RNN², LSTM³ y GRU⁴. El pronóstico se realiza con datos del registro mensual de exportación de banano orgánico (kg) de Perú, recolectados desde el año 2001 al 2021. Como parte del proceso de entrenamiento de los algoritmos de aprendizaje automático antes mencionados, se realizaron varios experimentos testeando diferentes arquitecturas de la red neuronal y optimizando sus hiper-parámetros. Posteriormente, se seleccionó el modelo con mejor performance, evaluando la precisión de los valores pronosticados y los valores de la serie temporal original. Como resultado, el modelo entrenado con el algoritmo RNN obtuvo los menores valores de error de predicción (MSE: 0.00147, RMSE: 0.03838, MAE: 0.02885, y MAPE: 2.88516), lo cual demostró ser el modelo predictivo más preciso para realizar el pronóstico de la demanda de banano orgánico de Perú.

Palabras claves: Machine Learning, pronóstico, serie de tiempo, exportación, banano, redes neuronales recurrentes.

¹ Multilayer Perceptron

² Recurrent Neural Network

³ Long Short Term Memory

⁴ Gated Recurrent Unit



Tabla de contenido

Introducción	19
Capítulo 1 Formulación de la investigación.....	23
1.1 Planteamiento del problema	23
1.2 Justificación	26
1.3 Objetivos de investigación	29
1.4 Esquema del trabajo de investigación	29
1.5 Alcance y limitaciones.....	30
Capítulo 2 Fundamentos de series de tiempo	31
2.1 Definición	31
2.2 Clasificación.....	33
2.3 Componentes.....	33
2.4 Áreas de aplicación.....	35
2.5 Métodos y modelos.....	37
2.5.1 Métodos de pronóstico	37
2.5.2 Modelos de pronóstico	38
2.6 Enfoque de análisis.....	39
2.7 Resumen.....	40
Capítulo 3 Fundamentos de Machine Learning y sus aplicaciones en la agricultura	43
3.1 Definiciones.....	43
3.1.1 Inteligencia Artificial.....	43
3.1.2 Machine Learning.....	44

3.2	Proceso general del aprendizaje automático.....	45
3.3	Tipos de aprendizaje y algoritmos	47
3.4	Aplicaciones en la agricultura	48
3.4.1	Áreas de investigación.....	48
3.4.2	Desafíos futuros	49
3.5	Resumen.....	50
Capítulo 4 Redes Neuronales Artificiales para el pronóstico de series de tiempo		51
4.1	Modelado de series de tiempo	51
4.1.1	Datos secuenciales	51
4.1.2	Aprendizaje supervisado	52
4.1.3	Modelo predictivo	52
4.1.4	Estrategias de pronóstico.....	53
4.1.5	Horizonte retrospectivo (look back)	54
4.2	Redes neuronales para series de tiempo.....	55
4.2.1	RNN - Recurrent Neural Network.....	58
4.2.2	LSTM - Long Short-Term Memory Network.....	59
4.2.3	GRU – Gated Recurrent Unit	60
4.3	Optimización de hiper-parámetros.....	62
4.4	Resumen.....	64
Capítulo 5 Estado del arte		65
5.1	Preliminar	65
5.2	Revisión de literatura	67
5.2.1	A nivel internacional.....	67
5.2.2	A nivel nacional y región Piura	68
5.3	Análisis y síntesis	68
5.4	Análisis de la frontera de conocimiento	71
5.5	Resumen.....	73

Capítulo 6 Exportación de banano orgánico del Perú	77
6.1 Exportaciones de banano orgánico.....	77
6.1.1 Partida arancelaria	77
6.1.2 Evolución histórica	78
6.1.3 Mercados destino.....	80
6.2 Análisis exploratorio - descriptivo.....	82
6.2.1 Time-plot	82
6.2.2 Estacionalidad	83
6.2.3 Box-plot	84
6.2.4 Componentes	85
6.3 Resumen.....	86
Capítulo 7 Metodología de investigación.....	87
7.1 Proceso de investigación.....	87
7.2 Metodología.....	89
7.3 Diseño de experimento	90
7.3.1 Experimento tipo 1.....	92
7.3.2 Experimento tipo 2.....	93
7.4 Técnicas y métodos	93
7.4.1 Re-muestreo.....	93
7.4.2 Normalización.....	95
7.4.3 División de datos (training-set y testing-set)	95
7.4.4 Métricas de error de predicción.....	95
7.4.5 Trade-off: bias y varianza	97
7.5 Dataset	99
7.5.1 Variable temporal.....	99
7.5.2 Fuente de datos.....	99
7.5.3 Calidad de datos	99
7.5.4 Tamaño de la base de datos.....	100

7.5.5 Pre-procesamiento.....	100
7.5.6 Software y hardware.....	101
Capítulo 8 Resultados y discusión.....	105
8.1 Resultados.....	105
8.1.1 Modelo MLP.....	106
8.1.2 Modelo RNN.....	109
8.1.3 Modelo LSTM.....	112
8.1.4 Modelo GRU.....	115
8.1.5 Mejores modelos.....	118
8.1.6 Modelo predictivo propuesto.....	122
8.2 Discusión.....	124
Capítulo 9 Conclusiones.....	127
9.1 Conclusiones.....	127
9.2 Contribución.....	128
9.3 Trabajos futuros.....	129
Referencias bibliográficas.....	131
Apéndices.....	139
Apéndice 1. Árbol de problemas.....	141
Apéndice 2. Modelado de datos secuenciales.....	142
Apéndice 3. Proyectos de investigación sobre banano en Piura.....	143
Apéndice 4. Calendario Plot de la exportación de banano orgánico del Perú desde Enero-2012 a Setiembre-2021.....	145
Apéndice 5. Resumen de las métricas reportadas en el Estado del Arte.....	146

Lista de figuras

Figura 1. <i>Cadena de valor del banano: esquema general.</i>	24
Figura 2. <i>Propuesta de trabajo para el modelado y pronóstico de las exportaciones de banano orgánico.</i>	30
Figura 3. <i>Ejemplos de series de tiempo: a) financiero, b) físico, c) marketing, y d) control de proceso.</i>	33
Figura 4. <i>Serie de tiempo y sus componentes.</i>	34
Figura 5. <i>Serie de tiempo: Descomposición en tendencia, estacionalidad y residual.</i>	34
Figura 6. <i>Series de tiempo: áreas de aplicación.</i>	35
Figura 7. <i>Serie de tiempo: Clasificación de métodos y modelos predictivos.</i>	38
Figura 8. <i>Serie de tiempo: objetivos para su análisis.</i>	40
Figura 9. <i>Inteligencia artificial: sub-áreas de conocimiento.</i>	44
Figura 10. <i>Machine Learning: Flujograma del aprendizaje automático.</i>	46
Figura 11. <i>Machine Learning: Clasificación de los algoritmos.</i>	47
Figura 12. <i>Machine Learning en la agricultura: Áreas de investigación en la cadena de suministro.</i>	49
Figura 13. <i>Estrategia de pronóstico: one-step ahead.</i>	53
Figura 14. <i>Estrategia de pronóstico: multi-step ahead.</i>	54
Figura 15. <i>Arquitectura de una (a) red neuronal artificial y (b) red neuronal recurrente.</i>	56
Figura 16. <i>Estructura de tres tipos de redes neuronales recurrentes: a) estándar, b) LSTM, c) GRU.</i>	57
Figura 17. <i>Similitudes y diferencias entre una celda de memoria de a) una red LSTM y b) una red GRU.</i>	59
Figura 18. <i>Inteligencia Artificial aplicada al banano: áreas de investigación en pre-cosecha, cosecha, post-cosecha, procesamiento y retail.</i>	66

Figura 19. <i>Inteligencia Artificial aplicada al banano: mapeo de aplicaciones de IA, algoritmos de aprendizaje implementados y potenciales impactos.</i>	66
Figura 20. <i>Evolución histórica de la exportación de banano orgánico (ene-2001 a set-2021).</i>	79
Figura 21. <i>Exportación mensual de banano orgánico del año 2018, 2019 y 2020.</i>	80
Figura 22. <i>Exportación de banano orgánico en el año 2020: distribución geográfica de los países de destino.</i>	81
Figura 23. <i>Exportación de banano orgánico: a) anual, b) mensual, c) semanal, y d) diario...</i>	82
Figura 24. <i>Exportación mensual de banano orgánico (ene-2001 a set-2021).</i>	84
Figura 25. <i>Exportación de banano orgánico: box-plot a escala a) anual y b) mensual.</i>	85
Figura 26. <i>Serie de tiempo: componentes de tendencia, estacionalidad y residual.</i>	86
Figura 27. <i>Flujograma del trabajo de investigación.</i>	88
Figura 28. <i>Flujograma del diseño de experimentos.</i>	92
Figura 29. <i>Técnicas de re-muestreo para para serie temporal: a) Cambios de las frecuencias de tiempo; b) down-sampling; c) up-sampling</i>	94
Figura 30. <i>Trade-off: Efectos del bias y la varianza en a) error de predicción del modelo, b) exactitud y precisión de valores pronosticados.</i>	98
Figura 31. <i>Training-set y testing-set según ratio: a) 95-05, b) 90-10, c) 80-20.</i>	102
Figura 32. <i>Modelo MLP: Efecto de la variación del look back en la curva Loss del testing-set.</i>	107
Figura 33. <i>Modelo MLP: Efecto del número de neuronas en el cálculo del error RMSE del testing-set.</i>	108
Figura 34. <i>Los mejores modelos MLP: Valores reales vs valores pronosticados.</i>	108
Figura 35. <i>Modelo RNN simple: Efectos de la variación del look back en la curva Loss del testing-set.</i>	110
Figura 36. <i>Modelo RNN simple: Efecto del número de unidades recurrentes en el error RMSE del testing-set.</i>	111
Figura 37. <i>Los mejores modelos RNN simple: Valores reales vs valores pronosticados.</i>	111
Figura 38. <i>Modelo LSTM: Efecto de la variación del look back en la curva Loss del testing-set.</i>	113
Figura 39. <i>Modelo LSTM: Efecto del número de unidades recurrentes en el error RMSE del testing-set.</i>	114

Figura 40. <i>Los mejores modelos LSTM: Valores reales vs valores pronosticados.</i>	114
Figura 41. <i>Modelo GRU: Efecto de la variación del look back en la curva Loss del testing-set.</i>	116
Figura 42. <i>Modelo GRU: Efecto del número de unidades recurrentes en el error RMSE del testing-set.</i>	117
Figura 43. <i>Los mejores modelos GRU: Valores reales vs valores pronosticados.</i>	117
Figura 44. <i>Mejores modelos entrenados y la influencia del look back en el error RMSE del testing-set.</i>	118
Figura 45. <i>Mejores modelos entrenados MLP, RNN, LSTM y GRU: Curva loss del testing-set y valores pronosticados para a) 3 meses, b) 6 meses y c) 12 meses de look back.</i>	119
Figura 46. <i>Mejores modelos entrenados: pronóstico vs real de a) MLP, b) RNN, c) LSTM, d) GRU.</i>	120
Figura 47. <i>Modelado de la serie de tiempo: pronóstico vs real.</i>	124



Lista de tablas

Tabla 1. <i>Tipos de redes neuronales para análisis de series de tiempo.</i>	56
Tabla 2. <i>Red neuronal LSTM: Interacciones dentro de una celda de memoria.</i>	60
Tabla 3. <i>Red neuronal GRU: Interacciones dentro de una celda de memoria.</i>	61
Tabla 4. <i>Resumen analítico del Estado del Arte: serie de tiempo a estimar y características del dataset.</i>	74
Tabla 5. <i>Resumen analítico del Estado del Arte: estrategia de pronóstico, algoritmo implementado, contribución y desventajas.</i>	75
Tabla 6. <i>Información arancelaria del banano orgánico del Perú.</i>	78
Tabla 7. <i>Exportación anual del banano orgánico del 2012 al 2020.</i>	79
Tabla 8. <i>Exportación de banano orgánico en el año 2020 según país de destino.</i>	81
Tabla 9. <i>Exportación de banano orgánico: características de la serie de tiempo y número de muestras.</i>	83
Tabla 10. <i>Exportación de banano orgánico en el año 2020: media, desviación estándar, y percentiles.</i>	85
Tabla 11. <i>Metodología para el análisis, modelado y pronóstico de series de tiempo en estudio.</i>	89
Tabla 12. <i>Diseño de experimentos.</i>	90
Tabla 13. <i>Modelos propuestos y configuración de sus hiper-parámetros.</i>	91
Tabla 14. <i>Dataset: revisión exploratoria - analítica.</i>	100
Tabla 15. <i>Tamaño del dataset según frecuencia de tiempo.</i>	100
Tabla 16. <i>División del dataset según ratio training-testing.</i>	102
Tabla 17. <i>Especificaciones del hardware y software.</i>	103
Tabla 18. <i>Modelo MLP: Performance en testing-set con diferentes valores parámetros.</i> ...	107

Tabla 19. <i>Modelo RNN simple: Performance en testing-set con diferentes valores parámetros.</i>	110
Tabla 20. <i>Modelo LSTM: Métricas de error de predicción según look back.</i>	113
Tabla 21. <i>Modelo GRU: Métricas de error de predicción según look back.</i>	116
Tabla 22. <i>Mejores modelos entrenados: configuración de sus hiper-parámetros.</i>	120
Tabla 23. <i>Mejores modelos predictivos y métricas de performance en el training-set y testing-set.</i>	121
Tabla 24. <i>Mejores modelos y sus errores de predicción en el testing-set.</i>	121
Tabla 25. <i>Mejores modelos: Tiempo computacional para el entrenamiento y validación.</i>	121
Tabla 26. <i>Modelo propuesto: Variables para el modelado y pronóstico.</i>	122
Tabla 27. <i>Secuencia del algoritmo para el modelo de serie de tiempo.</i>	123
Tabla 28. <i>Pronóstico de la serie de tiempo con intervalo de confianza.</i>	124

Introducción

Machine Learning es una de las tecnologías de la Industria 4.0. Los avances en Machine Learning han aportado beneficios significativos en la toma de decisiones estratégicas de las organizaciones (empresa, gobierno, sociedad civil). En las últimas décadas, los modelos predictivos usando algoritmos de Machine Learning han sido implementadas en entornos reales de organizaciones, que operan en la industria de la agricultura y en cadena de suministro global del banano, y han obtenido buenos resultados. Si embargo, este tipo de tecnología aún es incipiente o con nula presencia en la realidad de la agro-industria peruana.

Dado que la tecnología de Machine Learning tiene un alto potencial para optimizar sus procesos y la toma de decisiones acertadas y anticipadas, de tal manera que se maximice la demanda mundial del banano orgánico peruano. Por ello, la presente investigación buscar ser pionera en la implementación una aplicación de Machine Learning en el ámbito de la agro-industria del Perú y la región Piura, como escenario de la Industria 4.0. En ese sentido, la presente tesis doctoral busca contribuir al estudio del modelado y pronóstico de series de tiempo, mediante la implementación de algoritmos de Machine Learning.

El objetivo de la presente tesis es examinar y modelar los datos reales, y poco explorados, de la demanda internacional del banano orgánico del Perú con la finalidad de pronosticar valores futuros con el menor error de predicción posible. En ese sentido, esta investigación aplicada abarca el diseño, entrenamiento, validación y evaluación de cuatro modelos predictivos, usando algoritmos de Redes Neuronales Recurrentes. Para el desarrollo de la investigación, se utilizó los registros oficiales del volumen de exportación (kilogramos) de banano orgánico del Perú, recolectados del año 2001 al 2020 en el portal online de Aduanet-Sunat. Consecuentemente, en el proceso de alcanzar el objetivo de investigación, se explora las siguientes preguntas de investigación relacionado al modelado y pronóstico de datos secuenciales en estudio:

RQ1: *¿Puede el modelado a base de Redes Neuronales Recurrentes (RNN, LSTM y GRU) superar el performance del modelo a base de redes neuronales artificiales clásicas (MLP)?*

Por ello, la presente tesis doctoral buscar contribuir significativamente de la siguiente manera:

- Una revisión sistemática de publicaciones científicas internacionales relacionadas al modelado de series de tiempo para el pronóstico de demanda/oferta de agro-productos, implementando modelos paramétricos (algoritmos de Machine Learning) y modelos no-paramétricos.
- Una metodología para el modelado y pronóstico del volumen de exportación de banano orgánico de Perú. Esta metodología incluyendo las técnicas para el pre-procesamiento de datos temporales, y el procedimiento para el entrenamiento, validación y evaluación del modelo entrenado para el pronóstico de series de tiempo.
- Cuatro tipos de red neuronal artificial testeados para el pronóstico de serie de tiempo, incluyendo: a una red neuronal clásica (MLP) y tres redes neuronales recurrentes (RNN, LSTM, y GRU).
- Cuatro modelos entrenados con algoritmos de aprendizaje supervisado (MLP, RNN, LSTM, y GRU) para el pronóstico de la exportación de banano orgánico de Perú, usando datos históricos de 2001 al 2021.
- Un análisis comparativo del performance de los modelos entrenados, evaluando: horizonte de retrosección, curva *loss*, error de predicción, *trade-off* entre *bias* y varianza, y tiempo de procesamiento.
- Una implementación del algoritmo de aprendizaje supervisado del tipo red neuronal recurrente RNN en TensorFlow para el pronóstico de los datos temporales de la exportación de banano orgánico.

La presente tesis doctoral está estructurada de la siguiente manera:

Capítulo 1 – Formulación de la investigación: El primer capítulo de la tesis comprende la formulación de la investigación, describiendo a detalle: la problemática, la justificación, los objetivos de investigación, el alcance y las limitaciones.

Capítulo 2 – Fundamentos de series de tiempo: El segundo capítulo de la tesis abarca los fundamentos teóricos de las series de tiempo, tales como: definición, tipología, componentes descriptivos, y métodos y modelos de predicción.

Capítulo 3 – Fundamentos de Machine Learning y sus aplicaciones en la agricultura: El tercer capítulo de la tesis contiene los conceptos claves de la tecnología Machine Learning: principales definiciones, el proceso del aprendizaje automático, tipos de aprendizaje de máquina y sus algoritmos más conocidos. Asimismo, se presentan las aplicaciones de esta tecnología en la agricultura, describiendo las principales áreas de investigación y sus desafíos futuros.

Capítulo 4 – Redes neuronales artificiales para el pronóstico de series de tiempo: El cuarto capítulo presenta los fundamentos matemáticos de las Redes Neuronales Artificiales para el pronóstico de series de tiempo. Particularmente, se describen la dinámica del aprendizaje automático de las Redes Neuronales Recurrentes Clásica (RNN), Long-Short Term Memory (LSTM) y Gated Recurrent Unit (GRU).

Capítulo 5 – Estado del arte: El quinto capítulo de la tesis comprende un análisis sistemático de publicaciones científicas a nivel internacional relacionadas al pronóstico de la demanda y/o producción de agro-productos, usando modelos de Machine Learning; y la presentación de los antecedentes de la investigación a nivel nacional y local (región Piura). Asimismo, se delimita y discute la brecha de conocimiento.

Capítulo 6 – Exportación del banano orgánico del Perú: El séptimo capítulo presenta la descripción y el análisis exploratorio descriptivo de la serie de tiempo de la demanda de banano orgánico: sector bananero del Perú, evolución de las exportaciones de la exportación anual y principales características analíticas de la serie de tiempo.

Capítulo 7 – Metodología de investigación: El sexto capítulo de la tesis explica a detalle el proceso general de investigación, el diseño de experimentos; así como, las técnicas y los métodos empleados para el entrenamiento, validación y evaluación del modelo de pronóstico de serie de tiempo.

Capítulo 8 – Resultados y discusión: El octavo capítulo contiene la presentación de los experimentos y sus resultados para el pronóstico del dataset de la exportación de banano orgánico.

Finalmente, **Capítulo 9 – Consideraciones finales:** el noveno capítulo comprende la discusión de resultados, las conclusiones, contribuciones y limitaciones de la investigación; adicionalmente, se presenta los posibles trabajos futuros en base a los capítulos anteriores.



Capítulo 1

Formulación de la investigación

Este capítulo presenta la formulación de la investigación doctoral. En la sección 1.1, se describe la problemática. La justificación es presentada en la sección 1.2. Los objetivos de investigación son planteados en la sección 1.3. En la sección 1.4 se presenta un esquema del trabajo de investigación a desarrollar. Finalmente, la sección 1.4 presenta el alcance y las limitaciones de la investigación.

1.1 Planteamiento del problema

La cadena de suministro de agro-alimentos cada vez es más digital y globalizado (Ben Ayed & Hanana, 2021; Demartini et al., 2018; Sharma, Kamble, et al., 2020). Cada año aumenta el nivel de competitividad en el mercado global del alimentos y frutas (Demartini et al., 2018). En el año 2020, la cadena de valor agro-alimentaria fue impactada profundamente por las restricciones de la pandemia Covid-19. De acuerdo al estudio realizado por Das & Roy (2021), se afirma que las empresas agro-industriales presentaron desafíos relacionados a fluctuaciones del precio de alimento, seguridad alimentaria, estrategias de resiliencia para fortalecer la cadena de valor, variaciones en los tratados de comercio, entre otros. Similarmente, en el estudio desarrollado por Sharma, R. et al. (2020), manifiesta la inestabilidad de la demanda-oferta de los productos agro-alimentarios a nivel mundial debido a la adaptación de la “nueva normalidad” post-pandemia.

Recientemente, la demanda de la cadena de valor es considerado como objeto de estudio en la agricultura inteligente moderna (Benos et al., 2021). Y como línea de investigación de la industria del procesamiento y manipulación de alimentos (Kumar et al., 2021). Diversos estudios mencionan que la incertidumbre de la demanda afecta a la estabilidad de los precios de mercado y precio de venta del consumidor (Abraham et al., 2017, 2020; Devi et al., 2021). Todo lo anterior refuerza la factibilidad de considerar el tema de demanda de agro-productos como un tema de investigación.

Consecuentemente, la situación actual de la cadena de valor del banano también tiene latentes desafíos a ser atendidos (Tarekegn et al., 2020; Tinzaara et al., 2018). En la **Figura 1**

se representa la cadena de valor del banano y sus principales actividades, resaltando la etapa de exportaciones, el cual es donde se enmarca la presente investigación.

De acuerdo con la FAO (2020b), los países que exportan de bananas y frutas tropicales han visto afectado su volumen de ventas y ganancias debido a que la cadena productiva más competitiva, intensificación del poder de mercado de los actores intermedios, la aparición de enfermedades de las plantas, eventos meteorológicos adversos y la crisis de salud y económica del año 2020. Diversos estudios (Rathod & Mishra, 2018; Scott, 2021) concluyen que en los países en vías de desarrollo existe una necesidad de asegurar la demanda y expandir la producción/exportación de productos agro-industriales, pues es la base de su economía (Rathod & Mishra, 2018; Scott, 2021).

En ese sentido, se hace interesante y retadora el estudio de la incertidumbre en la demanda de agro-productos en el Perú, particularmente del banano orgánico, debido a que se considera una latente escenario vulnerable y con evidentes impactos en el ámbito económico, social y político (Das & Roy, 2021; Mahto et al., 2021). Por lo cual, se concluye que es relevante considerar esta coyuntura como problema de investigación.

Figura 1.

Cadena de valor del banano: esquema general.



Adaptado de "Challenges and opportunities for smallholders in banana value chains" (Tinzaara et al., 2018) y "Value chain analysis of banana in Bench Maji and Sheka Zones of Southern Ethiopia" (Tarekegn et al., 2020).

La problemática de la presente investigación está enmarcada en la incierta y casi impredecible demanda internacional de exportación del banano orgánico peruano. Este problema está vinculado a las siguientes causas: insuficiente información de demanda de

consumidor, constantes fluctuaciones de los precios de venta, mayor exigencia y cambios en los requerimientos de la seguridad alimentaria, políticas inciertas del comercio internacional, y nuevas reglas del mercado. Se sugiere revisar el Apéndice 1, donde se presenta un esquema resumen de esta problemática en estudio.

Este contexto evidencia el reto de implementar proyectos de transformación tecnológica, en responsabilidad compartida con otros actores de la cadena de valor agroalimentaria, con la finalidad adaptarse a los desafíos, aumentar competitividad, mantenerse vigente en el mercado y asegurar un futuro sostenible (Handayati et al., 2015). Consecuentemente, toma relevancia la adopción de tecnologías de la Industria 4.0, las cuales favorecen a mejorar significativamente el desarrollo sostenible de la cadena de suministro y a satisfacer la demanda dinámica del consumidor global (Sharma, Shishodia, et al., 2020).

La Inteligencia Artificial, considerada como una de las tecnologías 4.0, se anticipa a escenarios futuros del mercado global y tomar decisiones acertadas que conlleven a mitigar riesgos (Kouadio et al., 2018). Entonces, surge la oportunidad para investigar la aplicación e implementación de la tecnología de Inteligencia Artificial para explorar, entender y predecir el comportamiento del volumen de las exportaciones de banano orgánico peruano con la finalidad de minimizar la incertidumbre inherente del comercio internacional.

Consecuentemente, Machine Learning, considerada como un área de Inteligencia Artificial, facilita entender el comportamiento de variables predictoras (output) mediante variables predictoras (input). Para ello, los modelos predictivos usando algoritmos de aprendizaje automático son de gran utilidad y eficiencia en la predicción de escenarios futuros. Los modelos de Machine Learning se caracterizan por extraer *insights* de enormes volúmenes de datos, de manera económica y efectiva. Machine Learning facilita entender y anticiparse a la tendencia y estacionalidad de las exportaciones de banano orgánico peruano. Ello ofrece una gran ventaja en el proceso de toma de decisiones: decisiones más acertadas, más rápidas y con menor riesgo.

En el Perú, no hay investigaciones científicas que estudien el comportamiento de demanda del banano orgánico peruano empleando Machine Learning o Deep Learning, de acuerdo a una búsqueda extensa del Estado del Arte (ver Capítulo 5). Por lo cual, se concluye que es relevante considerarlo como tema de investigación.

En ese sentido, surge responder la siguiente pregunta de investigación *¿Puede un modelo de Machine Learning predecir significativamente el volumen de exportación de banano orgánico de Perú y bajo qué condiciones?*

Desde la disciplina del *Computer Science*, la presente tesis doctoral se enmarca bajo la siguiente línea de investigación: modelado y pronóstico de series de tiempo mediante la implementación de algoritmos de Machine Learning. La presente investigación busca contribuir en el desarrollo, entrenamiento y validación de un modelo predictivo para estimar

el volumen (kg.) de exportación de banano orgánico del Perú, usando algoritmos de Redes Neuronales Recurrentes.

Consecuentemente, con la intención de responder la pregunta de investigación inicial, se explora las siguientes preguntas de investigación específicas relacionadas al modelado y pronóstico de datos secuenciales de la exportación de banano orgánico peruano:

RQ1: *¿Puede el modelado a base de Redes Neuronales Recurrentes (LSTM y GRU) superar el performance del modelo a base de redes neuronales artificiales clásicas (MLP)?*

Para el desarrollo de la presente investigación, se utilizó los registros oficiales del volumen de exportación (kg.) de banano orgánico del Perú, recolectados del año 2001 al 2021 en el portal online de Aduanet-Sunat (ver Capítulo 7, Sección 7.4).

1.2 Justificación

La sección anterior presentó la problemática del sector del banano orgánico peruano y las preguntas de investigación. En resumen, la presente tesis doctoral estudia el modelado predictivo usando algoritmos de Machine Learning para pronosticar la demanda internacional de banano orgánico del Perú.

En esta sección corresponde presentar la justificación, los beneficios y posibles impactos positivos derivados de atender el problema de investigación. La justificación de la presente tesis es explicada bajo los siguientes enfoques: económico, tecnológico, social y político.

i) Económico:

A nivel internacional, el banano es la fruta fresca más exportada del mundo de acuerdo con los estudios realizados por el Foro Mundial Bananero de la FAO (2020c). Se estima que la industria del banano se valoriza en más de 10 billones de dólares al año (US \$ 10.000mn / año) (FAO, (2017). A nivel nacional, la agricultura es uno de los sectores económicos más dinámicos en Perú según el Informe de Producción Nacional elaborado por el INEI (2020). Particularmente, MINAGRI⁵ (2019) asegura que el banano pertenece al top 10 de los productos frutales exportables de acuerdo a su “Boletín Estadístico Mensual, Junio-2019”. Según el MINCETUR⁶(2021), las exportaciones del banano representó el 7mo lugar del total de productos exportados a la Unión Europa en el año 2020. El sector bananero del Perú, tiene

⁵ Ministerio de Desarrollo Agrario y Riego

⁶ Ministerio de Comercio Exterior y Turismo

un influencia directa en los ingresos de las empresas agro-industriales y exportadoras según la FAO (2020b). Según estudios realizados por CIPCA⁷ (2019) y CEDEPAS⁸ Norte (2017), la exportación de banano orgánico en Piura afecta directamente a los ingresos económicos de cientos de hogares de pequeños-agro productores de zonas rurales. Lo explicado anteriormente, refuerza la relevancia del presente tema de estudio a nivel económico.

ii) Tecnológico:

En el escenario de la Industria 4.0 en la agricultura, la Inteligencia Artificial ofrece ventajas para maximizar el rendimiento económico, la optimización del uso y disponibilidad de recursos, y la conservación de medio ambiente (Annosi et al., 2019; Muhuri et al., 2019). Particularmente, la tecnología Machine Learning aplicada a tareas de agricultura impacta positivamente en la generación de nuevo conocimiento para la trazabilidad del proceso agro-industrial y la gestión de toma de decisiones asertivas, aportando significativamente a lograr una agricultura sostenible y más productiva (Benos et al., 2021; Sharma, Kamble, et al., 2020). Es decir, esta tecnología desarrolla modelos inteligentes, usando algoritmos de aprendizaje de máquina, que explican la interrelación entre factores específicos y una acción consecuente, con la finalidad de facilitar la estimación de una respuesta en un escenario futuro (Elavarasan et al., 2018). Ello repercute directamente en la optimización del proceso de toma decisiones empresariales, se obtiene información anticipada para elegir decisiones de forma acertada y más rápida (Pugliese et al., 2021). En la cadena de valor del banano orgánico del Perú, estos beneficios tecnológicos favorecen a optimizar procesos agro-industriales y convertirla en una cadena de valor agro-tecnológicamente sostenible.

Adicionalmente, la presente tesis abordar un área de investigación del *Computer Science* relacionado al modelamiento de series de tiempo usando algoritmos de aprendizaje automático. La investigación contribuirá con el desarrollo de modelos predictivos con enfoque de Machine Learning que atiendan la necesidad de minimizar la incertidumbre de la exportación de banano orgánico peruano. Ello impacta positivamente en la comunidad científica: la investigación amplía la frontera de conocimiento en esa área relacionado al pronóstico de series de tiempo de agro-productos. De todo lo explicado anteriormente, se concluye la relevancia del tema de investigación a nivel tecnológico en el sector del banano orgánico.

iii) Social y político:

En ese sentido, la tecnología de Machine Learning aplicado al contexto del comercio internacional del banano orgánico de Perú ofrece diversas ventajas para los agricultores, las

⁷ Centro de Investigación y Promoción del Campesinado

⁸ Centro Ecuaménico de Promoción y Acción Social

empresas exportadoras, entidades del Gobierno y otros *stakeholders* de la cadena de valor del banano (Benos et al., 2021; Meshram et al., 2021; Sharma, Kamble, et al., 2020) (Irani et al., 2018):

El cultivo, cosecha y exportación de banano orgánico tiene un fuerte impacto social en la población peruana CIPCA (2019). La venta y exportación de banano es el principal sustento de miles de familias en zonas rurales del norte y nor-orientes del Perú CEDEPAS Norte (2017). Asegurando la sostenibilidad de la cadena de valor del banano orgánico se está asegurando el empleo de miles de pequeños agricultores (FAO, (2020b), mejorando la calidad de vida de sus hogares, y beneficiando la reactivación de asociaciones de pequeños productores y empresas agro-exportadoras.

Los *stakeholders* del eslabón de distribución y *retail* de la cadena de valor del banano, tales como empresas agro-exportadoras podrán acceder a una herramienta tecnológica confiable para anticiparse a la demanda internacional del banano orgánico. De tal manera que puedan planificar, organizar y optimizar sus recursos logísticos y financieros para maximizar las campañas de exportación y/o post-cosecha de banano orgánico (Sharma, Kamble, et al., 2020).

Los tomadores de decisiones del gobierno local y regional tendrán un recurso de información (confiable y preciso) para planificar programas y proyectos agro-tecnológicos (Benos et al., 2021), ajustadas al ritmo real de la demanda internacional del banano orgánico. De tal manera que les facilite la optimización de recursos logísticos y económicos para continuar potenciando la industria agro-exportadora del banano orgánico.

Los formuladores de políticas públicas y gestores políticos podrán acceder a información valiosa pre-procesada para desarrollar mejores políticas a nivel nacional referentes a la sostenibilidad del cultivo, cosecha y post-cosecha del banano orgánico. Por ejemplo, políticas sectoriales para la reducción de pérdida post-cosecha (Irani et al., 2018). Asimismo, establecer estrategias de producción y comercio internacional para los próximos años (mediano plazo), buscando potenciar la economía del sector.

Finalmente, la viabilidad de la presente tesis de doctorado se justifica en base a la disponibilidad de los datos históricos de exportación de banano orgánico peruano. Se cuenta con un dataset oficial de la Agencia de Aduanas-Sunat, el cual contiene datos recolectados de las exportaciones mensuales del banano orgánico del Perú durante el período 2001 al 2021 Sunat (ver Capítulo 7, Sección 7.4).

1.3 Objetivos de investigación

En esta sección se exponen los objetivos de investigación de la presente tesis doctoral.

Objetivo principal:

Estudiar el modelado y pronóstico de series de tiempo para estimar la demanda internacional del banano orgánico de Perú usando algoritmos de Machine Learning.

Objetivos específicos:

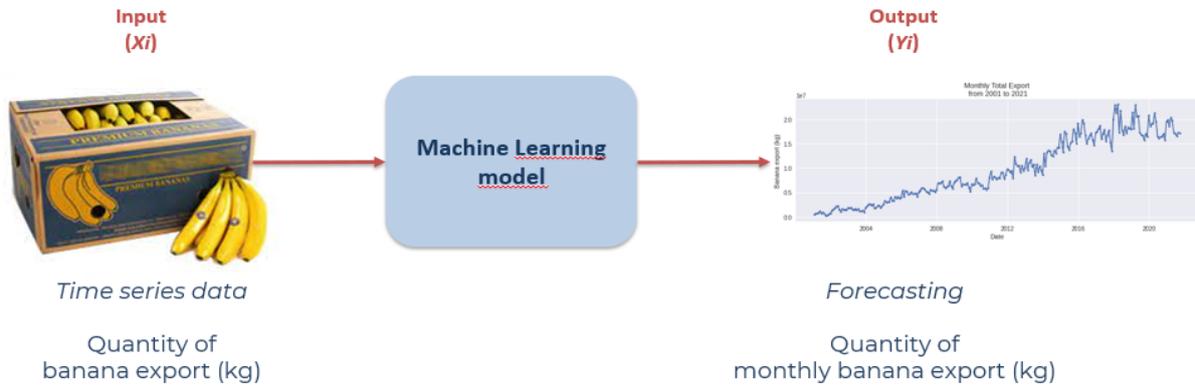
- Comprender las series de tiempo y los fundamentos para pronosticar sus valores futuros en base a valores pasados.
- Estudiar los algoritmos de Machine Learning aplicables para el pronóstico de series de tiempo. Particularmente, comprender los fundamentos de las Redes Neuronales Recurrentes aplicadas a series de tiempo.
- Explorar modelos de pronóstico de demanda de agro-productos que han sido implementados en los últimos años a nivel internacional, nacional y local.
- Diseñar una metodología de investigación para el diseño y desarrollo de modelos de pronóstico de series de tiempo.
- Describir analíticamente la serie de tiempo de la demanda internacional de banano orgánico en Perú, a través del volumen de exportación mensual del 2001 al 2021.
- Desarrollar un modelo predictivo para la exportación mensual del banano orgánico de Perú usando algoritmos de Redes Neuronales Recurrentes.
- Analizar, interpretar y discutir los resultados obtenidos.
- Elaborar las conclusiones de la investigación, presentar las contribuciones, las limitaciones y los trabajos futuros.

1.4 Esquema del trabajo de investigación

La **Figura 2** expone una representación general del trabajo de investigación para el modelado de serie de tiempo con algoritmos de Machine Learning, el cual realizará pronósticos de los valores futuros del volumen de exportaciones mensuales del banano orgánico peruano.

Figura 2.

Propuesta de trabajo para el modelado y pronóstico de las exportaciones de banano orgánico.



1.5 Alcance y limitaciones

La presente tesis doctoral aborda el diseño, entrenamiento, validación y evaluación de diversos modelos predictivos, usando algoritmos de Redes Neuronales Recurrentes. Para el desarrollo de la investigación, se utiliza los registros oficiales del volumen de exportación (Kg.) de banano orgánico del Perú (Aduanet-Sunat). De acuerdo a la cadena de valor del banano, el cual está representado en la **Figura 1**, el presente estudio se ubica en la fase de venta al mercado internacional: exportaciones totales registradas en los agentes aduaneros.

La principal limitación de esta investigación es el dataset. La investigación cuenta con datos recolectados del total de exportación de banano orgánico peruano recolectadas desde el 2001 al 2020, disponibles en el portal online de Aduanet-Sunat. Por lo cual, se cuenta con un limitado número de datos para entrenar el modelo predictivo. Ello limita el aprendizaje del modelo, pues sólo se cuenta con una cantidad fija de datos. A pesar de ello, se realizará varios experimentos para encontrar el algoritmo de aprendizaje que presente mejor performance y/o el mejor ajuste para lograr una alta precisión en el pronóstico de la demanda internacional de banano orgánico.

Capítulo 2

Fundamentos de series de tiempo

Este capítulo repasa los fundamentos de las series de tiempo, como parte del marco teórico. En la sección 2.1, 2.2 y 2.3 se presenta los conceptos básicos relacionados a las series de tiempo: definición, clasificación y componentes principales. Seguidamente, las áreas de aplicación de las series de tiempo son explicadas en la sección 2.4. La sección 2.5 expone los métodos y modelos para la estimación de valores futuros de la serie de tiempo bajo el enfoque tradicional y el enfoque de Machine Learning. Finalmente, la sección 2.6 repasa el enfoque de análisis para el pronóstico de series de tiempo, el cual comprende descripción, modelado, predicción y control.

2.1 Definición

En esta sección se presenta las definiciones que se usarán para la presente tesis.

Definición 2.1.1 Serie de tiempo

De acuerdo con Charfield (2019) y Esling & Agon (2012), una serie de tiempo se define como una colección de observaciones secuenciales en el tiempo. Una serie de tiempo es una secuencia de observaciones en orden cronológico que son registrados en intervalos de tiempo fijos (Hyndman & Athanasopoulos, 2021).

Una serie de tiempo univariable X es una secuencia ordenada de valores reales (Esling & Agon, 2012):

$$X = \{x_1, x_2, x_3, \dots, x_T\}, \forall x_i \in \mathbb{R}$$

Donde:

x_i es el valor de la variable X en el tiempo i

T es la longitud de X , representa el número total de valores que conforman la serie temporal.

Cuando las observaciones son dependientes a lo largo del tiempo, los valores futuros pueden ser predecible a partir de valores pasados. La importancia del modelado de una serie de tiempo radica en que el modelo realiza pronósticos de nuevas observaciones futuras, las cuales son comparadas con las observaciones reales pasadas (Lara-Benítez et al., 2021). Es decir, se puede analizar una muestra que está fuera de la muestra de la serie de tiempo para realizar el pronóstico.

Definición 2.1.2 Pronóstico de serie de tiempo

Dada una serie de tiempo univariable $X = \{x_1, x_2, x_3, \dots, x_N\}$, la tarea de pronosticar los futuros valores de la serie de tiempo se formula de la siguiente manera (Hewamalage et al., 2021):

$$\hat{X} = M(X) + \varepsilon$$

$$(\hat{x}_{T+1}, \hat{x}_{T+2}, \dots, \hat{x}_{T+H}) = M(x_1, x_2, \dots, x_T) + \varepsilon$$

Donde:

M es el modelo entrenado con aprendizaje supervisado, usando observaciones de la serie de tiempo X para pronosticar sus valores futuros \hat{X} .

X es un conjunto de datos de la serie de tiempo usados para entrenamiento del modelo M .

T es la longitud de X , cantidad total de muestras de X para entrenar el modelo M .

H es el horizonte de predicción deseado.

\hat{X} es el conjunto de datos pronosticados por el modelo. Este modelo estima los valores futuros de la serie temporal en intervalos de tiempo futuros desde $T + 1$ hasta $T + H$.

ε es el error de predicción asociado con la performance del modelo M . La idea es minimizar el error de predicción, el cual es definido de la siguiente forma (Lara-Benítez et al., 2021):

$$\varepsilon = \sum_{i=1}^{h=H} |x_{T+i} - \hat{x}_{T+i}|$$

Definición 2.1.3 Base de datos de serie de tiempo

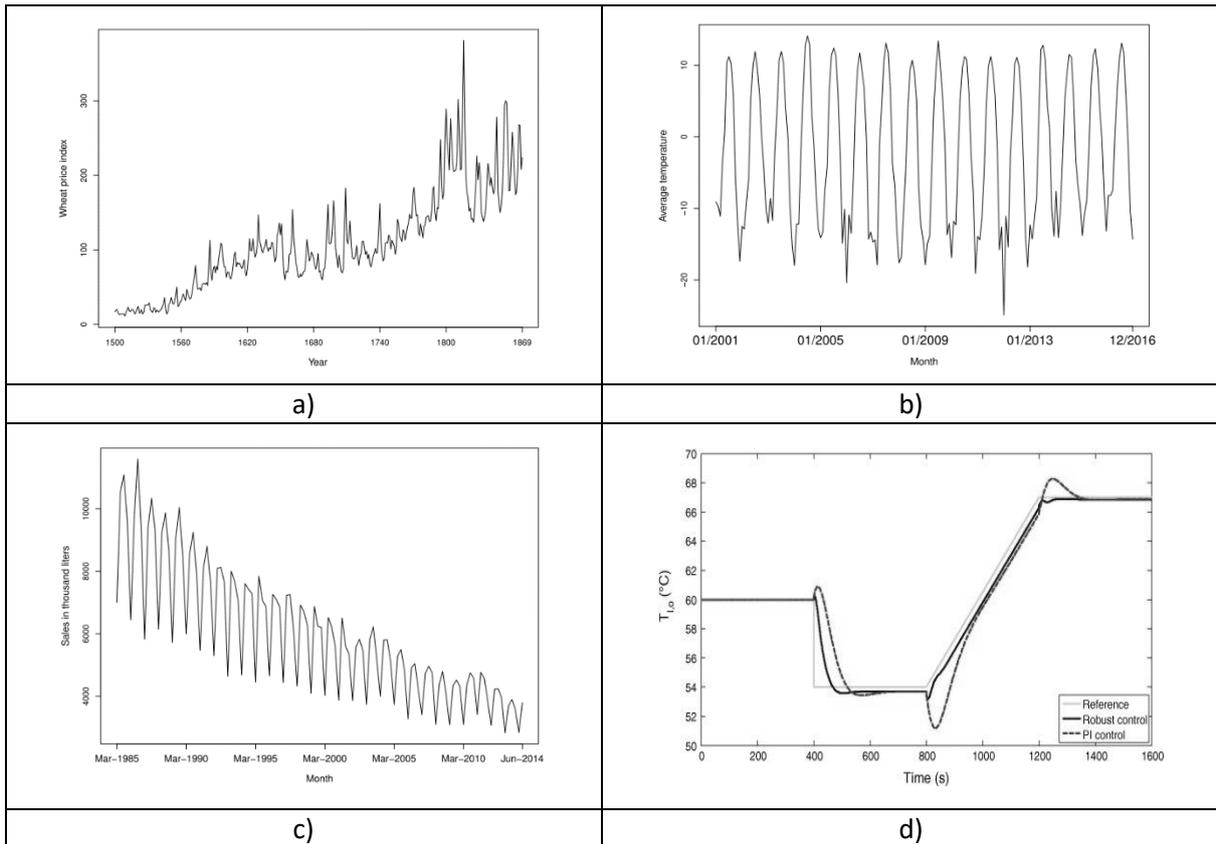
Una base de datos de una serie de tiempo es un conjunto de datos históricos de la serie temporal, recolectados directamente desde la fuente de información y que no tienen ningún tipo de procesamiento (Esling & Agon, 2012).

2.2 Clasificación

Según lo propuesto por Chatfield et al. (2019) y Parmezan et al. (2019), las series de tiempo se clasifican por su campo de aplicación: (i) procesos de control (frecuencia, voltaje, etc.), (ii) demográficos (densidad poblacional, natalidad, etc.), (iii) económicos (PBI, tipo de cambio, etc.), (iv) físicos (temperatura, humedad, etc.), (v) marketing (ventas anuales, ventas promocionales, etc.). La **Figura 3** presenta cuatro tipos de series de tiempo.

Figura 3.

Ejemplos de series de tiempo: a) financiero, b) físico, c) marketing, y d) control de proceso.



Tomado de "The analysis of time series: An introduction with R, 7th edition" (Chatfield, 2019).

2.3 Componentes

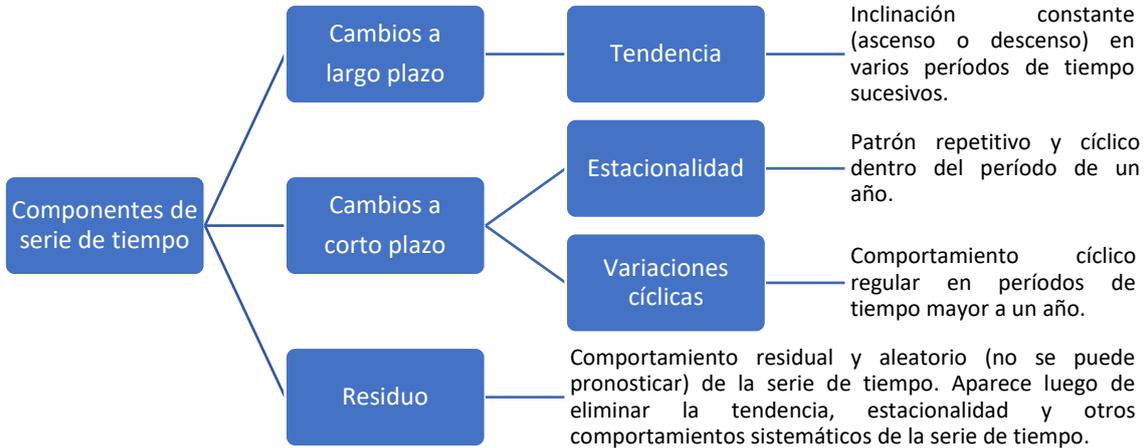
Hyndman & Athanasopoulos (2021) explica que una serie de tiempo está compuesta por tres elementos: tendencia (T), estacionalidad (E), y residual (R). Estos componentes definen el comportamiento de la serie de tiempo en el largo plazo (tendencia) y corto plazo (estacionalidad). La **Figura 4** presenta la explicación de cada componentes según los lineamientos de Chatfield et al. (2019), Parmezan et al. (2019), y Hyndman & Athanasopoulos (2021).

En este sentido, Parmezan et al. (2019) expresa que una serie de tiempo se puede descomponer aplicando métodos analíticos. Por ejemplo, dada una serie de tiempo $y_t = f(t)$,

esta puede definirse como la suma independiente de sus tres componentes: $y_t = T(t) + E(t) + R(t)$. También se puede modelar la serie de tiempo mediante la combinación de la suma y multiplicación de sus componentes: $y_t = T(t) + E(t) + C(t) \times A(t)$. La **Figura 5** contiene una representación gráfica de la descomposición de una serie de tiempo.

Figura 4.

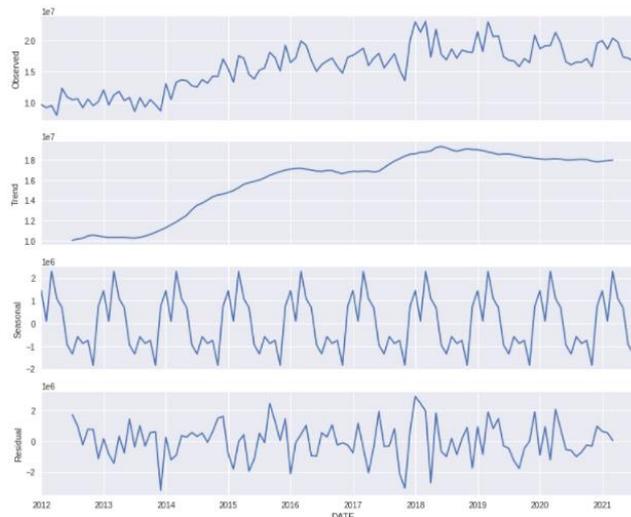
Serie de tiempo y sus componentes.



Elaboración propia a partir de "The analysis of time series: An introduction with R, 7th edition" (Chatfield, 2019), "Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model" (Parmezan et al., 2019), "Forecasting: Principles and Practice, 3th edition" (Hyndman & Athanasopoulos, 2021).

Figura 5.

Serie de tiempo: Descomposición en tendencia, estacionalidad y residual.



Elaboración propia a partir de "Forecasting: Principles and Practice, 3th edition" (Hyndman & Athanasopoulos, 2021).

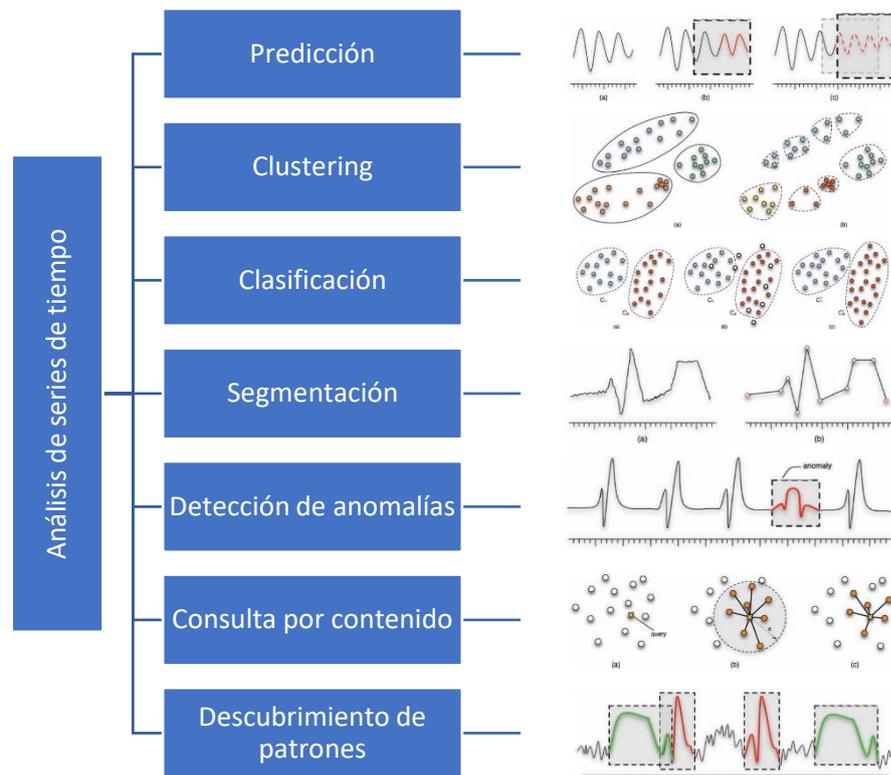
2.4 Áreas de aplicación

Esling & Agon (2012) explica que las series de tiempo en el campo del *data mining* tiene la finalidad de visualizar la forma de los datos e identificar patrones en varias escalas de tiempo. Desde que las series de tiempo comenzaron a ser estudiadas, han surgido diversos campos de aplicación.

En esta sección se describe las principales áreas de aplicación en base al tipo de análisis de la serie temporal, aunque en la práctica varias de estas aplicaciones se implementen para un mismo caso de estudio. La **Figura 6** presenta las seis áreas de aplicación de acuerdo con los propuesto por Esling & Agon (2012): predicción, *clustering* (agrupamiento), clasificación, segmentación, detección de anomalías, consultas por contenido y descubrimiento de patrones.

Figura 6.

Series de tiempo: áreas de aplicación.



Adaptado de “*Time-series data mining*” (Esling & Agon, 2012)

i) Predicción:

Las series temporales suelen ser largas y se consideran uniformes; es decir, los valores subsiguientes se encuentran dentro de rangos predecibles entre sí. La tarea de predicción tiene como objetivo modelar explícitamente dichas dependencias para pronosticar los próximos valores de una serie dentro de un horizonte predicción. La tarea de predicción

resulta más complicada cuando se trata de hacer una predicción recursiva; es decir, la predicción a largo plazo de una serie de tiempo que implica reutilizar los valores de pronóstico anteriores como entradas para continuar con la predicción.

ii) Clustering:

La tarea de *clustering* (también llamado agrupamiento) es el proceso de encontrar grupos naturales, llamados clúster, en un conjunto de datos. El objetivo es encontrar los clústeres más homogéneos que sean lo más distintos posible de otros clústeres a lo largo de intervalos de tiempo. El algoritmo debería ubicar automáticamente qué grupos están intrínsecamente presentes en los datos.

iii) Clasificación:

La tarea de clasificación busca asignar etiquetas a la serie temporal. La principal diferencia en comparación con la tarea de *clustering*: las clases se conocen de antemano y el algoritmo se entrena en un conjunto de datos etiquetados. El objetivo es primero aprender los *features* distintivos de cada clase entre sí. Luego, cuando se ingresa un conjunto de datos sin etiquetar en el sistema, puede determinar automáticamente a qué clase pertenece cada serie.

iv) Segmentación:

La tarea de segmentación tiene como objetivo crear una aproximación precisa de la serie temporal. La segmentación en series de tiempo se puede aplicar para (i) encontrar una nueva la serie de tiempo similar a la original, en base a la reducción de dimensionalidad, sin perder ninguna de sus características esenciales; (ii) identificar la cantidad de datos que representan ruido en la serie temporal.

v) Detección de anomalías:

La tarea de detección de anomalías identifica subsecuencias anormales en una serie de tiempo. Es decir, dada una serie temporal larga y con un comportamiento periódico a lo largo del tiempo, se puede modelar en base a una serie reducida de su comportamiento estándar, retirando aquellas subsecuencias que no sigan el modelo y, por lo tanto, puedan ser consideradas como anomalías. Entonces, si se pronostica los próximos valores de una serie de tiempo con gran precisión, los valores atípicos se pueden detectar de manera directa y marcar como anomalías.

vi) Consulta por contenido:

Se basa en hacer una consulta en la serie de tiempo y obtener un conjunto de soluciones lo más parecidas a lo consultado. Cada muestra en la serie de tiempo es está asociada a coordenadas. Normalmente, se representa en un espacio de búsqueda bidimensional. Se pueden calcular dos tipos de consulta. (i) una consulta de rango ε devolverá

el conjunto de muestras que están dentro de la distancia ε de la consulta, (ii) una consulta de *K-Nearest Neighbors* identificar los K puntos más cercanos a la consulta.

vii) Descubrimiento de patrones:

La tarea del descubrimiento de patrones consiste en encontrar cada subsecuencia que aparece recurrentemente en una serie temporal más larga. Estas subsecuencias se denominan “patrones”. Esta tarea exhibe una alta complejidad combinatoria, pueden existir varios patrones dentro de una sola serie, estos patrones pueden tener varias longitudes e incluso superponerse.

2.5 Métodos y modelos

Mahto et al. (2021) y Chatfield (2019) explican que las técnicas de pronóstico de series temporales se clasifican en técnicas cualitativas y técnicas cuantitativas. Por un lado, el enfoque cualitativo comprende el desarrollo de encuestas de mercado, o *focus group* con opinión de expertos. Por otro lado, el enfoque cuantitativo abarca métodos (univariable y multivariable) y modelos (Box-Jenkins, Machine Learning e híbrido) para el pronóstico de las series de tiempo. La **Figura 7** lo representa de forma esquemática. Cuando se estudia el pronóstico de una serie de tiempo, es fundamental elegir el método y el modelo más adecuado con la finalidad de propiciar el menor error de predicción (Chatfield, 2019).

2.5.1 Métodos de pronóstico

Chatfield (2019) propone dos tipos de métodos para el pronóstico de las series de tiempo: univariable y multivariable. Lara-Benítez et al. (2021) propone que el método de pronóstico de la serie de tiempo se clasifica dependiendo del número de variables en cada paso de las cuales se describen a continuación (ver **Figura 7**):

i) Método univariable:

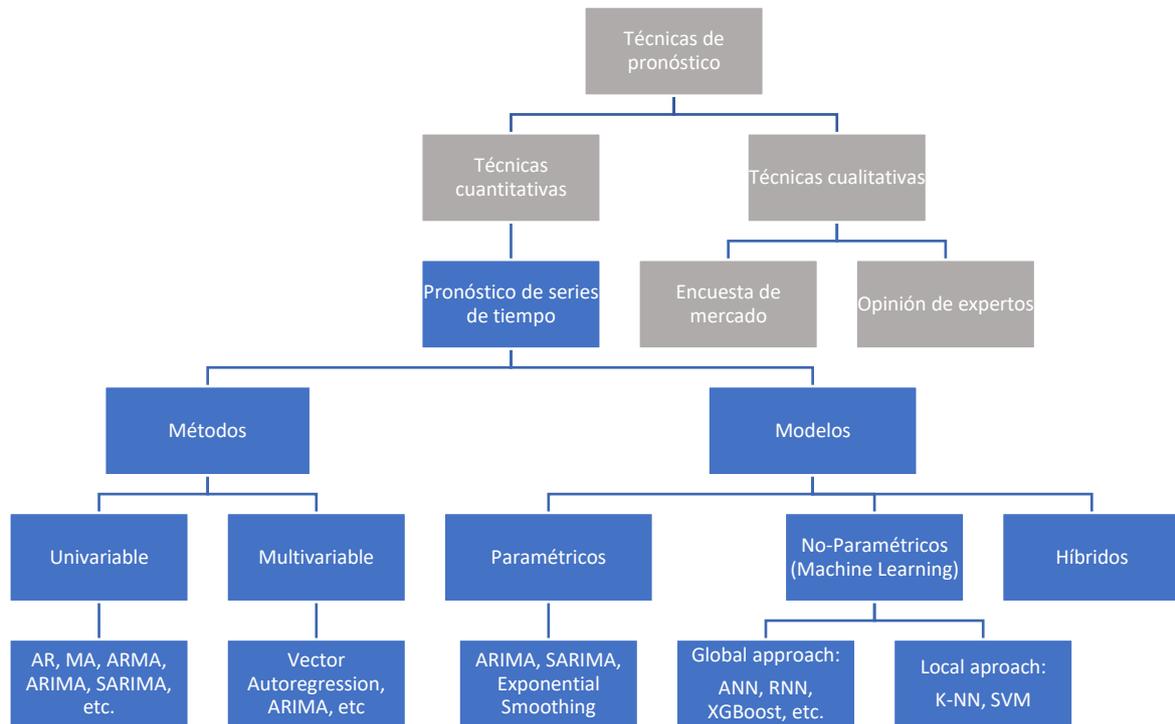
La serie de tiempo contine observaciones registradas de una única variable a lo largo del tiempo. Este método se caracteriza porque el pronóstico sólo depende de valores presentes y pasados de una variable.

ii) Método multivariable:

La serie de tiempo considera a dos o más variables observadas a lo largo del tiempo. Es decir, el pronóstico de los valores futuros depende de dos o más variables de series de tiempo, las cuales se les denomina variables explicativas o predictoras.

Figura 7.

Serie de tiempo: Clasificación de métodos y modelos predictivos.



Elaboración propia a partir de “*The analysis of time series: An introduction with R, 7th edition*” (Chatfield, 2019), “Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model” (Parmezan et al., 2019), y “*Short-Term Forecasting of Agriculture Commodities in Context of Indian Market for Sustainable Agriculture by Using the Artificial Neural Network*” (Mahto et al., 2021).

2.5.2 Modelos de pronóstico

Parmezan (2019) explica que los modelos de pronóstico de series de tiempo se agrupan según el conocimiento previo de la distribución de sus datos (ver **Figura 7**): (i) modelo paramétrico (*exponential smoothing* o basado en técnicas de autorregresión), (ii) modelo no-paramétrico (basado en algoritmos de Machine Learning), (iii) modelos híbridos (combinación de los anteriores).

Los modelos paramétricos necesitan conocer las propiedades de los datos de la serie de tiempo para construir el modelo de pronóstico (Parmezan et al., 2019). Por tanto, estos modelos dependen de los parámetros de la serie temporal. Se determina los parámetros para luego crear y optimizar la eficiencia en la predicción. Los principales algoritmos analíticos-estadísticos en este tipo de modelado son: ARIMA, SARIMA y *exponential smoothing*. Específicamente, ARIMA trabaja bajo una suposición: la serie de tiempo es estacionaria. Sin embargo, la mayoría de series de tiempo en entornos reales no son estacionarias; por el contrario, presentan no-linealidades a lo largo de los intervalos de tiempo. Ante este contexto,

los modelos con enfoque Machine Learning son de gran utilidad, debido a que no requieren este tipo de supuestos (series temporales estacionarias).

Los modelos no-paramétricos no requieren conocer las propiedades de los datos de la serie temporal para realizar el pronóstico. Estos modelos modelan el comportamiento de la serie de tiempo sin dependencia de los parámetros de los datos (Parmezan et al., 2019). Estos modelos emplean algoritmos de Machine Learning, los cuales son más adaptables, muestran un rendimiento confiable incluso cuando los datos temporales son complejos y presentan no linealidad. Ello favorece en la identificación de patrones del comportamiento de la serie de tiempo y el posterior pronóstico de valores futuros (Parmezan et al., 2019). Estos modelos de pronóstico trabajan con dos tipos de enfoques: (i) enfoque global, el cual utiliza todos los datos de la serie temporal para construir y entrenar el modelo, y (ii) enfoque local, el cual divide la serie de tiempo en sub-secuencias cuyos valores son cercanos entre sí y/o comparten propiedades similares que relacionan para pronosticar el valor futuro. Los principales algoritmos de Machine Learning en este tipo de modelado son: para tareas de regresión: ANN, RNN, XGBoost, etc; para tareas de *clustering* o clasificación: SVM, K-NN, etc.

2.6 Enfoque de análisis

Chatfield (2019) propone que el análisis de series de tiempo se basarse en cuatro objetivos: descripción, modelado, predicción, y control.

i) Descripción:

Busca conocer el comportamiento de los datos a través del tiempo. Para ello, es útil aplicar métodos estadísticos o elaborar graficar de las observaciones en cada intervalo de tiempo para realizar un análisis descriptivo-analítico, identificando tendencias (ascendente o descendente), estacionalidad, fluctuaciones irregulares, posibles “*outliers*”, etc.

ii) Modelado:

Centrado en construir un modelo adecuado para describir el comportamiento de serie de tiempo. Para un modelo univariable, se base sólo en valores pasados de una variable. Mientras que un modelo multivariable (dos o más variables), no solo toma en cuenta valores pasados de una variable, sino también de los valores presentes y pasados de otra (s) variable (s) predictora (s). En ese sentido, es posible que la variación de una serie de tiempo explique la variación de la otra serie de tiempo.

iii) Predicción:

A partir del modelo definido previamente, pronostica los siguientes valores de la serie temporal. Dado valores pasados, se calcula la predicción de valores futuros de la misma serie.

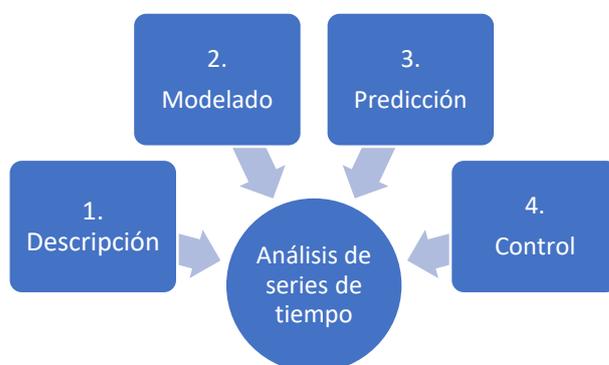
iv) Control:

Busca mantener un constante análisis de la serie de tiempo. Enfocado en la recopilación de los nuevos valores de la serie de tiempo y contrarrestarlos con los valores pronosticados del modelo predictivo para mejorar el control o supervisión de sistemas (físicos o económicos). En procesos de ingeniería, la predicción de los valores futuros ayuda a ajustar las variables de entrada del proceso para mantener los objetivos de control.

La **Figura 8** esquematiza el análisis de series de tiempo basado en la secuencia de sus cuatro objetivos principales.

Figura 8.

Serie de tiempo: objetivos para su análisis.



Elaboración propia a partir de *“The analysis of time series: An introduction with R, 7th edition”* (Chatfield, 2019).

2.7 Resumen

Este capítulo recopila conceptos fundamentales de las series de tiempo, tales como definición, tipología, componentes, principales áreas de aplicación, tipos de métodos y modelos de pronóstico, y objetivos de análisis de series temporales. La presente investigación explora una serie de tiempo del tipo marketing-ventas, considerando como variable temporal al volumen de exportación mensual de banano orgánico peruano. Los componentes de la serie de tiempo en estudio, estos son presentados en el Capítulo 6, Sección 6.2.4: tendencia, estacionalidad y residual.

Considerando las áreas de aplicación de las series de tiempo, la presente tesis está vinculada directamente a la tarea de predicción, el cual tiene la finalidad de identificar las dependencias y no-linealidades de los datos temporales para construir un modelo no-paramétrico capaz de pronosticar eficientemente los valores futuros de la serie de tiempo. Respecto al análisis de la serie de tiempo, la tesis aborda tres de los cuatro objetivos para el análisis de los datos temporales: describir, modelar y predecir.

En ese sentido, de acuerdo a lo presentado sobre el método de pronóstico, la presente investigación emplea un método univariable, debido a que la serie de tiempo sólo tiene una variable predictora. Finalmente, respecto al modelo de pronóstico, esta tesis contempla pronosticar los valores de la serie de tiempo de las exportaciones de banano orgánico, usando un modelo no-paramétrico basados en algoritmos de Machine Learning.



Capítulo 3

Fundamentos de Machine Learning y sus aplicaciones en la agricultura

Este capítulo presenta los fundamentos y principales aplicaciones de Machine Learning, como parte del marco teórico. En la sección 3.1 se repasa las definiciones generales de la Inteligencia Artificial y el Machine Learning. En la sección 3.2, se repasa el proceso del aprendizaje automático. Seguidamente, los tipos de aprendizaje automático y la clasificación de algoritmos de Machine Learning son descritos en la sección 3.3. Finalmente, en la sección 3.4, se presenta un panorama general sobre las aplicaciones de esta tecnología en la agricultura, describiendo las actuales áreas de investigación y sus principales desafíos futuros.

3.1 Definiciones

Esta sección presenta las definiciones de Inteligencia Artificial y de Machine Learning en base a diversos autores con la finalidad de tener un panorama amplio de la concepción de ambas tecnologías.

3.1.1 Inteligencia Artificial

Shukla et al. (2019), Dwivedi et al. (2019), y Abiodun et al. (2018) concluyen que la Inteligencia Artificial (IA) ha tomado vital importancia en las últimas décadas debido a la diversidad de aplicaciones en entornos reales. La IA es una área del conocimiento muy amplia, el cual comprende sub-áreas de conocimiento tales como *Machine Learning* (aprendizaje de máquina) y *Deep Learning* (aprendizaje profundo) (Abiodun et al., 2018; Dwivedi et al., 2019). En la **Figura 9**, se presenta un esquema básico de la interrelación que hay entre estas interesantes áreas de conocimiento dentro del campo de la IA.

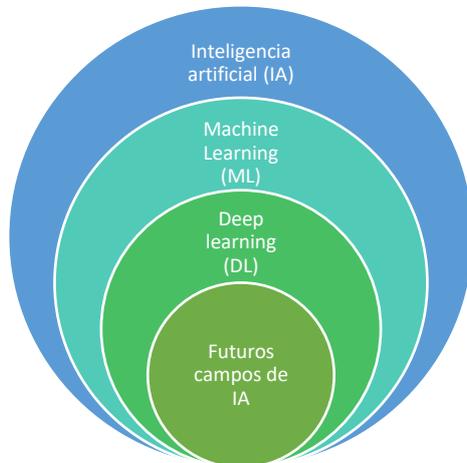
De acuerdo con Ben Ayed & Hanana (2021), la mayoría de las aplicaciones de la IA se enfocan en el Procesamiento de Lenguaje Natural (*Natural Language Processing, NLP*) para comprender la comunicación verbal humana, por ejemplo: el reconocimiento de voz humana, simulación de la visión humana (conversión de analógico a digital) usando la visión por computadora, y sistemas expertos para simular toma de decisiones. Debido a sus diversos campos de aplicación, a la fecha, no hay una definición universal para IA. No obstante, hay

definiciones similares propuestas por investigadores de la comunidad científica de IA alrededor del mundo. Todos coinciden que la finalidad de la IA está orientada a reducir la intervención humana y los esfuerzos humanos en los procesos y/o toma de decisiones. A continuación, se presenta las definiciones de IA más relevantes para la presente investigación:

- Kaplan & Haenlein (2019), citados por Dwivedi (2019), consideran que IA está vinculado a la capacidad de interpretar de forma independiente y aprender de datos externos para alcanzar resultados específicos a través de la adaptación flexible.
- Jha et al. (2019) define a la IA como aquel proceso por el cual el hombre hace una máquina inteligente. Asimismo, menciona que la IA debería de hacer un trabajo basado en el aprendizaje de comportamientos del pasado.
- Dwivedi et al. (2019) postula que la IA es la capacidad de las máquinas para realizar funciones y/o tareas específicas que realizan los seres humanos en un lugar de trabajo y la sociedad en general.
- Kouadio et al. (2018) se refiere a la IA como una automatización basada en modelos inteligentes para ayudar en el proceso de toma de decisiones.

Figura 9.

Inteligencia artificial: sub-áreas de conocimiento.



Tomado de "State-of-the-art in artificial neural network applications: A survey" (Abiodun et al., 2018).

3.1.2 Machine Learning

Abiodun et al. (2018) y Benos et al. (2021) explican que el Machine Learning (ML) o también llamado aprendizaje de máquina es uno de las sub área de conocimiento de la IA. De acuerdo con Abiodum et al. (2018), el ML se ha convertido en una tendencia de evolución digital, la cual hace que los procesos sean más eficientes y confiables. De acuerdo lo estudiado

por Pugliese et al. (2021), las aplicaciones de ML presentan un crecimiento exponencial durante los últimos 10 años en diversos sectores del entorno industrial, económico, social, y ambiental. Algunas de estas aplicaciones son las siguientes: manufactura inteligente, agricultura inteligente, reconocimiento de imágenes, reconocimiento de voz, vehículos automáticos, detección de fraude con tarjetas de crédito, detección de correos spam y virus, diagnóstico médico anticipado, educación, mercado financiero, gobierno de datos, marketing, etc. Actualmente, las aplicaciones de ML en entornos de agricultura se han diversificado y especializado en procesos relacionados a la cadena de suministro agro-inteligente (Bontempi et al., 2013; Kumar et al., 2021; Meshram et al., 2021; Sharma, Kamble, et al., 2020).

La tecnología ML ofrece diseñar procesos con mayor flexibilidad para implementarlos en sistemas ciber-físicos (mecánicos, eléctrico, hidráulico, térmico, etc.) como soporte a la toma de decisiones debido a que no requieren condiciones iniciales para la simulación del sistema (Kouadio et al., 2018; Pugliese et al., 2021). A continuación, se presenta las definiciones de ML más relevantes para la presente investigación:

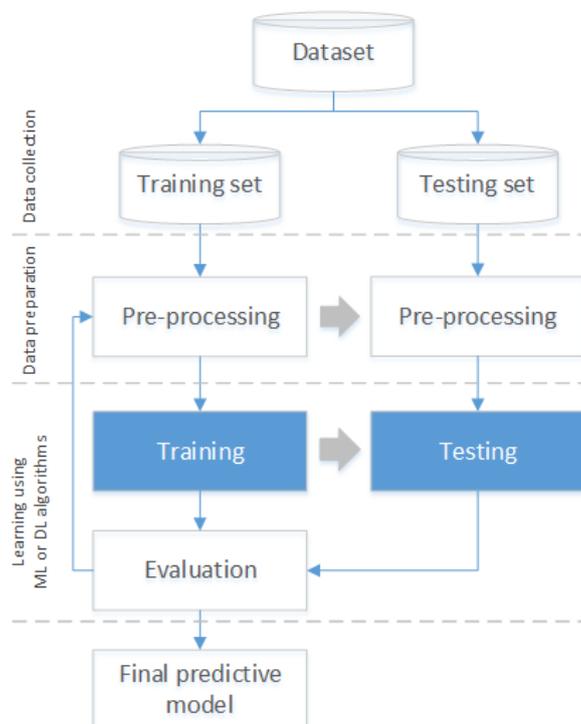
- Mohri et al. (2018), citado por Sharma et al. (2020), define al ML como el estudio científico de algoritmos y modelos matemáticos en computadoras usando eventos históricos para mejorar progresivamente el desempeño en una tarea específica o para hacer pronósticos precisos.
- Boutaba et al. (2018) consideran que ML se caracteriza por analizar datos del pasado e inferir conocimiento a partir de ellos. Es decir, explorar los datos para identificar patrones ocultos en el dataset de entrenamiento. Estos patrones aprendidos se usarán posteriormente para analizar datos desconocidos
- Jha et al. (2019) postulan que el ML tiene un enfoque matemático, el cual comprende el acto de proporcionar datos estadísticos y/o experiencias pasadas a una máquina para que identifique patrones y pueda resolver un problema en específico, tales como reconocimiento de voz y rostro, diagnósticos médicos, y predicción del procesos.
- Benos & Hanana (2021) se refiere al ML como una tecnología que ayuda a las personas a trabajar de manera más creativa y eficiente. Mediante el uso de métodos estadísticos y matemáticos, el ML aprender de conjuntos de datos para realizar predicciones y/o tomar decisiones basadas en datos.

3.2 Proceso general del aprendizaje automático

Diversos autores (Benos et al., 2021; Liakos et al., 2018; Sharma, Kamble, et al., 2020; Zhou et al., 2017) explican que el proceso de aprendizaje con algoritmos de ML está compuesto por cuatro fases: (1) recopilación de datos, (2) preparación de datos, (3) modelado

(aprendizaje mediante algoritmos de ML o DL), y (4) evaluación. La **Figura 10** esboza la secuencia de estas fases y el flujo de datos entre ellas.

Figura 10.
Machine Learning: Flujograma del aprendizaje automático.



Adaptado de “*Machine learning in agriculture: A comprehensive updated review*” (Benos et al., 2021).

La primera fase comprende la medición de variables y la recopilación histórica de sus valores usando diversas fuentes de información. La segunda fase, se enfoca en la preparación o el preprocesamiento de los datos: transformación y preparación para usarlos como datos entrada de la siguiente fase. La tercera fase, el modelado, consiste en seleccionar los algoritmos de aprendizaje más adecuado (técnicas ML o DL), así como ajustar los parámetros del modelo para descubrir información (*insight*) y hacer predicciones con el mínimo error posible (Mohri et al., 2018). Finalmente, el proceso de aprendizaje automático incluye un proceso de evaluación, cuarta fase, el cual calcula el rendimiento del modelo, usando métricas de error. La evaluación del modelo de ML ayudan a optimizar los hiper-parámetros del modelo para lograr un rendimiento óptimo (Benos et al., 2021; Zhou et al., 2017). No obstante, construir un modelo predictivo de alto rendimiento es un desafío para investigadores (Dwivedi et al., 2019; Kamilaris & Prenafeta-Boldú, 2018; Liakos et al., 2018).

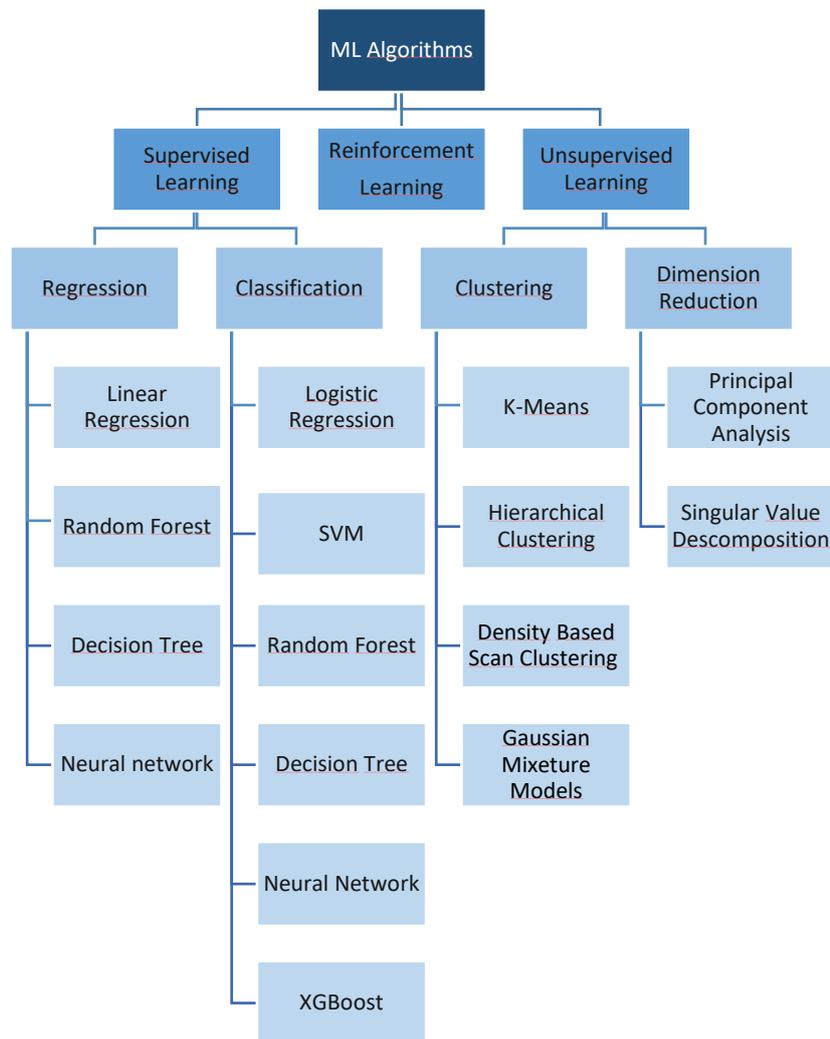
3.3 Tipos de aprendizaje y algoritmos

Pugliese et al. (2021) y Benos et al. (2021) explican que el aprendizaje automático de los algoritmos de ML se clasifica en tres categorías: aprendizaje supervisado, aprendizaje no supervisado, y aprendizaje reforzado. En el campo de ML, el método de aprendizaje supervisado es el más usado por la comunidad científica.

En la **Figura 11**, se presenta un desglose de la clasificación de los algoritmos más populares según su tipo de aprendizaje.

Figura 11.

Machine Learning: Clasificación de los algoritmos.



Elaborado a partir de “*Machine learning-based approach: Global trends, research directions, and regulatory standpoints*” (Pugliese et al., 2021).

A continuación, se describe cada uno de los tres tipos de aprendizaje automático:

El aprendizaje supervisado se caracteriza por realizar predicciones futuras usando un dataset etiquetado: tanto *inputs* y *outputs* (Pugliese et al., 2021). Por etiquetado se entiende que los outputs del dataset son datos conocidos. Este tipo de aprendizaje está orientado a la tarea: regresión y clasificación. Entre los algoritmos de regresión están: árbol de decisiones, regresión lineal (simple o múltiple), redes neuronales, y *random forest*. Por otro lado, algunos de los algoritmos de clasificación son: regresión logística (binaria o multiclase), árbol de decisión, *random forests*, redes neuronales, y *support vector machine* (SVM).

El aprendizaje no supervisado está orientado a los datos; logra construir un modelo que infiere una tendencia del conjunto de datos (Pugliese et al., 2021). Se caracteriza porque por usar un dataset no etiquetado (se desconoce el valor de los outputs). En este tipo de aprendizaje se encuentran dos clases algoritmos de ML: *clustering* (agrupamiento) y reducción de dimensionalidad. Algunos algoritmos de *clustering* son los siguientes: *K-means*, *K-Nearest Neighbor*, y *clustering* jerárquico y no jerárquico. Mientras que los algoritmos de reducción de dimensionalidad son: análisis de componentes principales (PCA⁹), descomposición de valor singular (SVD¹⁰).

El aprendizaje reforzado está orientado a aprender al reaccionar al entorno (Benos et al., 2021). Se caracteriza porque el modelo aprende por su cuenta. El modelo recibe una recompensa o una penalización por cada acción que realice. Es decir, con este sistema de recompensas el modelo logrará acercarse a predecir el mejor resultado posible.

3.4 Aplicaciones en la agricultura

En esta sección se presenta un panorama general de las aplicaciones de la tecnología ML en el campo de la agricultura. En este contexto, la difusión y la implementación de tecnologías como *Internet of Things* (IoT) y *Big Data* han facilitado que la ML desarrolle aplicaciones más pragmáticas para los procesos de la cadena de suministro agrícola (Benos et al., 2021; Liakos et al., 2018; Meshram et al., 2021; T. U. Rehman et al., 2019; Sharma, Kamble, et al., 2020).

3.4.1 Áreas de investigación

Como resultado de una amplia revisión de la literatura, la **Figura 12** presenta las principales áreas de investigación de ML en la agricultura:

Elavarasan et al. (2018) explica que los casos prácticos de las aplicaciones de ML en la agricultura se inclinan por atender necesidades reales. Consecuentemente, las áreas de investigación que se han venido desarrollando más frecuentemente son las siguientes: (i)

⁹ Principal Component Analysis

¹⁰ Singular Value Descomposition

estimación de rendimiento de cultivo, (ii) identificación de enfermedades del cultivo, (iii) detección de malezas en plantas, (iv) reconocimiento de variedades de plantas, (v) predicción de factores agro-climáticos.

Benos et al. (2021) postula que la tecnología ML se utiliza para facilitar la gestión operativa en la agricultura. Por tal, agrupa las aplicaciones de Machine Learning en la agricultura en cuatro *clusters*: (i) gestión del cultivo (el cual comprende pronóstico de rendimiento de cultivo, detección de enfermedades, detección de plagas, reconocimiento de cultivo, y calidad de cultivo), (ii) gestión de agua, (iii) gestión de suelo, y (iv) gestión del ganado (bienestar de los animales y producción ganadera).

Desde un enfoque más amplio, Sharma et al. (2020) y Meshram et al. (2021) describen las áreas de investigación del ML en agricultura en base a las etapas de la cadena de suministro: (i) pre-cosecha (monitoreo del suelo, gestión de pesticidas, detección de malezas, detección de enfermedades, gestión de riego), (ii) cosecha (detección de edad de madurez, reconocimiento de firmeza, clasificación de tamaño y color, y predicción de rendimiento), (iii) pos-cosecha (vida útil, clasificación de la fruta, temperatura, y humedad), (iv) procesamiento (gestión de la demanda y producción), y (v) distribución (gestión de transporte, de inventario, y análisis del consumidor).

Figura 12.

Machine Learning en la agricultura: Áreas de investigación en la cadena de suministro.

Pre-harvest	Harvest	Post-Harvest	Processing	Distribution
<ul style="list-style-type: none"> •Soil •Seed •Environmental •Pesticide •Weed detection •Disease detection •Irrigation 	<ul style="list-style-type: none"> •Fruit detection and classification •Maturity age •Firmness •Size •Skin color •Yield prediction 	<ul style="list-style-type: none"> •Shelf-life •Temperature •Quality •Fruit grading •Humidity 	<ul style="list-style-type: none"> •Demand Management •Production Management 	<ul style="list-style-type: none"> •Exportation •Transportation •Storage •Inventory •Retailing •Consumer analysis

Elaborado a partir de “*Machine learning in agriculture domain: A state-of-art survey*” (Meshram et al., 2021), “*A systematic literature review on machine learning applications for sustainable agriculture supply chain performance*” (Sharma, Kamble, et al., 2020), “*Machine learning in agriculture: A comprehensive updated review*” (Benos et al., 2021) y “*Forecasting yield by integrating agrarian factors and machine learning models: A survey*” (Elavarasan et al., 2018).

3.4.2 Desafíos futuros

De acuerdo con el estudio de Pugliese et al. (2021), uno de los desafíos de la ML en la agricultura es desarrollar herramientas con tecnología ML accesible para mitigar los grandes

retos a nivel mundial, tales como: el cambio climático, el cultivo excesivo, contaminación, entre otros. Los autores proponen que el ML debe estar orientado a fomentar una industria agro-tecnológica inteligente y sostenible, la cual contemple toma de decisiones más precisas y rápidas para alimentar la creciente población mundial del futuro.

El estudio de Elavarasan et al. (2018) propone lineamientos sobre los desafíos de investigación en escenarios futuro de la agricultura con intervención del ML: monitoreo y prevención del cultivo frente a plagas y malezas, sistema de recomendación de fertilizantes para optimizar el rendimiento del cultivo, control y monitoreo de calidad del suelo, y modelos de optimización mediante enfoque híbrido. Asimismo, el estudio enfatiza desarrollar aplicaciones con tecnología de ML para alcanzar una cadena de suministro agro-inteligente, mediante: (i) modelos que analicen en tiempo real los datos del mercado oferta/demanda para facilitar el margen de ganancia por transacción compra-venta, (ii) modelos de gestión de riesgo crediticio, asegurando una operación de bajo riesgo al superar problemas de incumplimiento crediticio.

3.5 Resumen

Este capítulo recopila conceptos básicos y claves del Machine Learning. La presente investigación explora una serie de tiempo a través del proceso general de aprendizaje automático, el cual fue presentado en este capítulo. El modelado de la serie de tiempo seguirá los lineamientos del aprendizaje supervisado, debido a que es una tarea de regresión: pronóstico de valores futuros en base a datos pasados (conocidos y etiquetados).

La presente tesis doctoral estudia las cuatro fases del proceso de aprendizaje automático. En particular, este estudio trabaja a profundidad la fase tres (encontrar el mejor modelo predictivo, y sus hiper-parámetros respectivos) y fase cuatro (comparativa de los resultados de performance del modelo predictivo). En este sentido, el algoritmo que se entrenará para concretar el pronóstico la serie de tiempo en estudio es la red neuronal artificial, específicamente una red neuronal recurrente.

Este capítulo también detalló las áreas de investigación de ML en la la cadena de suministro y los desafíos futuros del ML en la agricultura. La presente investigación se ubica en la etapa de procesamiento y considera el área de investigación relacionada a la gestión de demanda, debido a que se propone desarrollar un modelo para pronosticar la demanda internacional de banano orgánico del Perú, usando algoritmos de ML.

Asimismo, la presente tesis doctoral se enmarca en el desafío de investigación: cadena de suministro agro-inteligente y sostenible. En consecuencia, la presente tesis tiene como finalidad contribuir a maximizar la atención de demanda del banano orgánico mediante la disposición de datos prospectivos a la mano que optimicen la toma de decisiones de forma más rápidas y precisas.

Capítulo 4

Redes Neuronales Artificiales para el pronóstico de series de tiempo

Este capítulo, como parte del marco teórico, presenta los fundamentos de las redes neuronales artificiales implementadas para el pronóstico de series de tiempo. En la sección 4.1, se repasa los conceptos relacionados al modelado de series temporales, explicando los fundamentos de datos secuenciales, usando algoritmos del aprendizaje supervisado, las estrategias de pronóstico y el horizonte de retrospectivo para series de tiempo. Seguidamente, en la sección 4.2, se describe los fundamentos matemáticos de tres tipos de Redes Neuronales Artificiales para modelar series temporales: Red Neuronal Recurrentes (RNN), *Long Short-Term Memory Network* (LSTM) y *Gated Recurrent Unit* (GRU). Finalmente, en la sección 4.3, se repasa los lineamientos para la optimización de hiper-parámetros de redes neuronales artificiales.

4.1 Modelado de series de tiempo

En esta sección, se presenta los conceptos relacionados al el modelado y pronóstico de series de tiempo usando algoritmos de aprendizaje supervisado. Asimismo, se explica la relevancia de seleccionar adecuadamente la estrategia de pronóstico y el horizonte retrospectivo para el modelado secuencial.

4.1.1 Datos secuenciales

Hyndman & Athanasopoulos (2021) y Chatfield (2019) definen a una serie de tiempo como una secuencia temporal de valores; es decir, es una secuencia de observaciones en orden cronológico que son registrados en intervalos de tiempo fijos. Ver Apéndice 2 para entender la definición de los datos secuenciales y las aplicaciones de este tipo de modelado.

El modelado de series de tiempo es considerado como una aplicación del modelado secuencial (Shickel & Rashidi, 2020). El modelado secuencial, también conocido como *sequential learning*, es aquel modelo de *Machine Learning* o *Deep Learning* que utilizan datos de secuencias (*inputs* y *outputs*) (Bontempi et al., 2013; Shickel & Rashidi, 2020). El modelado de datos secuenciales tiene como objetivo predecir qué valor viene a continuación en la

secuencia temporal (número, letra, elemento, etc). El principal atributo del modelo secuencial consiste en que los datos, con los que se trabaja para entrenar el modelo, dependen uno del otro debido a la naturaleza de su orden secuencial (Fang & Yuan, 2019).

4.1.2 Aprendizaje supervisado

Por mucho tiempo el modelado de las series de tiempo han empleado métodos estadístico clásicos, tales como ARIMA, SARIMA, etc. (Hajirahimi & Khashei, 2019). Sin embargo, la no linealidad de los datos ha limitado la precisión del pronóstico. Ante este contexto, los algoritmos de ML resultaron ser más eficientes para modelar y predecir los valores futuros de la serie de tiempo considerando los valores pasados (Hewamalage et al., 2021; Lara-Benítez et al., 2021).

Bontempi et al. (2013) afirma que la serie de tiempo es estudiada como una tarea de aprendizaje supervisado, el cual consiste en modelar, sobre la base de un conjunto finito de observaciones, la relación entre un conjunto de variables de entrada (inputs) y una o más variables de salida (outputs), que se consideran dependientes de las entradas. En ese sentido, una observación de un paso de tiempo anterior de los datos secuenciales puede servir para estimar la observación del siguiente paso de tiempo, como si fuera la salida (output) de un modelo de aprendizaje supervisado (Parmezan et al., 2019). Ello se logra en base a las técnicas de ventanas deslizantes del horizonte de tiempo (ver Capítulo 4, Sección 4.1.4).

4.1.3 Modelo predictivo

Fang & Yuan (2019) propone esta expresión matemática para entender el modelado y pronóstico de series de tiempo, usando algoritmos de ML:

Dado un modelo determinístico M , el cual tiene como objetivo aprender patrones de una secuencia de datos de entrada $X = \{x_1, x_2, x_3, \dots, x_T\}$ para pronosticar la secuencia de valores futuros \hat{Y} :

$$\hat{Y} = M(X) + \varepsilon$$

$$(\hat{y}_{T+1}, \hat{y}_{T+2}, \dots, \hat{y}_{T+H}) = M(x_1, x_2, \dots, x_T) + \varepsilon$$

Donde:

X es conjunto de datos de la serie temporal.

T cantidad total de muestras de X para entrenar el modelo M .

H es el horizonte de predicción deseado.

\hat{X} es el conjunto de datos pronosticados por el modelo M .

ε es el error de predicción asociado con la performance del modelo M .

Se sugiere revisar las definiciones de series de tiempo presentadas en el Capítulo 1, Sección 2.1.

4.1.4 Estrategias de pronóstico

Bontempi et al. (2013) y Fang & Yuan (2019) proponen dos tipos de estrategias de pronóstico para modelar series de tiempo: *one-step ahead* y *multi-step ahead*. A continuación, se explican los fundamentos teóricos de cada una de estas estrategias:

i) Pronóstico de un único-paso de tiempo (*one-step ahead*):

En la estrategia de pronóstico a un único-paso, el objetivo de salida es solo un paso de tiempo de la serie temporal. Ver **Figura 13**. Es decir, dado un conjunto de datos de entrenamiento $X = \{x_1, x_2, \dots, x_T\}$, sólo se tiene una única etiqueta para pronosticar $\hat{Y} = \{y_{T+1}\}$:

$$\hat{y}_{T+1} = M(x_1, x_2, \dots, x_T) + \varepsilon$$

Donde:

$$x_i, \hat{y}_{T+1} \in \mathbb{R}$$

\hat{y}_{T+1} es la estimación del siguiente valor real a pronosticar, considerando los T valores pasados de la serie temporal (horizonte retrospectivo).

Figura 13.

Estrategia de pronóstico: one-step ahead.



Adaptado de “*Recurrent Neural Networks for Time Series Forecasting: Current status and future directions*” (Hewamalage et al., 2021)

ii) Pronóstico de múltiples-pasos de tiempo (*multi-step ahead*):

En la estrategia de pronóstico a múltiples-pasos, el objetivo de salida es predecir los próximo H valores $\hat{Y} = \{\hat{y}_{T+1}, \hat{y}_{T+2}, \dots, \hat{y}_{T+H}\}$ de una serie temporal histórica $X = \{x_1, x_2, \dots, x_T\}$ compuesta por T observaciones (horizonte retrospectivo), donde $H > 1$ denota el horizonte de pronóstico. Ver **Figura 14**. Es decir, en el pronóstico de múltiples-pasos se tiene varias etiquetas de salida:

$$(\hat{y}_{T+1}, \hat{y}_{T+2}, \dots, \hat{y}_{T+H}) = M(x_1, x_2, \dots, x_T) + \varepsilon$$

Donde:

$$x_i, \hat{y}_i \in \mathbb{R}$$

$\hat{y}_i \in (\hat{y}_{T+1}, \hat{y}_{T+2}, \dots, \hat{y}_{T+H})$ es la estimación de los siguientes H valores futuros de la serie de tiempo en intervalos de tiempo futuros desde $T + 1$ hasta $T + H$, considerando los T valores pasados de la serie temporal (horizonte retrospectivo).

Figura 14.

Estrategia de pronóstico: multi-step ahead.



Adaptado de “Recurrent Neural Networks for Time Series Forecasting: Current status and future directions” (Hewamalage et al., 2021)

4.1.5 Horizonte retrospectivo (*look back*)

De acuerdo a la literatura, el pronóstico de una serie de tiempo es un área de investigación con mayores retos en la ciencia de datos porque necesita mirar hacia atrás los datos históricos para estimar, con precisión, lo que podría suceder a futuro.

El horizonte retrospectivo (o también llamado *look back*) define cuántos datos temporales anteriores se requiere utilizar para predecir el período de tiempo posterior. El tamaño de este horizonte retrospectivo puede tomar cualquier valor igual o superior a 1. Por ejemplo, potencia de 2: 2, 4, 6, 8, etc. Sin embargo, mientras más grande sea el tamaño del

horizonte retrospectivo, se necesitarán más registros del pasado para realizar las proyecciones.

De acuerdo con Cerqueira et al. (2020) sobre la configuración de pronóstico de series de tiempo se requiere definir el horizonte retrospectivo, el cual contiene los valores predictores:

Dado a serie de tiempo S , se selecciona un conjunto de datos para entrenamiento Y (*training set*). La notación matemática de la matriz Y es la siguiente:

$$Y_{[t,p]} = \begin{bmatrix} y_1 & y_2 & \dots & y_{p-1} & y_p & y_{p+1} \\ y_{i-p+1} & y_{i-p+2} & \dots & y_{i-1} & y_i & y_{i+1} \\ y_{t-p+1} & y_{t-p+2} & \dots & y_{t-1} & y_t & y_{t+1} \end{bmatrix}$$

Donde:

t , es la cantidad de datos para entrenamiento

p , es el horizonte retrospectivo

En ese sentido, tomando la primera fila: el valor a predecir es y_{p+1} y sus predictores son los p valores previos (y_1, y_2, \dots, y_p) . Se asume que no hay dependencia de tiempo mayores que p .

4.2 Redes neuronales para series de tiempo

Faruk (2010), citado por Fang & Yuan (2019), afirma que los científicos han estado desarrollando y validando diversos tipos de algoritmos de aprendizaje para el pronóstico de series de tiempo. Particularmente, las redes neuronales artificiales clásicas han evolucionado durante los últimos años, con arquitecturas cada vez más sofisticadas para obtener mayor precisión en la predicción de series temporales.

Lata-Benítez et al. (2021) propone tres tipos de arquitecturas para las redes neuronales artificiales que modelan datos secuenciales: (i) Red neuronal full-conectada (*feed-forward*), (ii) Red neuronal recurrente, y (iii) Red neuronal convolucional. La **Tabla 1** presenta la clasificación de seis algoritmos de redes neuronales artificiales según la clasificación en mención.

Hewamalage et al. (2021) explica que la red neuronal full-conectada solo tiene conexiones directas entre las neuronas, mientras que la red neuronal recurrente tienen flujos de retroalimentación de información, también llamados “estados de recurrencia” o “celdas de memoria”. La **Figura 15** esquematiza esta idea, mediante la arquitectura neuronal.

Tabla 1.

Tipos de redes neuronales para análisis de series de tiempo.

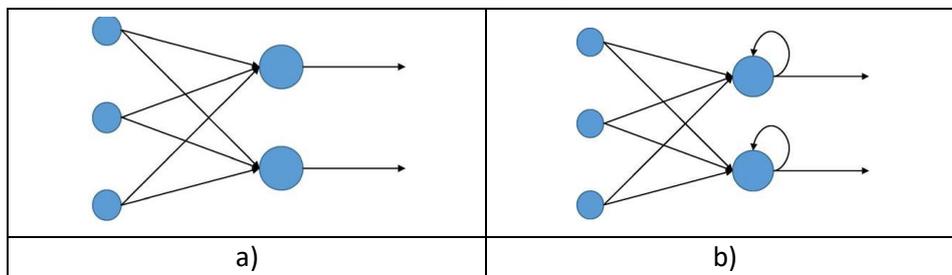
Clasificación	Red neuronal artificial	Propuesto por (autor, año) para el modelado de series temporales
Full-conectada	MLP: <i>Multi-Layer Perceptron</i>	(Faruk, 2010),
Recurrente	ERNN: <i>Elman Recurrent Neural Network</i>	(Elman, 1990)
	LSTM: <i>Long Short-Term Memory Network</i>	(Hochreiter & Schmidhuber, 1997)
	GRU: <i>Gated Recurrent Units Network</i>	(Cho et al., 2014)
Convolutiva	CNN: <i>Convolutional Neural Network</i>	(Gamboa, 2017)
	TCN: <i>Temporal Convolutional Network</i>	(Bai et al., 2018)

Adaptado de “An Experimental Review on Deep Learning Architectures for Time Series Forecasting” (Lara-Benítez et al., 2021) y “Recurrent Neural Networks for Time Series Forecasting: Current status and future directions” (Hewamalage et al., 2021)

A continuación, se explica a profundidad tres tipos de Redes Neuronales Artificiales, las cuales son implementadas en la presente tesis: *Recurrent Neural Network* (RNN), *Long Short-Term Memory Network* (LSTM) y *Gated Recurrent Unit* (GRU). De manera general, la **Figura 16** presenta las principales diferencias en la arquitectura y la dinámica de la celda de memoria de cada una de estas redes neuronales.

Figura 15.

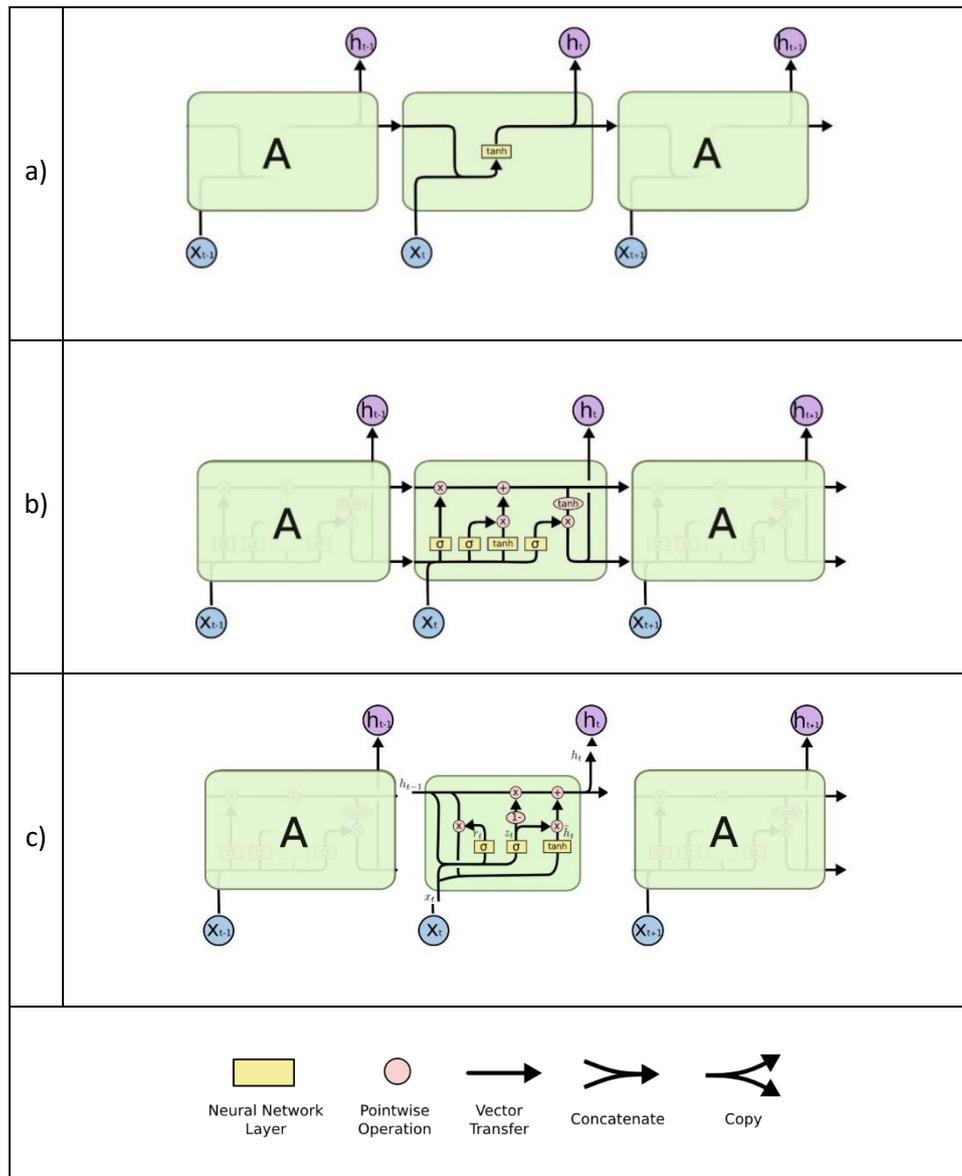
Arquitectura de una (a) red neuronal artificial y (b) red neuronal recurrente.



Adaptado de “Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model” (Parmezan et al., 2019)

Figura 16.

Estructura de tres tipos de redes neuronales recurrentes: a) estándar, b) LSTM, c) GRU.



Elaborado a partir de "Recurrent Neural Networks and ARIMA models for euro/dollar exchange rate forecasting" (Escudero et al., 2021).

4.2.1 RNN - Recurrent Neural Network

Una Red Neuronal Recurrente, o también llamada *Recurrent Neural Network* (RNN) por sus siglas en inglés, es una variación de la red neuronal artificial del tipo *feed-forward* para datos dependientes de tiempo (Lara-Benítez et al., 2021).

La RNN conecta los valores en cada paso de tiempo con los valores anteriores para modelar la dependencia temporal de los datos, lo cual es el principal atributo intrínseco de las RNN para datos secuenciales (Lara-Benítez et al., 2021). Este atributo le permite resolver eficientemente problemas con no-linealidades temporales (Mateus et al., 2021). De acuerdo con lo definido por Parmezan et al. (2019), la RNN tiene la funcionalidad de recordar una secuencia de datos, y guardarlos por varias instancias de tiempo para luego pronosticar datos posteriores o futuros.

De manera general, una RNN está conformada por una combinación de un número de “celdas de memoria” o “unidades de recurrencia” en su arquitectura, las cuales transmiten información de un paso de la red al siguiente (Hewamalage et al., 2021). Esta arquitectura se basa en la capa de entradas, el número de capas recurrentes apiladas, el número de unidades recurrentes en cada capa, y la capa de salida (Lara-Benítez et al., 2021). Esta estructura evidencia una fuerte interrelación entre ellas.

Una RNN tiene un estado oculto h_t (celda de memoria) y un output intermedio en forma de variable secuencial $x = (x_1, x_2, x_3, \dots, x_t)$ en cada paso de tiempo t . Este estado oculto de la RNN se actualiza mediante la siguiente definición matemática (Cho et al., 2014):

$$h_t = f(h_{t-1}, x_t)$$

Donde: f es una función de activación no lineal.

Una RNN aprende en base a la distribución de probabilidad de los datos secuenciales, entrenándose para predecir el siguiente valor de la secuencia. La salida de cada intervalo de tiempo t (*timestep*) sigue la siguiente distribución $p(x_t | x_{t-1}, \dots, x_1)$. Por ejemplo, una distribución multinomial puede usar una función de activación *softmax*, Para todos los valores de la secuencia $j = 1, \dots, K$ (Cho et al., 2014):

$$p(x_{t,j} = 1 | x_{t-1}, \dots, x_1) = \frac{\exp(w_j h_{(t)})}{\sum_{j=1}^K \exp(w_j h_{(t)})}$$

Donde: w_j son las filas de una matrix de tamaño W . Entonces, la probabilidad de los datos secuenciales se calcula mediante la siguiente expresión:

$$p(x) = \prod_{t=1}^T p(x_t | x_{t-1}, \dots, x_1)$$

En este sentido, arquitectura de RNN se entrena a partir de esta distribución, muestreando iterativamente el valor de la secuencia en cada *timestep* t . La finalidad de ello,

es comprender la probabilidad de que un *timestep* t siga al valor *timestep* $t - 1$. Similarmente, se calcular la probabilidad para que el valor $t + 1$ siga al valor t . Por tal, cada vez que la red reciba una nueva secuencia de datos, determina la probabilidad del siguiente valor basada en la probabilidad del anterior.

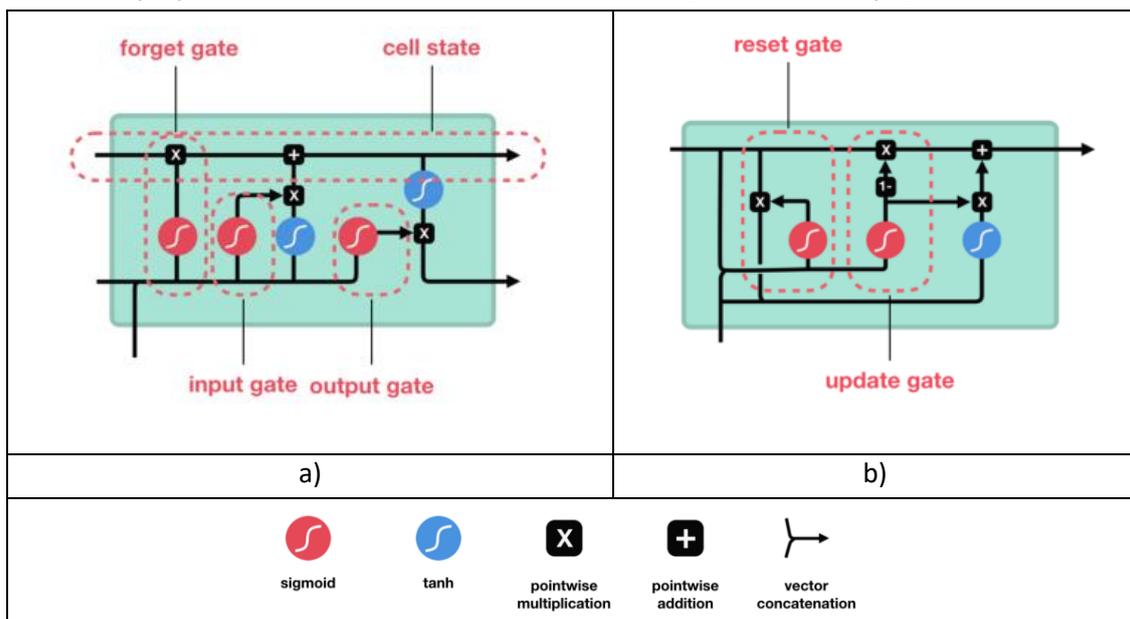
4.2.2 LSTM - Long Short-Term Memory Network

La red neuronal memoria a corto y largo plazo, o también llamada *Long Short-Term Memory Network* (LSTM) por sus siglas en inglés, es un tipo de RNN. Es ese sentido, la red LSTM sigue la estructura de cadena de celdas de memoria. Su principal característica consiste en que dentro de la celda de memoria tiene componentes que interactúan entre sí antes de pasar a la siguiente celda de memoria (Yu et al., 2022).

La **Tabla 2** describe a detalle el funcionamiento de la celda de memoria de una red LSTM y sus respectivas compuertas (Yu et al., 2022). La línea horizontal (c_{t-1}, c_t) de la parte superior es muy importante, pues transmite información y atraviesa todos los módulos a lo largo de la cadena. Una red LSTM tiene la capacidad de regular la información (agregándola o restringiéndola) usando unas compuertas, las cuales están conformadas por una capa de red neuronal sigmoidea como función de activación (0: no deja pasar información; 1: pasa información). Estas compuertas aparecen 3 veces en cada celda de memoria. La **Figura 17 a)** presenta un esquema de la dinámica de estas compuertas dentro de la celda de memoria en la red LSTM.

Figura 17.

Similitudes y diferencias entre una celda de memoria de a) una red LSTM y b) una red GRU.



Adaptado de “Recurrent Neural Networks for Time Series Forecasting: Current status and future directions” (Hewamalage et al., 2021).

Tabla 2.

Red neuronal LSTM: Interacciones dentro de una celda de memoria.

Esquema	Representación matemática	Función	Descripción
	$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$	Decidir qué información pasa	La capa neuronal sigmoidea (f_t) define: 0: no pasa información 1: pasa información
	$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i)$ $g_t = \tanh(W_G[h_{t-1}, x_t] + b_g)$	Decidir qué información es actualizada o se almacena como nueva	Hay dos capas de neuronas: Sigmoidea (i_t): decide qué valor es actualizado Tangente Hiperbólica (g_t): almacena valores nuevos. Posteriormente, ambos resultados son multiplicados. Para actualizar el estado de la celda (C_t).
	$C_t = f_t \times C_{t-1} + i_t \times g_t$	Actualizar el estado de la celda	El nuevo estado de la celda C_t está dado por la suma de: La multiplicación del estado de la celda anterior (C_{t-1}) a la nueva celda (C_t) Y la multiplicación de la capa sig (i_t) y $\tanh(g_t)$.
	$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$ $h_t = o_t \times \tanh(C_t)$	Decidir el valor de la salida de la celda (h_t)	La salida de la celda (h_t) es definida por la multiplicación de: El estado de la celda (C_t) filtrada por una capa \tanh . Y el valor de (o_t), el cual es el resultado de la salida de la celda anterior (h_{t-1}) a través de la capa sigmoide.

Adaptado de "Recurrent Neural Networks for Time Series Forecasting: Current status and future directions" (Hewamalage et al., 2021).

4.2.3 GRU – Gated Recurrent Unit

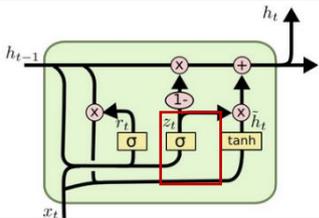
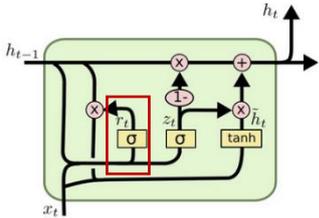
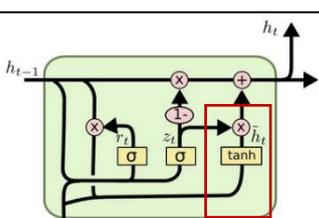
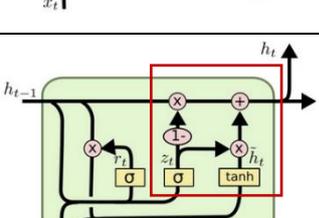
En la actualidad, hay diversas variantes de la unidad de memoria LSTM. La más popular es *Gated Recurrent Unit* (GRU). Lara-Benítez et al. (2021) asegura que la red GRU contribuye en dar solución a una de los problemas de la RNN: desvanecimiento del gradiente (*Vanishing Gradient Problem*), lo cual repercute en el aprendizaje del algoritmo.

La **Figura 17 b)** presenta un esquema de la dinámica las compuertas dentro de la celda de memoria en la red GRU. La red neuronal GRU presenta un mejor rendimiento que la red

LSTM en modelos predictivos con dataset pequeños (Hewamalage et al., 2021). La **Tabla 3** se describen las ecuaciones matemáticas presenten las celdas de memoria de una red GRU, las cuales son actualizadas cada paso de tiempo.

Tabla 3.

Red neuronal GRU: Interacciones dentro de una celda de memoria.

Esquema	Representación matemática	Función	Descripción
	$z_t = \sigma(W_z \cdot [h_{t-1}, x_t])$	Actualización	Actualiza la compuerta z_t en cada <i>timestep</i> t
	$r_t = \sigma(W_r \cdot [h_{t-1}, x_t])$	Reinicio	Decide qué cantidad de la información debe ser olvidada o eliminada.
	$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t])$	Contenido actual de memoria	Presenta el nuevo contenido de memoria que utilizará la puerta de reinicio para almacenar la información relevante del pasado.
	$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t$	Memoria final en el paso de tiempo actual	Calcula el valor de salida de la red, considerando el valor actual de la celda y el valor del pasado.

Adaptado de "Recurrent Neural Networks for Time Series Forecasting: Current status and future directions" (Hewamalage et al., 2021).

Una red GRU está conformada por una capa de entrada, capas ocultas y una capa de salida. La capa oculta alberga celdas de memoria, las cuales están definidas por dos elementos en el proceso de entrenamiento y predicción a través de datos secuenciales: la puerta de actualización (update) y la puerta de reinicio (reset).

i) Puerta de actualización (update gate): z_t

Encargada de controlar la información que transita en la celda de memoria. Es decir, es la responsable de actualizar los pesos y eliminar el problema del *Vanishing Gradient*. Como

el modelo puede aprender por sí mismo, continuará actualizando la información para pasarla al futuro.

ii) Puerta de reinicio (reset gate): r_t

Actúa de manera opuesta, pues se encarga de controlar la información que sale de la celda de memoria. Es decir, decide qué parte de la información pasada debe olvidarse, dado el estado actual.

4.3 Optimización de hiper-parámetros

Respecto al entrenamiento de las redes neuronales recurrentes, toma relevancia el rol de los hiperparámetros en el proceso de aprendizaje supervisado y la optimización de los mismos.

Hewamalage et al. (2021) sugiere realizar la optimización de hiperparámetros del modelo predictivo para obtener el mejor *fit* y menor error de predicción. Estos son los hiperparámetros que se deben de tomar en cuenta:

i) Hiper-parámetros de la arquitectura:

- Capa de entrada: Recibe los datos a modelar en la red neuronal.
- Capas ocultas: Ubicada entre la capa de entrada y la capa de salida. Contiene las neuronas que realizan los cálculos para entrenamiento del algoritmo.
- Capa de salida: Contiene las neuronas de salida de la red neuronal.
- Neuronas ocultas o unidades recurrentes: Cantidad de neuronas o unidades recurrentes que están en las capas ocultas de la red neuronal.

ii) Hiper-parámetros para el entrenamiento:

- Ventana retrospectiva (*look back*): Define el número de observaciones pasadas de la serie temporal que serán consideradas como inputs para entrenar el modelo.
- Número de épocas: Define la cantidad de veces que el algoritmo ejecuta los datos de entrenamiento. Es el número de veces que la red neuronal es entrenada.
- Ratio de aprendizaje (*learning rate*): Controla la velocidad con la que el algoritmo aprende. En cada época, el *learning rate* se actualiza para encontrar la función de pérdida mínima (*loss*). Toma valores entre 1 y 1×10^{-7} .

- Función de activación: Introduce la no-linealidad en la salida de las neuronas.
- Función de pérdida (*loss function*): Calcula el error en cada época de entrenamiento de la red neuronal.
- Optimizador: Los optimizadores son algoritmos o funciones matemáticas utilizados para minimizar una función de pérdida (*loss*) o para maximizar la eficiencia del entrenamiento. Los optimizadores dependen de los parámetros de aprendizaje del modelo, por ende, ayudan a cambiar los pesos y el *learning rate* de la red neuronal para disminuir el error de predicción.
- Normalización: Ejecuta un cambio de escala a los datos de entrada de la red neuronal. Toma valores entre 0 y 1. Ayuda a la convergencia del entrenamiento de la red neuronal.
- Batch size o mini batch size: Define el número de muestras que entra a la red para que sea entrenada. Cuando pasan todos los datos por la red, se completa 1 época. Con un *batch size* pequeño, la red neuronal entrena más rápido.
- Regularización de pesos: Define la magnitud de los pesos en la red neuronal al inicio del entrenamiento.
- Dropout: Define la probabilidad de entrenar una neurona en la capa oculta de la red neuronal.
- Early stopping: Deje de entrenar el modelo cuando una métrica monitoreada (*loss*) haya dejado de mejorar en las épocas seguidas. Es una técnica de optimización. La idea es aplicar una interrupción temprana para detener el entrenamiento antes que el modelo comience a sobre-ajustarse (*overfitting*).

Para el entrenamiento de la red neuronal aplicando la técnica del “descenso del gradiente” (*Gradient Descent*), se requiere prestar atención al gradiente. El gradiente controla el progreso del aprendizaje de la red neuronal. El gradiente se calcula a partir de las derivadas parciales de la función de pérdida (*loss*), teniendo como parámetros los pesos y el *bias* de las neuronas. Mientras se profundiza con el entrenamiento de todas las capas de la red neuronal, estas derivadas pueden ser muy pequeñas o nulas (desaparecen), lo cual impide que cambie el valor del peso de neurona, y, por ende, bloquea el entrenamiento del algoritmo. A este problema se le conoce como el desvanecimiento del gradiente (*Vanishing Gradient Problem*). Esto es muy frecuente en redes neuronales artificiales con muchas capas, tal como las CNN y en la RNN.

De acuerdo con la literatura (Ratanamahatana & Wanichsan, 2008) (Esling & Agon, 2012), se proponen las siguientes soluciones para atender el desvanecimiento del gradiente en una red neuronal: (1) pre-entrenar una capa a la vez; (2) implementar redes residuales que conecten capas iniciales con las últimas capas; y/o (3) usar *ReLU* como función de activación ayuda a que se sature en una dirección. Todos ellos favorecen a ser más resistente a que gradiente sea muy pequeño o nulo.

En ese sentido, es relevante considerar la optimización de los hiper-parámetros del modelo predictivo. Esta optimización busca minimizar el error (los) de la función de activación en el proceso de entrenamiento del algoritmo. De acuerdo con la literatura, se recomienda estas técnicas para entrenar una red GRU de forma eficiente:

- Aplicar *early stopping*
- Usar el *mini-batch*
- Escoger como optimizador al RMSprop
- En las capas ocultas, usar la regularización *dropout* para evitar el *overfitting*, descartando ciertos valores de probabilidad de la red.

4.4 Resumen

Este capítulo recopila los lineamientos para el modelado de datos secuenciales y los fundamentos teóricos de las RNN. Las RNN pueden entrenarse para reconocer patrones cambiantes en el tiempo para una serie temporal, debido a que cuentan con celdas de memoria que se encargan de retener y actualizar información secuencial.

La presente investigación se centra en el modelado de una serie de tiempo univariable mediante algoritmos de aprendizaje supervisado. En ese sentido, la tesis aborda el diseño, entrenamiento y evaluación de dos tipos de redes neuronales: redes neuronales full-conectadas (MLP) y redes neuronales recurrentes (RNN estándar, LSTM y GRU). Ello para contrastar el desempeño de cada arquitectura de red neuronal para el pronóstico de los valores futuros de la serie de tiempo de exportación de banano orgánico peruano.

Respecto a la estrategia de pronóstico, la presente tesis explora la estrategia “único-paso de tiempo” o también conocida como *one-step ahead*, debido a la cantidad limitada de muestras la base de datos de la serie temporal en estudio.

Capítulo 5

Estado del arte

Este capítulo desarrolla el Estado del Arte de la tesis. En la sección 5.1 se repasa el contexto preliminar de las aplicaciones de Inteligencia Artificial en la cadena de valor de banano. En la sección 5.2, se presenta las publicaciones científicas que forman parte del Estado del Arte. En la sección 5.3 se repasa las técnicas, algoritmos y perfil de los datos temporales que usaron las publicaciones para desarrollar sus modelos predictivos. Finalmente, la sección 5.4 se discute la frontera de conocimiento.

5.1 Preliminar

Como primer paso, se requiere explorar, a nivel internacional, la situación actual de los avances de la tecnología Machine Learning aplicada al banano. Con ello delimitar las líneas de investigación que ha venido desarrollando la comunidad científica.

En ese sentido, un reciente estudio realizado por Almeyda & Ipanaqué (2022) exploró 52 publicaciones científicas proveniente de 23 países, las cuales implementaron modelos predictivos para atender problemáticas reales de la cadena de valor del banano, usando algoritmos de ML o DL. Los hallazgos del estudio revelan que las 52 publicaciones científicas analizadas se agrupan en 11 aplicaciones de ML y/o DL para la cadena de valor. La **Figura 18** presenta la distribución de estas aplicaciones:

- **Precosecha:** clasificación del tipo de cultivo, detección visual de enfermedades de la hoja de banano, clasificación de la incidencia de plagas y clasificación de la calidad de suelo
- **Cosecha:** Clasificación del nivel de madurez del banano, y detección de la edad del racimo de banano.
- **Pos-cosecha:** pronóstico del rendimiento de cultivo, detección visual de los estándares de calidad de la fruta, y reconocimiento visual del banano entre diversas frutas.
- **Procesamiento:** estimación de los parámetros de procesamiento para el proceso de secado del banano.

- **Retail:** pronóstico de la producción nacional de banano.

Consecuentemente, Almeyda & Ipanaqué (2022) confirmaron que el ML y DL ayudan a superar los desafíos vigentes de la pre-cosecha, cosecha, y post-cosecha del banano, logrando impactos en el ámbito económico, ambiental, gestión agrícola, y social. La **Figura 19** presenta un marco contextual de las 11 aplicaciones de IA, el tipo de algoritmo implementado y sus potenciales impactos a lo largo de la cadena de valor del banano.

Figura 18.

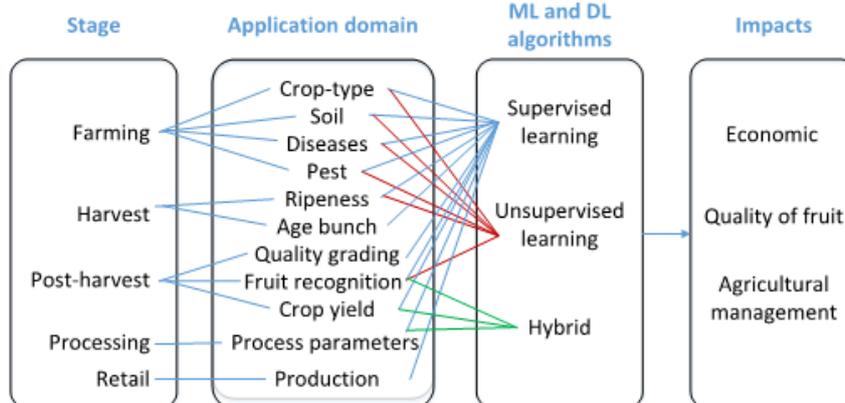
Inteligencia Artificial aplicada al banano: áreas de investigación en pre-cosecha, cosecha, post-cosecha, procesamiento y retail.



Tomado de “Recent developments of Artificial Intelligence for banana: application areas, algorithms, performance, and future challenges” (Almeyda & Ipanaqué, 2021).

Figura 19.

Inteligencia Artificial aplicada al banano: mapeo de aplicaciones de IA, algoritmos de aprendizaje implementados y potenciales impactos.



Tomado de “Recent developments of Artificial Intelligence for banana: application areas, algorithms, performance, and future challenges” (Almeyda & Ipanaqué, 2021).

5.2 Revisión de literatura

Como segundo paso, es requiere analizar aquellas publicaciones científicas, a nivel internacional de los últimos 5 años, donde desarrollen e implementen modelos predictivos para el pronóstico de series de tiempo con aplicación de técnicas de ML. Hajirahimi & Khashei (2019) afirman que estas investigaciones se ha venido desarrollando con mayor frecuencia en las últimas décadas.

5.2.1 A nivel internacional

Luego de un proceso de búsqueda bibliográfica de publicaciones científicas, se identifica trabajos de investigación que presentan modelos paramétricos y no paramétricos para pronosticar la demanda y/o producción nacional de frutos tropicales o productos agro-industriales, tales como: banana, soja, trigo, etc. Estas investigaciones son presentadas a detalle a continuación:

Hossain et al. (2016) estudió el modelado de la demanda de banana expresada en la producción anual (toneladas) durante el período 1972 a 2013 en el país de Bangladesh. Su aporte se basó en el desarrollar un modelo ARIMA¹¹ para pronosticar la producción de banana entre el 2014 al 2025.

Abraham et al. (2017) investigó sobre el modelado para pronosticar la exportación de soja del Brasil (toneladas) usando datos de un período de 16 años entre el 2001 y el 2016. El estudio propuso el diseño, entrenamiento y simulación de una Red Neuronal Artificial para pronosticar la producción de soja para el año 2017.

Rehman et al. (2018) analizó el modelado de la productividad agrícola de frutos en Pakistán. El estudio empleó un dataset con muestras de la producción total (mil toneladas) desde el año 1980 hasta el año 2015. El estudio implementó un modelo de Regresión Lineal Múltiple para predecir la productividad de frutos tales como banano, cítricos, pera, manzanas y uvas. Posteriormente a ello, el estudio realizó un análisis econométrico para investigar la relación entre el Producto Interno Bruto Agrícola (PIBA) y la producción total de manzanas, cítricos, peras, uvas y bananos.

Eyduran, S. (2020) investigó el modelado para pronosticar la producción de banano (toneladas) en Turquía. El estudio utilizó datos del período 1961-2015 para el entrenamiento del modelo; y del 2016-2025 para realizar el pronóstico. El estudio comparó dos modelos: ARIMA y Exponential Smoothing, siendo este último con el mejor desempeño.

Abraham et al. (2020) estudió el modelo para predecir producción de soya del Brasil, considerando datos recopilados en el período 1961 al 2016. Desarrolló tres modelos para pronosticar: (i) el área cosechada (hectárea), (ii) el rendimiento del cultivo

¹¹ Media Móvil Integrada Auto-Regresiva

(toneladas/hectárea), y (iii) la producción anual de soya (miles de toneladas). El estudio realizó un análisis comparativo sobre modelado paramétrico () y modelado no-paramétrico (usando redes neuronales artificiales), siendo este último el de mejor rendimiento para la estimación del área cosechada y producción de soja.

Devi et al. (2021) propuso un modelado híbrido para pronosticar la producción de trigo en Haryana en India. El estudio utilizó datos recolectados en el período 1980 a 2019. Los autores desarrollaron un modelo híbrido, integrando ARIMA con una Red Neuronal Artificial, para modelar la serie de tiempo de la producción de trigo y pronosticar futuros escenarios.

5.2.2 A nivel nacional y región Piura

Se realizó una búsqueda profunda en diversas bases de datos para identificar aquellas publicaciones científicas que hayan estudiado sobre el modelado para estimar la exportación o producción de banano orgánico a nivel nacional y en la región Piura, usando algoritmos de ML. Como resultado, no se obtuvo ningún estudio. Sin embargo, se identificó un trabajo de investigación de pronóstico de la producción nacional de plátano usando un modelo paramétrico (técnica estadístico-analítico):

Carrasco et al. (2021) implementó un método univariante ARIMA para pronosticar la producción total de plátano peruano (toneladas). El estudio usó datos de la producción mensual desde el 2000 al 2020, recolectados por el Banco Central de Reserva del Perú. Posteriormente, los investigadores lograron estimar la producción de plátano para los años 2020-2022.

Adicionalmente, se identificó investigaciones y proyectos de innovación, con alcance en la región Piura, relacionados a la productividad de la cadena de banano orgánico. En el Apéndice 3, se presenta un resumen de proyectos de I+D+i y estudios afines que fueron identificados: proyecto de fortalecimiento de extensionismo tecnológico del sector bananero en la región Piura; proyectos de innovaciones tecnológicas dirigidas a aumentar la productividad del banano orgánico de Piura; e investigaciones académicas orientadas sobre el manejo técnico-agrícola del cultivo de banano orgánico en los valles de la región Piura.

5.3 Análisis y síntesis

Como tercer paso, se analiza individualmente las siete publicaciones que pertenecen al Estado del Arte. Como resultado, se confirma que existen diversas investigaciones a nivel mundial que han diseñado, implementado y validado modelos predictivo aplicados a pronósticos de series de tiempo para la demanda o producción de frutos y/o productos agro-industriales.

La **Tabla 4** presentan un resumen de estas siete publicaciones, resaltando las principales características del dataset, tales como: fuente de datos, escala de tiempo empleada (anual, mensual, etc), cantidad de datos para entrenamiento, cantidad de datos (nuevos) para el pronóstico, y división del dataset (train/test/valid).

La **Tabla 5** presenta un resumen de estas siete investigaciones, considerando aspectos más técnicos del modelado, tales como: tipo de serie de tiempo que analizan (univariable o multivariable), estrategia de pronóstico (one-step o multi-step ahead), algoritmo implementado, hiper-parámetros del modelo, y contribución y desventajas del trabajo de investigación.

A continuación, se explican las principales características de las publicaciones seleccionadas con respecto a: objetivo de investigación, serie de tiempo estudiada, técnica de pre-procesamiento de datos utilizada, estrategia de pronóstico seleccionada, enfoque para el modelado, técnicas de optimización implementada, y métricas para la evaluación de la performance del modelo:

i) Objetivo de investigación:

Las siete publicaciones se caracterizan por estudiar el modelado de series de tiempo y al pronóstico de la demanda o producción de agro-productos (Abraham et al., 2017, 2020; Carrasco et al., 2021; Devi et al., 2021; Eyduran et al., 2020; Hossain et al., 2016; A. Rehman et al., 2018). Sólo una de las siete publicaciones emplea serie de tiempo de las exportaciones (tons) de un agro-producto (Abraham et al., 2017), el resto utiliza datos de la producción nacional (tons.).

Cuatro de las siete publicaciones tienen como objeto de investigación al banano (Carrasco et al., 2021; Eyduran et al., 2020; Hossain et al., 2016; A. Rehman et al., 2018). En el Perú, sólo hay un estudio para pronosticar la producción de demanda de banano peruano (Carrasco et al., 2021); sin embargo, esta investigación utiliza un modelo paramétrico (ARIMA) en lugar de algoritmos de Machine Learning.

ii) Serie de tiempo:

La mayoría de las investigaciones analizan series de tiempo del tipo univariable. Sólo una investigación modela una series de tiempo multivariable (Abraham et al., 2020). Respecto a la escala de tiempo, todos los trabajos de investigación analizan series de tiempo con frecuencia anual; a excepción una publicación que emplea escala mensual (Carrasco et al., 2021).

iii) Dataset:

Tres de las siete publicaciones emplean datos temporales recolectados de los 40 últimos años en promedio (Devi et al., 2021; Hossain et al., 2016; A. Rehman et al., 2018). Sólo dos trabajos de investigación emplean datos históricos de 15 años (Abraham et al., 2017) y 20

años (Carrasco et al., 2021) respectivamente. Los modelos predictivos son entrenados con diferentes tamaños de *training-set*: desde 15 muestras (Abraham et al., 2017), pasando por 37 muestras (Devi et al., 2021) y hasta 56 muestras (Abraham et al., 2020). Asimismo, mencionar que las bases de datos de la serie de tiempo, empleadas en las investigaciones, proviene de fuentes de acceso abierto, en su mayoría.

iv) Técnicas de pre-procesamiento:

Ninguna de las publicaciones explica las técnicas de pre-procesamiento empleadas. Por ejemplo, re-muestreo, descomposición de serie de tiempo, etc. Sin embargo, las investigaciones que implementan el modelado paramétrico enfocan su análisis en la estacionariedad de la serie de tiempo (estable a lo largo del tiempo), empleando métodos estadísticos-clásicos como el ACF (AutoCorrelation Function) y Parcial-ACF de residuos (indispensable para los modelos ARIMA).

v) Estrategia de pronóstico:

La mayoría de publicaciones seleccionaron *one-step ahead* para realizar el pronóstico de valores futuros; no obstante, sólo una investigación realizó el pronóstico de la serie de tiempo empleando dos estrategias de pronóstico (Abraham et al., 2020): *one-step ahead* y *multi-step ahead*.

vi) Modelado de serie de tiempo:

Las publicaciones han modelado la serie de tiempo empleando métodos paramétricos, tales como ARIMA (Carrasco et al., 2021; Hossain et al., 2016) y NARX (Abraham et al., 2017), o técnicas de Machine Learning, tales como Redes Neuronales Artificiales (Abraham et al., 2017, 2020), Regresión Lineal Múltiple (A. Rehman et al., 2018), y *Exponential Smoothing* (Eyduran et al., 2020). Sólo una de las siete publicaciones ha implementado un modelo híbrido (Devi et al., 2021), la cual fusiona ARIMA con una Red Neuronal Artificial.

vii) Técnicas de optimización:

Las investigaciones utilizaron diversos enfoques para optimizar el entrenamiento del modelo predictivo y reducir el error de predicción, entre las más destacadas: realizar experimentos con diferentes estrategias de pronóstico, emplear serie de tiempo multivariable (Abraham et al., 2020), aplicar regularización a los pesos de las neuronas (Abraham et al., 2017), desarrollar modelos híbridos (Devi et al., 2021), entre otros.

viii) Técnicas de evaluación de desempeño del modelo:

Todas las investigaciones calcularon al menos una métrica del error para estimar la precisión de su modelo predictivo. Las métricas usadas con frecuencia son: Root Relative Square Error (RMSE), Mean Absolute Error (MAE), y Mean Absolute Percentage Error (MAPE). En casos específicos, los investigadores usaron: Factor de Correlación (R^2) (Abraham et al.,

2020), Maximum Absolute Percentage Error (MaxMAPE) (Eyduan et al., 2020), y Theil Inequality Coefficient (TIC) (Hossain et al., 2016).

5.4 Análisis de la frontera de conocimiento

Como cuarto paso, se requiere explorar la frontera de conocimiento del Estado del Arte. Por ello, se formula las siguientes preguntas:

P1. *¿Qué tipo de estrategia de pronóstico se usa?*

P2. *¿Qué algoritmos son implementados, frecuentemente, para el pronóstico de serie de tiempo?*

P3. *¿Qué tipo de pre-procesamiento de datos temporales hacen posible que los algoritmos de Machine Learning superen a los modelos estadísticos-clásicos?*

P4. *¿Cuántos valores de la serie de tiempo son empleados para el entrenamiento del modelo y cuántos valores para la validación?*

P5. *¿Cuál es la caracterización de la base de datos de series de tiempo (escala de tiempo, fuente de datos, tamaño del dataset, etc.)?*

P6. *¿Qué métricas se usa para comparar y evaluar modelos predictivos de series de tiempo?*

De acuerdo a lo explicado en la sección 5.1, 5.2, y 5.3, se responde las preguntas planteadas al inicio de esta sección:

P1. *¿Qué estrategia de pronóstico es más usada?*

One-step ahead es la estrategia de pronóstico más usada por las investigaciones revisadas.

P2. *¿Qué algoritmos son implementados frecuentemente para el pronóstico de serie de tiempo?*

Los modelos paramétricos, es decir aquellos que usan métodos estadísticos-clásico como el ARIMA, aún tiene gran prevalencia para el pronóstico de serie de tiempo. Sin embargo, los algoritmos de ML, tales como las Redes Neuronales Artificiales, están siendo implementadas para realizar pronósticos de serie de tiempo, los cuales ofrecen ventajas para procesar datos temporales no-lineales y realizar pronósticos con alta precisión.

Recientemente, se están desarrollando modelos híbridos que fusionan los atributos de los métodos paramétricos (por ejemplo, ARIMA) y algoritmos de Machine Learning (por ejemplo, Red Neuronal Artificial).

P3. *¿Qué tipos de pre-procesamiento de datos de series temporales hacen posible que los algoritmos de Machine Learning superen a los modelos estadísticos clásicos?*

Por un lado, los modelos paramétricos (métodos estadísticos-clásicos) sí tienen definido las técnicas de pre-procesamiento, básicamente enfocadas en evaluar la estacionariedad de la serie temporal.

Sin embargo, no hay un método, definido y explicado, para el pre-procesamiento de datos temporales antes del entrenamiento de modelo de ML. Entonces, infiriendo el diseño de los modelos de ML, las técnicas principales son las siguientes: identificación de datos nulo/vacíos, re-muestreo, descomposición de serie temporal, normalización de datos, entre otros.

P4. *¿Cuántos valores de la serie de tiempo son empleados para el entrenamiento del modelo y cuántos valores para la validación?*

No hay un número exacto de muestras para entrenar el modelo. Depende del período de tiempo a estudiar, la disponibilidad de datos históricos y del acceso a una fuente de datos confiable. Sin embargo, deben ser suficientes para que el algoritmo reconozca los patrones no-lineales de los datos a lo largo del tiempo.

P5. *¿Cuál es la caracterización general de la base de datos de las series de tiempo (escala de tiempo, tamaño del dataset, fuente de datos, etc.)?*

La base de datos debe contener valores reales de una variable temporal. Los datos deben provenir de fuentes de datos confiable para asegurar un pronóstico de valores futuros en base a valores reales pasados. Se requiere definir previamente el período de tiempo a modelar (varía de acuerdo al análisis retrospectivo), y las escalas de tiempo (anual o mensual) para entrenar el modelo predictivo.

P6. *¿Qué métricas se pueden usar para comparar y evaluar modelos en el pronóstico de series de tiempo?*

Tres métricas se han usado frecuentemente en las investigaciones revisadas. Estas métricas son las siguientes: RMSE (Root Mean Square Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percent Error).

5.5 Resumen

Este capítulo presenta el Estado del Arte y el análisis de la frontera de conocimiento. Se evidencia una oportunidad para investigar y profundizar el estudio del modelado secuencial aplicado a series de tiempo bajo el enfoque de ML: diseño, entrenamiento y validación de modelos aplicados a pronosticar la demanda o producción de productos agro-industriales. Se confirma que existe una brecha de conocimiento (*gap knowledge*) para pronosticar pronóstico de la demanda internacional del banano orgánico en relación a la implementación de Redes Neuronales Recurrentes. Específicamente, estudiar el desempeño de diversos tipos de algoritmos de Redes Neuronales Recurrentes para obtener el menor el error de predicción. Por tal motivo, se refuerza la justificación del objetivo principal de la presente tesis doctoral.

Tabla 4.

Resumen analítico del Estado del Arte: serie de tiempo a estimar y características del dataset.

Referencia	País	Agro-producto	Variable a estimar (unid)	Escala de tiempo	Fuente de datos	Datos de entrenamiento	Datos a pronosticar (nuevos)	Data Train/Test/Valid
(Hossain et al., 2016)	Bangalesh	Banana	Producción (tons.)	Anual	FAOSTAT ¹²	1972 a 2013 (41 muestras)	2014 a 2025 (12 muestras)	76%/25%/-
(Abraham et al., 2017)	Brasil	Soja	Exportación (millones tons.)	Anual	SISCOMEX ¹³	2001 a 2016 (15 muestras)	2017 (1 muestra)	80%/5%/15% (aleatorio)
(Abraham et al., 2020)	Brasil	Soja	Producción** (millones tons.)	Anual	ERS USDA ¹⁴	1967 a 2016 (50 muestras)	No emplea nuevos valores	70%/15%/15% (aleatorio)
(A. Rehman et al., 2018)	Pakistán	Banana	Producción (mil tons.)	Anual	Sin especificar	1980 a 2015 (35 muestras)	2015 a 2030 (16 muestras)	100% para entrenamiento
(Eyduran et al., 2020)	Turquía	Banana	Producción* (tons.)	Anual	FAOSTAT	1961 a 2015 (54 muestras)	2016 a 2025 (10 muestras)	100% para entrenamiento
(Devi et al., 2021)	India	Trigo	Producción** (mil tons.)	Anual	SAH ¹⁵	1980 a 2015 (37 muestras)	2016 a 2019 (4 muestras)	100% para entrenamiento
(Carrasco et al., 2021)	Perú	Banana	Producción (tons.)	Mensual	BCRP ¹⁶	Jul-2000 a Set-2020 (51 muestras)	Oct-2020 a Set-2022 (24 muestras)	68%/32%/-

* Emplea dataset adicionales para pronosticar: área cosechada

** Emplea dataset adicionales para pronosticar: área cosechada y rendimiento de cultivo.

¹² Food and Agriculture Organization Corporate Statistical Database.

¹³ Foreign Trade Integrated System, Ministry of Industry, Foreign Trade and Services, Brazil.

¹⁴ United States Department of Agriculture-Economic Research Service (<https://www.ers.usda.gov/data-products/oil-crops-yearbook/oil-crops-yearbook/#So%20and%20Soybean%20Products>)

¹⁵ Statistical Abstract of Haryana, Department of Economic and Statistical Analysis Haryana, India (<https://esaharyana.gov.in/state-statistical-abstract-of-haryana/>)

¹⁶ Banco Central de Reserva, Perú

Tabla 5.

Resumen analítico del Estado del Arte: estrategia de pronóstico, algoritmo implementado, contribución y desventajas.

Referencia	Cultivo	Time series	Estrategia de pronóstico	Algoritmo implementado	Hiper-parámetros	Contribución	Desventaja
Métodos de procesamiento de los datos							
(Hossain et al., 2016)	Banana	Univariable	One-step ahead	ARIMA	ARIMA (0,2,1)	Aplica métodos estadísticos para la estacionalidad y pre-procesamiento: ACF ¹⁷ , PACF de residuos.	Trabaja el dataset para convertirlo en serie temporal estacionaria.
(Eyduran et al., 2020)	Banana	Univariable	One-step ahead	Brown Exponential Smoothing	Estimador: 0.718 SE: 0.066 t: 10.863 Sig: 0.001	Aplica métodos estadísticos para la estacionalidad y pre-procesamiento: ACF, Parcial-ACF de residuos.	Los valores futuros pronosticados no siguen el patrón natural de la serie de tiempo.
(Carrasco et al., 2021)	Banana	Univariable	One-step ahead	ARIMA	ARIMA (1,0,1)	Aplica pruebas de estacionalidad: ACF test y prueba de punto de quiebre estructural: Chow test.	Débil balance entre el error de predicción y el horizonte de pronóstico (24 meses)
Métodos de optimización							
(Abraham et al., 2017)	Soja	Univariable	One-step ahead	NAX ¹⁸ y ANN	1 capa oculta 50 neuronas 4 delay Bayesian regularization	Utiliza la técnica de regularización de pesos (Bayesiana) de la red neuronal.	Entrenar el modelo con pocos datos (15 muestras).
(A. Rehman et al., 2018)	Banana	Univariable	One-step ahead	Ordinary Least Square y Reg. Lineal Múltiple	Sin especificar	Trabaja con dos algoritmos de regresión para el pronóstico.	El modelo es deficiente ante la no-linealidad de serie temporal.
(Abraham et al., 2020)	Soja	Multivariable	One-step ahead y Multi-step ahead	Non-linear Autoregressive Network y ANN	1 capa oculta 10 neuronas 6 delay k-cross validation	Emplea dos estrategias de pronósticos (one-step-ahead and multi-step-ahead) y compara resultados.	No valida el modelo con datos nuevos o desconocidos
(Devi et al., 2021)	Trigo	Univariable	One-step ahead	Híbrido: ARIMA + ANN	ARIMA (1,1,0) ANN (no especifica arquitectura de la red)	Optimiza el pronóstico mediante un enfoque híbrido.	La configuración inicial del modelo es ambigua.

¹⁷ Autocorrelation Function

¹⁸ Nonlinear Autoregressive Network



Capítulo 6

Exportación de banano orgánico del Perú

Este capítulo presenta una visión general de la evolución de las exportaciones de banano orgánico peruano en los últimos 20 años. En la sección 6.1, se exponen el panorama de la evolución de las exportaciones de banano orgánico del Perú. En la sección 6.2 se realiza un análisis exploratorio-descriptivo de la serie de tiempo en estudio.

6.1 Exportaciones de banano orgánico

En esta sección se presenta una descripción de la evolución de la exportación de banano orgánico del Perú registrado desde enero 2001 a setiembre del 2021 (fecha de corte para descargar dataset). Adicionalmente, se presenta detalles de su partida arancelaria y una revisión de la exportación según mercado de destino.

6.1.1 Partida arancelaria

Las exportaciones de banano son declaradas ante la SUNAT a través de su agencia ADUANET. Las empresas exportadoras de banano orgánico deben declarar toda salida de mercadería, detallando información como el RUC del exportador, el código del Agente de Aduanas, la partida arancelaria del producto, el peso (bruto y neto) en Kg del producto, el valor FOB (\$) de la mercancía, entre otros. Aduanet registra todas las exportaciones de banano, con frecuencia diaria, y publica el registro en su portal web oficial. De acuerdo con Aduanet-Sunat (2020), el banano orgánico peruano tiene asignado la siguiente partida arancelaria: 0803.90.11.00. La Tabla 6 detalla la información consignada a los bananos orgánicos para exportación.

Tabla 6.*Información arancelaria del banano orgánico del Perú.*

Nombre comercial	Banana orgánica
Nombre científico	Musa acuminata (grupo AAA) / Musa paradisiaca, Musa cavenshi
Nombre común	Banana orgánica
Partida arancelaria	0803001200
Descripción arancelaria	Bananas o plátanos del tipo cavenshi valery frescos

Elaborado a partir de portal oficial de Aduanet-Sunat (2020).

6.1.2 Evolución histórica

El Foro Mundial Bananero de la FAO (2020a) afirma que el banano es la fruta fresca más exportada del mundo, su industria puede llegar a valer más de 10 billones de dólares al año (US\$ 10.000mn/año). El mercado global del banano ha crecido a lo largo de los últimos 20 años según un estudio sobre la producción global de banano elaborado por la FAO (2020c). De acuerdo con lo expresado por MINAGRI (2018), el banano orgánico cada vez es más atractivo por su calidad, buen sabor y bondades nutricionales de la fruta.

PromPerú (2020) confirman la variedad de banana peruana más consumida es la banana *Cavendish*; asimismo, asegura que el banano orgánico del Perú es una de las frutas más comercializan con certificados de comercio justo o *Fairtrade*. Ello lo posiciona estratégicamente en mercados extranjeros. Efectivamente, el MINAGRI (2018) expone que el banano orgánico del Perú es muy demandado por países de Europa y Estados.

El Foro Mundial del Banano de la FAO (2017) menciona que la producción de banano orgánico del Perú aumentó un 94% desde el 2010 al 2015. Respecto a los volúmenes de exportación de banano orgánico, reportes aduaneros de la Sunat (2020) confirman que las exportaciones han crecido progresivamente desde sus inicios en el año 2001.

Otro aspecto positivo del comercio internacional del banano orgánico peruano es su precio de venta. El precio se mantiene estable a lo largo de los años debido a que la mayoría del banano peruano para exportación es orgánica, atributo que es muy valorado en el mercado europeo.

i) Exportación mensual

La **Tabla 7** tabula el volumen de exportación anual del banano orgánico desde al año 2012 al 2020. Se observa un incremento progresivo de las exportaciones (miles de kilos) a lo largo de los 20 años. En los último 5 años, las exportaciones acumuladas superaban las 200 mil toneladas; y alcanzaron un índice de crecimiento anual del 13% del 2017 al 2018. El año 2018 se registró 231 mil toneladas, considerado el mayor volumen de exportación de banano orgánico registrado a la fecha. No obstante, en el año 2020, el volumen de exportación se

redujo a exportó 72 mil toneladas debido a la crisis mundial del Covid-19 y a las restricciones de comercio internacional por la emergencia sanitaria.

Tabla 7.

Exportación anual del banano orgánico del 2012 al 2020.

Año	Valor FOB (mil dólares)	Var anual (%)	Peso (mil kilos)	Var anual (%)
2020	148,000	-67%	215,317	-4%
2019	151,000	-9%	224,417	-3%
2018	165,000	13%	231,040	13%
2017	147,411	-3%	203,898	1%
2016	151,622	5%	201,788	5%
2015	144,396	21%	191,534	19%
2014	119,317	34%	160,785	31%
2013	88,971	11%	122,429	3%
2012	80,366	-	119,131	-

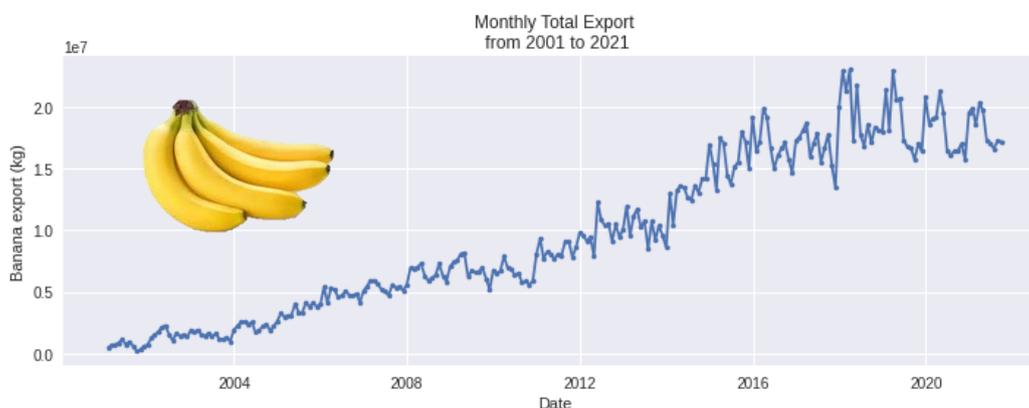
Elaborado a partir de portal oficial de Aduanet-Sunat (2020).

ii) Exportación mensual

La **Figura 20** representa las exportaciones mensuales desde enero de 2001 a setiembre 2021. Se observa un incremento lento entre los primeros 12 años. En los años siguientes, hay un crecimiento acelerado entre el 2012 y 2016. Sin embargo, entre los años 2016-2018, hay un decremento significativo. De acuerdo con los hallazgos del estudio realizado por Colonia Luy & Carrillo Caceres (2019) sobre los niveles de exportación de banano orgánico a USA realizados entre 2016 y 2018, revela que las exportaciones fueron afectadas negativamente por las condiciones climáticas en las parcelas de cultivo, exigencia de medidas sanitarias y fitosanitarias, y la competitividad de la cadena de valor.

Figura 20.

Evolución histórica de la exportación de banano orgánico (ene-2001 a set-2021).



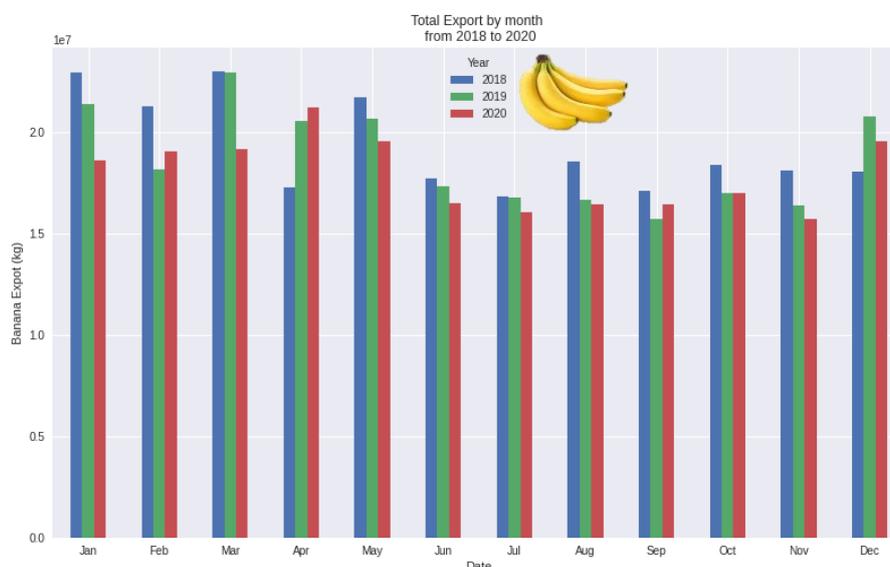
Elaborado a partir de portal oficial de Aduanet-Sunat (2020).

En ese sentido, la **Figura 20** muestra que las exportaciones empezaron a adoptar una estacionalidad en los años posteriores al 2018, con picos de exportación en el primer trimestre del año. Ver detalles del calendario de exportaciones en Apéndice 4. Por tal motivo, se analiza a detalle el volumen de exportación de banano orgánico en los últimos 3 años.

La **Figura 21** representa la evolución de las exportaciones mensuales de los años 2018, 2019 y 2020. Se confirma un ligero decremento desde el 2018. Asimismo, las exportaciones presentan una ligera estacionalidad: los primeros meses del año (temporada alta) registran mayor demanda que el segundo trimestre (temporada baja).

Figura 21.

Exportación mensual de banano orgánico del año 2018, 2019 y 2020.



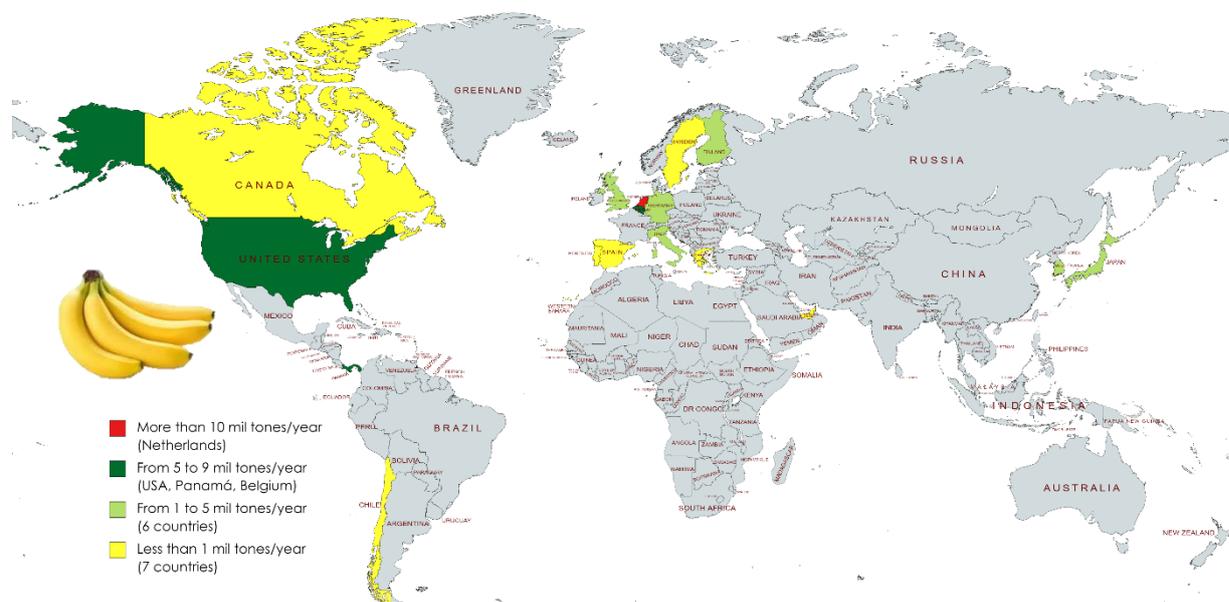
Elaborado a partir de portal oficial de Aduanet-Sunat (2020)

6.1.3 Mercados destino

La **Figura 22** representa los países de destino registrados en las exportaciones de banano orgánico del año 2020. En todo el año 2020, se exportó a 17 países: siendo Países Bajos (Netherlands) y EE.UU. aquellos que abarcan mayor valor FOB: 30% y 19% respectivamente. Estos dos países, se siguen manteniendo en el top-2 durante los últimos 5 años. La **Tabla 8** detalla el valor FOB y el volumen de las exportaciones de banano orgánico por país.

Figura 22.

Exportación de banano orgánico en el año 2020: distribución geográfica de los países de destino.



Elaborado a partir de portal oficial de Aduanet-Sunat (2020)

Tabla 8.

Exportación de banano orgánico en el año 2020 según país de destino.

País de Destino	FOB (dólares)	Peso Neto (Kilos)	Peso Bruto (Kilos)	FOB (%)
Netherlands	15,157,157.37	21,436,079.13	24,229,065.90	30.19
United States	9,700,416.34	14,472,345.58	16,522,974.31	19.32
Panamá	8,182,182.80	12,700,885.20	14,269,096.00	16.30
Belgium	5,481,329.19	7,782,635.84	8,913,396.00	10.92
Republic of Korea	2,876,590.40	3,802,819.60	4,340,001.90	5.73
Germany	2,430,830.78	3,549,314.20	4,058,321.00	4.84
Finland	1,740,291.17	2,523,225.80	2,880,875.20	3.47
Japan	1,431,716.93	1,734,487.24	1,927,801.20	2.85
Italy	1,390,002.91	2,500,583.40	2,762,057.42	2.77
United Kingdom	1,270,917.73	1,469,340.00	1,660,770.00	2.53
Canada	271,820.40	367,879.20	418,550.00	0.54
Sweden	156,816.00	235,094.40	257,904.00	0.31
Chile	61,828.56	128,757.60	139,545.00	0.12
Portugal	43,249.68	78,364.80	89,950.00	0.09
United Arab Emirates	9,486.40	12,740.00	14,670.00	0.02
Greece	7,000.00	1,080.00	21,800.00	0.01
Spain	664.4	340	389.039	0.0001
Total	50,212,301.06	72,795,971.99	82,507,166.97	100%

Elaborado a partir de portal oficial de Aduanet-Sunat (2020).

6.2 Análisis exploratorio - descriptivo

En esta sección se realiza una exploración de datos históricos de la exportación de banano orgánico peruano. En ese sentido, se analiza el comportamiento de la serie de tiempo a nivel anual, mensual, semanal y diario, usando las gráficas de *time-plot*, *box-plot* y estacionalidad.

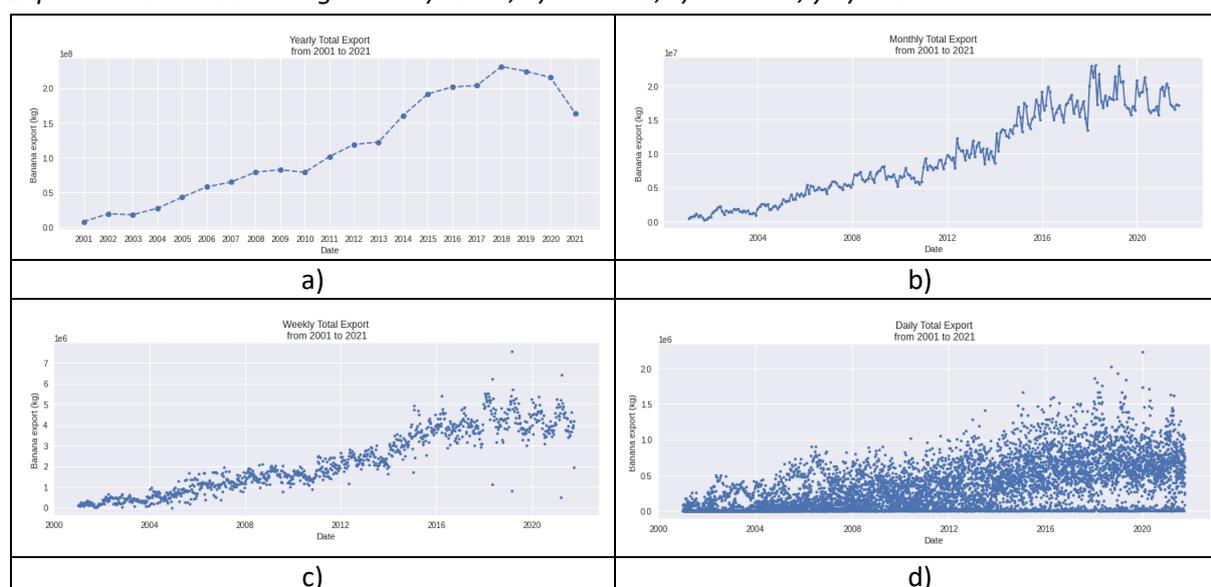
6.2.1 Time-plot

La **Figura 23** presenta la gráfica de la serie de tiempo de la exportación de banano [kg] desde enero de 2001 a setiembre de 2021 en cuatro frecuencias de tiempo diferentes: anual, mensual, semanal y diario (aplicando la técnica del *down-sampling*). Complementariamente, la **Tabla 9** escribe las principales características del comportamiento de estas cuatro series de tiempo, destacando la presencia de tendencia, estacionalidad y *outliers*.

Se infiere que cada una de estas cuatro series de tiempo tienen varianzas diferentes. Por ejemplo, la serie temporal de las exportaciones diarias presenta una alta varianza, el cual complica identificar patrones temporales de los datos para entrenar un modelo predictivo. En ese sentido, la presente investigación emplea la serie de tiempo de la demanda mensual, como input del modelo predictivo, debido a que presenta menor varianza y moderadamente controlada en el tiempo, lo cual permitirá que el modelo aprenda con mayor rapidez y precisión.

Figura 23.

Exportación de banano orgánico: a) anual, b) mensual, c) semanal, y d) diario.



Elaborado a partir de portal oficial de Aduanet-Sunat (2020)

Tabla 9.

Exportación de banano orgánico: características de la serie de tiempo y número de muestras.

Demanda	Características
Anual	El comportamiento de la serie de tiempo anual se puede analizar en 3 períodos: del 2012 al 2013, la demanda es constante; del 2014 al 2018, la demanda presenta un crecimiento constante año a año; del 2019 al 2020, hay un decrecimiento notable. Finalmente, en el 2021, la demanda es menor debido a que aún no se contabiliza la demanda del último trimestre del año.
Mensual	Se aprecia un crecimiento de la demanda mensual a lo largo del 2012 al 2018. Particularmente, a partir del año 2018, se presenta estacionalidad (anual): mayor demanda en el primer trimestre del año, y con temporada de baja demanda en el último semestre del año.
Semanal	Aumenta la dispersión de los datos y se identifican outliers en el año 2018, 2019 y 2021. Si embargo, denota una tendencia creciente, con una marcada estacionalidad: temporada alta (inicio del año), y temporada baja (finales de año).
Diario	Se aprecia que hay una alta dispersión, con picos de demanda a inicios del año (primer semestre), y con una tendencia ligeramente al alza a lo largo del horizonte de tiempo.

Elaborado a partir de portal oficial de Aduanet-Sunat (2020).

6.2.2 Estacionalidad

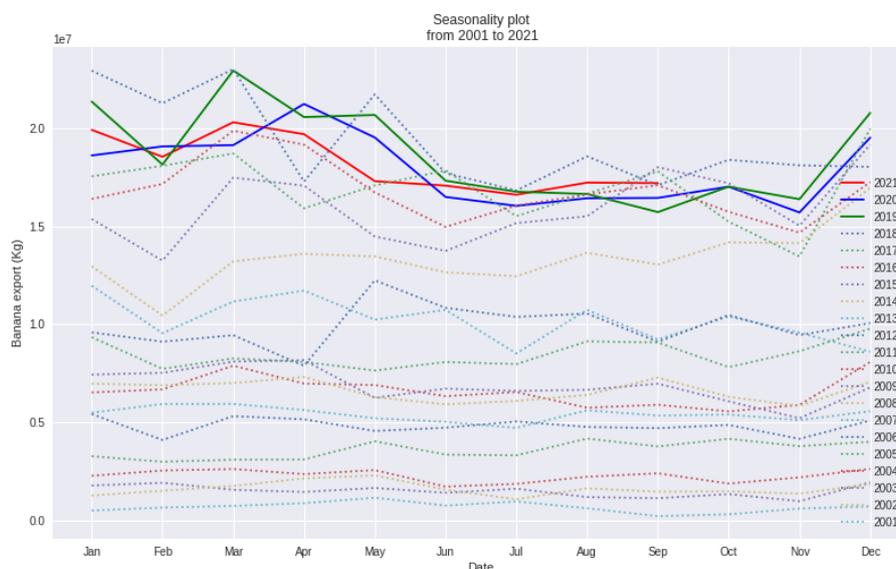
La **Figura 24** esboza las series de tiempo mensual de la exportación de banano año a año desde ene-2001 a set-2021. Se infiere que los meses del primer trimestre del año (enero a abril) y el último mes del año (diciembre) registran mayor demanda mensual comparado al resto. Particularmente, en el mes de marzo de 2020 (inicio de la inmovilización social obligatoria por el Covid-19) se registró una caída en las exportaciones. De acuerdo al estudio realizado por Das & Roy (2021), la demanda de productos agro-industriales presentó fue ligeramente menor en el año 2020, debido a las restricciones de la pandemia COVID-19.

En el mismo sentido, la demanda del primer semestre del año 2021 es menor al primer trimestre del año 2020. No obstante, a partir de junio se observa un volumen exportación estable y sostenido hasta setiembre (fecha de corte para descargar dataset).

De manera complementaria se presenta el Apéndice 4, el cual trazar datos de series de tiempo de la exportación de banano orgánico muestreados por día en un mapa de calor por año calendario. Se infiere que: el año 2018 fue un año con mucha actividad de comercio internacional, lo cual coincide con las gráficas explicadas anteriormente en la Sección 6.2.

Figura 24.

Exportación mensual de banano orgánico (ene-2001 a set-2021).



Elaborado a partir de portal oficial de Aduanet-Sunat (2020).

6.2.3 Box-plot

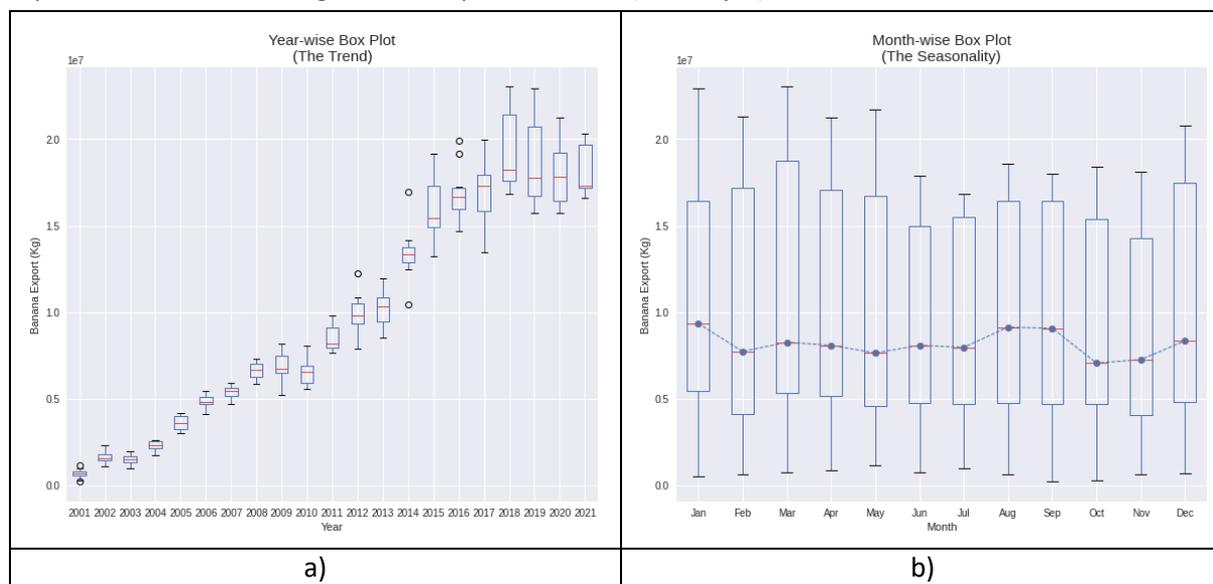
Considerando la serie de tiempo mensual, se grafica el box-plot en dos escalas: anual y mensual. La **Figura 25 a)** esquematiza la distribución de los valores de la exportación anual desde ene-2001 a set-2021 (media y percentiles 25-50-75). En esta gráfica se visualiza algunos valores atípicos de la serie de tiempo en el año 2012, 2014 y 2016; asimismo, se observa que en los dos últimos años (2020 y 2021), la demanda de exportación tiene una media similar.

Por otro lado, la **Figura 25 b)** representa la distribución de los valores de la exportación mes a mes desde ene-2001 a set-2021. Se confirma una estacionalidad marcada (ver Sección 6.2.1). Asimismo, se observa que los meses febrero, marzo, abril, mayo y junio registran un valor de media cercana a $0.9e7$. Sin embargo, es notable que en el mes de febrero el valor del percentil-25 y percentil-75 disminuye respecto al mes de enero. Ello podría deberse a las amenazas de plagas y enfermedades que aparecen durante los meses de verano en los cultivos de banano orgánico en Piura.

Complementariamente, la **Tabla 10** presenta elementos estadísticos básicos de la serie de tiempo de demanda mensual del año 2020: media, desviación estándar, y percentil 25%-50%-75%.

Figura 25.

Exportación de banano orgánico: box-plot a escala a) anual y b) mensual.



Elaborado a partir de portal oficial de Aduanet-Sunat (2020).

Tabla 10.

Exportación de banano orgánico en el año 2020: media, desviación estándar, y percentiles.

Promedio	1.794310e+07
Desviación estándar	1.788203e+06
Valor mínimo	1.570982e+07
25%	1.644697e+07
50%	1.782122e+07
75%	1.924122e+07
Valor máximo	2.124677e+07

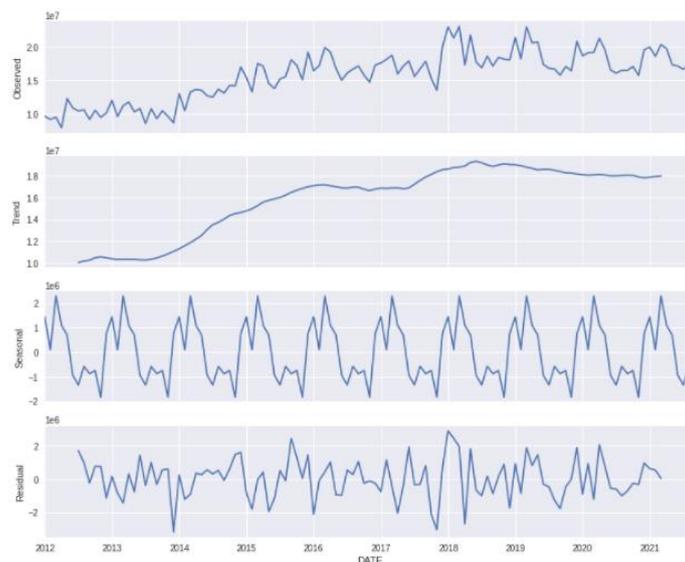
Elaborado a partir de portal oficial de Aduanet-Sunat (2020).

6.2.4 Componentes

Se aplica una técnica estadística de para el desglose de los componentes de serie de tiempo en el período 2012 - 2021. La **Figura 26** expone los tres principales componentes de los datos temporales en estudio: tendencia, estacionalidad y residuos (o ruido blanco). Por lo tanto, se confirma que la serie de tiempo tiene una tendencia creciente y una estacionalidad definida.

Figura 26.

Serie de tiempo: componentes de tendencia, estacionalidad y residual.



Elaborado a partir de portal oficial de Aduanet-Sunat (2020).

6.3 Resumen

Este capítulo presenta aspectos relacionados al panorama de evolución de las exportaciones de banano orgánico, y un análisis exploratorio y descriptivo de su serie de tiempo desde el período: ene-2001 a set-2021. Como resultado del análisis, se evidencia un crecimiento progresivo de las exportaciones, pero en los últimos años se ha presentado un leve decremento. Ello manifiesta un escenario de inestabilidad del mercado internacional, el cual amerita ser estudiado para mitigar impactos económicos y sociales. En ese sentido, la presente investigación empleará la serie de tiempo mensual, como input del modelo predictivo, debido a que presenta menor varianza, lo cual permitirá que el modelo aprenda con mayor rapidez y precisión.

Capítulo 7

Metodología de investigación

Este capítulo presenta la metodología para realizar el modelado secuencial y temporal de la exportación de banano orgánico del Perú usando algoritmos de aprendizaje supervisado. La sección 7.1 repasa el proceso de investigación. La sección 7.2 explica los pasos de la metodología para el pre-procesamiento, modelado y pronóstico de la serie de tiempo en estudio. La sección 7.3 presenta el diseño de experimentos para la elegir el modelo predictivo con mejor ajuste y menor error de predicción. La sección 7.4 repasa las técnicas y métodos empleados para el desarrollo del modelo predictivo. Finalmente, la sección 7.5 realiza un estudio analítico-descriptivo del dataset usado para entrenar el algoritmo de Machine Learning.

7.1 Proceso de investigación

La **Figura 27** presenta el flujograma del proceso de investigación de la presente tesis. Este proceso comprende tres etapas:

i) Formulación de la investigación:

La primera etapa abarca la definición del problema de investigación, los objetivos de investigación, y la variable de estudio para el pronóstico de la demanda internacional del banano orgánico. Asimismo, incluye el Estado del Arte, el marco teórico y el análisis de la frontera de conocimiento.

ii) Pre-procesamiento de datos:

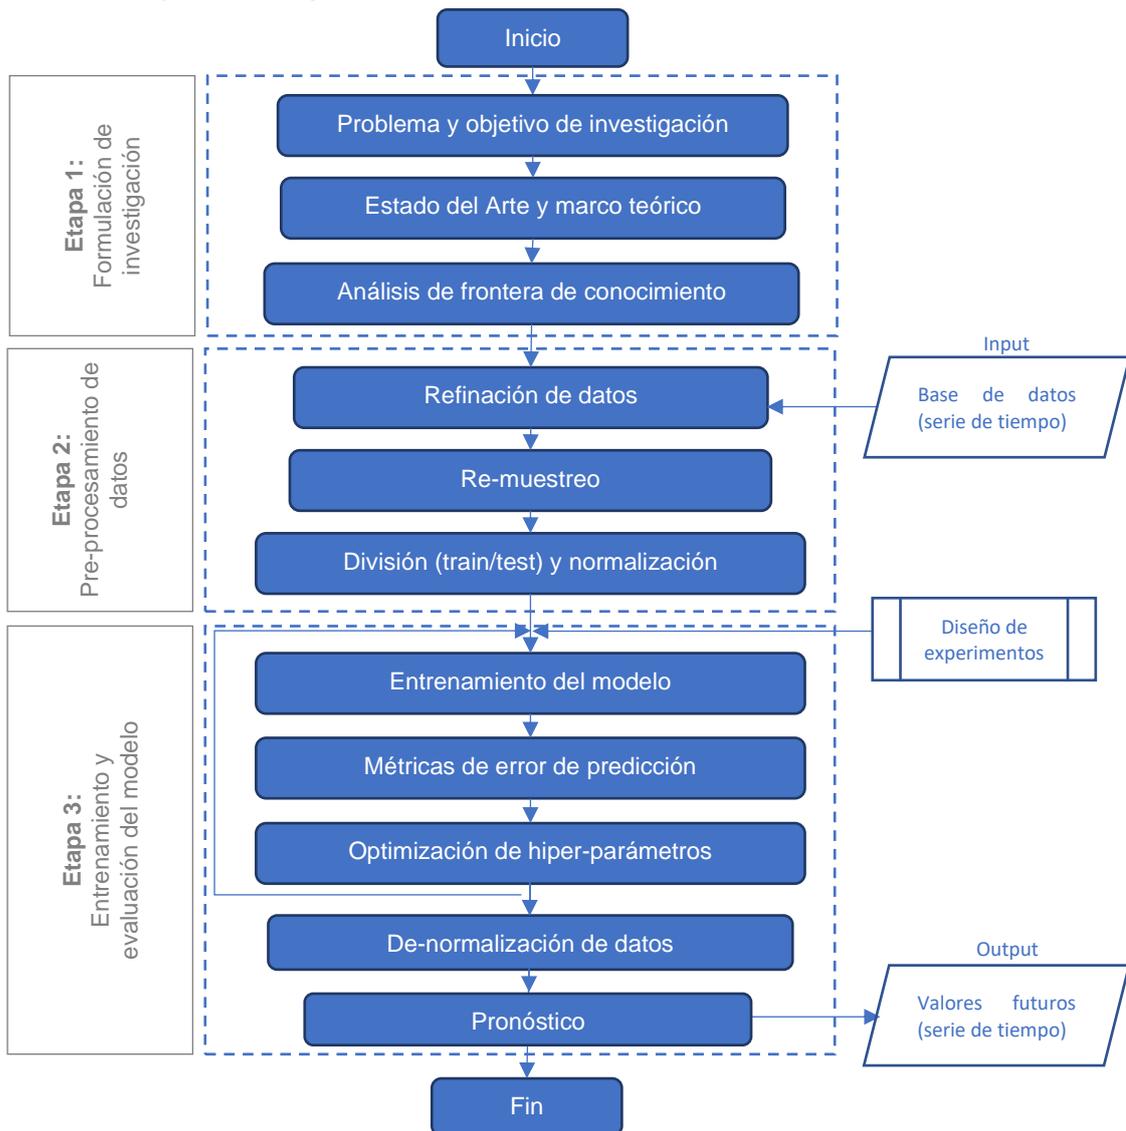
La segunda etapa comprende desde la descarga del dataset histórico de las exportaciones peruanas de banano orgánico y el análisis de su evolución como serie temporal; pasando por la refinación de datos (valores nulos y/o vacíos) y re-muestreo de la serie de tiempo; realizando la división del dataset (*training-set* y *testing-set*) y normalización de los datos. Esto último, se considera un paso previo para que los datos ingresen al modelo predictivo.

iii) Entrenamiento y evaluación del modelo:

La tercera etapa comprende la construcción de los algoritmos de aprendizaje automático (*Machine Learning*); el diseño de experimentos para el entrenamiento del algoritmo; y selección de los hiper-parámetros de aprendizaje del modelo predictivo (*training*). Finalmente, la evaluación del modelo con mejor ajuste (en el *testing-set*) mediante el cálculo de las métricas de error de predicción para determinar si el modelo se acerca al pronóstico de valores futuros de la serie de tiempo.

Figura 27.

Flujograma del trabajo de investigación.



Elaboración propia a partir de “*Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model*” (Parmezan et al., 2019) y “*An Experimental Review on Deep Learning Architectures for Time Series Forecasting*” (Lara-Benítez et al., 2021).

7.2 Metodología

Esta sección describe la metodología empleada para el análisis, modelado y pronóstico de la exportación mensual de banano orgánico peruano, considerando los objetivos de análisis de series temporales propuesto por Chatfield (2019) (ver Sección 2.6); e incluyendo los lineamiento para el pronóstico de series de tiempo univariable explicado por Parmezan et al. (2019). La **Tabla 11** explica la secuencia de estos pasos.

Tabla 11.

Metodología para el análisis, modelado y pronóstico de series de tiempo en estudio.

Enfoque	Pasos	Descripción	Técnica o método empleado
Descripción	1. Análisis descriptivo y exploratorio	1.1 Refinar serie de tiempo (valores nulos y vacíos). 1.2 Re-muestrear datos. 1.3 Analizar tendencia, estacionalidad y fluctuaciones aleatorias.	<ul style="list-style-type: none"> • Time-plot • Down-sampling • Box-plot • Estacionalidad
	2. Pre-procesamiento	2.1 Definir estrategia de predicción 2.2 Definir período de retrosección 2.3 Dividir serie temporal: <i>training-set</i> y <i>testing-set</i> . 2.4 Normalizar de datos.	<ul style="list-style-type: none"> • One-step ahead • Look back • División train/test • Normalización
Modelado	3. Entrenamiento y evaluación de la performance del modelo	Para cada experimento: 3.1 Ejecutar experimentos (modificando arquitecturas del modelo predictivo y sus hiper-parámetros). 3.2 Entrenar el algoritmo con datos del training-set. 3.4 Validar el modelo entrenado con valores nuevos (<i>testing set</i>). 3.5 Calcular error de predicción. 3.6 Tabular resultados y seleccionar los modelos con mejor ajuste.	<ul style="list-style-type: none"> • Diseño de experimentos • Entrenar y validar modelo predictivo • Métricas de error de predicción
	4. Optimización de la performance del modelo	Para cada modelo elegido: 4.1 Afinar los hiper-parámetros del modelo predictivo (previa selección del algoritmo). 4.2 Aplicar técnicas de optimización de hiper-parámetros. 4.3 Calcular el nuevo error de predicción. 4.4 Tabular y evaluar los resultados de predicción.	<ul style="list-style-type: none"> • Diseño de experimentos • Opt. de aprendizaje • Métricas de error de predicción
	5. Identificación del mejor modelo	5.1 Graficar serie temporal: real vs pronosticado (por cada modelo predictivo). 5.3 Elegir el mejor modelo.	<ul style="list-style-type: none"> • Trade-off (bias y varianza)
Pronóstico	6. Pronóstico de valores futuros	6.1 Emplear datos nuevos (que no hayan sido utilizados en el entrenamiento) para realizar predicciones con el modelo elegido.	<ul style="list-style-type: none"> • Pronóstico de valores futuros

Elaboración propia a partir de “*Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model*” (Parmezan et al., 2019) y “*The analysis of time series: An introduction with R, 7th edition*” (Chatfield, 2019).

7.3 Diseño de experimento

El diseño de experimentos consiste en planear una serie de pruebas, con una configuración diferente entre sí, para obtener resultados y conclusiones de forma válida y objetiva. En este contexto, el diseño de experimentos facilitó el proceso de búsqueda para encontrar el modelo predictivo con mayor precisión; es decir, seleccionar la red neuronal artificial y la configuración de sus hiper-parámetros que consiga mínimo error de predicción en el pronóstico de la exportación mensual de banano orgánico.

En este sentido, se definieron dos tipos de experimentos para evaluar la performance de los cuatro tipos de redes neuronales artificiales a ser estudiadas (MLP, RNN, LSTM y GRU), en concordancia con la pregunta de investigación de la presente tesis (ver Capítulo 1, Sección 1.1). La **Tabla 12** presenta el diseño de experimentos, el cual incluye los objetivos para cada tipo de experimentos y los hiper-parámetros de las redes neuronales artificiales que fueron modificados para encontrar el modelo predictivo que asegure el mejor ajuste para el pronóstico de valores futuros.

Tabla 12.

Diseño de experimentos.

Pregunta de investigación	Experimentos	Configuración de hiper-parámetros
RQ1: ¿Puede el modelado a base de Redes Neuronales Recurrentes (RNN, LSTM y GRU) superar el performance del modelo a base de redes neuronales artificiales clásicas (MLP) para el modelado y pronóstico de series de tiempo?	Experimento tipo 1: Encontrar el período retrospectivo más adecuado.	Experimento 1.1 <i>Look back</i> = {3, 6, 12 meses}
	Experimento tipo 2: Descubrir la arquitectura más eficiente para la red neuronal artificial (MLP, RNN, GRU, LSTM).	Experimento 2.1 <u>Para MLP:</u> N° neuronas = {4, 8, 16, 32, 64} <u>Para RNN, LSTM y GRU:</u> N° unid recurrents = {8, 16, 32, 64, 128}

Como resultado de este diseño de experimentos, se generó 60 modelos con diferente configuración de hiper-parámetros entre sí para ser entrenados y evaluados. En todos los experimentos, se configuró los siguientes parámetros para facilitar el proceso de entrenamiento y validación de los modelos predictivos:

- **Número de capas:** Se dispone con 224 y 25 datos de la serie de tiempo para el entrenamiento y la validación respectivamente. De forma preliminar, se entrenó las redes neuronales con una y dos capas ocultas. Con la primera opción, se obtuvo mejores resultados. Por tal, se trabajó sistemáticamente en encontrar el número de neuronas necesarias en la capa oculta para obtener un óptimo entrenamiento.
- **Número de épocas:** Se entrenó todos los modelos predictivos entre 20 y 30 épocas para observar la influencia de este parámetro en la red neuronal artificial.

- **Función de activación:** Para los modelos con RNN, LSTM y GRU, se utilizó la *tanH* como función de activación debido a que es intrínseca del algoritmo de las redes neuronales recurrentes. En contraste, para la red neuronal perceptrón (MLP) se empleó *ReLU* como función de activación.
- **Optimizador:** Adam fue el optimizador elegido para optimizar iterativamente los pesos de la red neuronal artificial, utilizando el error cuadrático medio (MSE) como función de pérdida (curva *loss*). Este optimizador ofrece velocidad de aprendizaje adaptativa.
- **Batch Size:** Las redes neuronales fueron entrenadas con un *batch size* igual a 8. Este valor de *batch size* es divisor del total de muestras de entrenamiento para facilitar el cálculo computacional.
- **Early stopping:** Se aplicó la técnica *early stopping* (también conocido como “parada anticipada”) con el parámetro *patience* igual a 10. Es decir, el entrenamiento de la red neuronal finaliza automáticamente solo si no hay una mejora de la métrica de error en 10 épocas seguidas (disminución de curva *loss*).
- **Dropout:** En vista que el dataset de entrenamiento tiene 224 muestras, se requirió pocas neuronas en la arquitectura de la red neuronal para modelar la no-linealidad de la serie temporal. Por tal, para evitar reducir el número de neuronas, la técnica del *dropout* no fue empleada en el proceso de entrenamiento del modelo predictivo.

La **Figura 28** esboza el diagrama de flujo del diseño de experimentos. Este diagrama explica la secuencia de pasos para la ejecución del entrenamiento, validación y evaluación de los 60 modelos predictivo con la finalidad de identificar el modelo con mejor performance, de forma válida y objetiva. En ese sentido, la **Tabla 13** presenta la configuración completa de los experimentos para cada modelo (MLP, RNN, LSTM, y GRU) y los valores de sus hiper-parámetros.

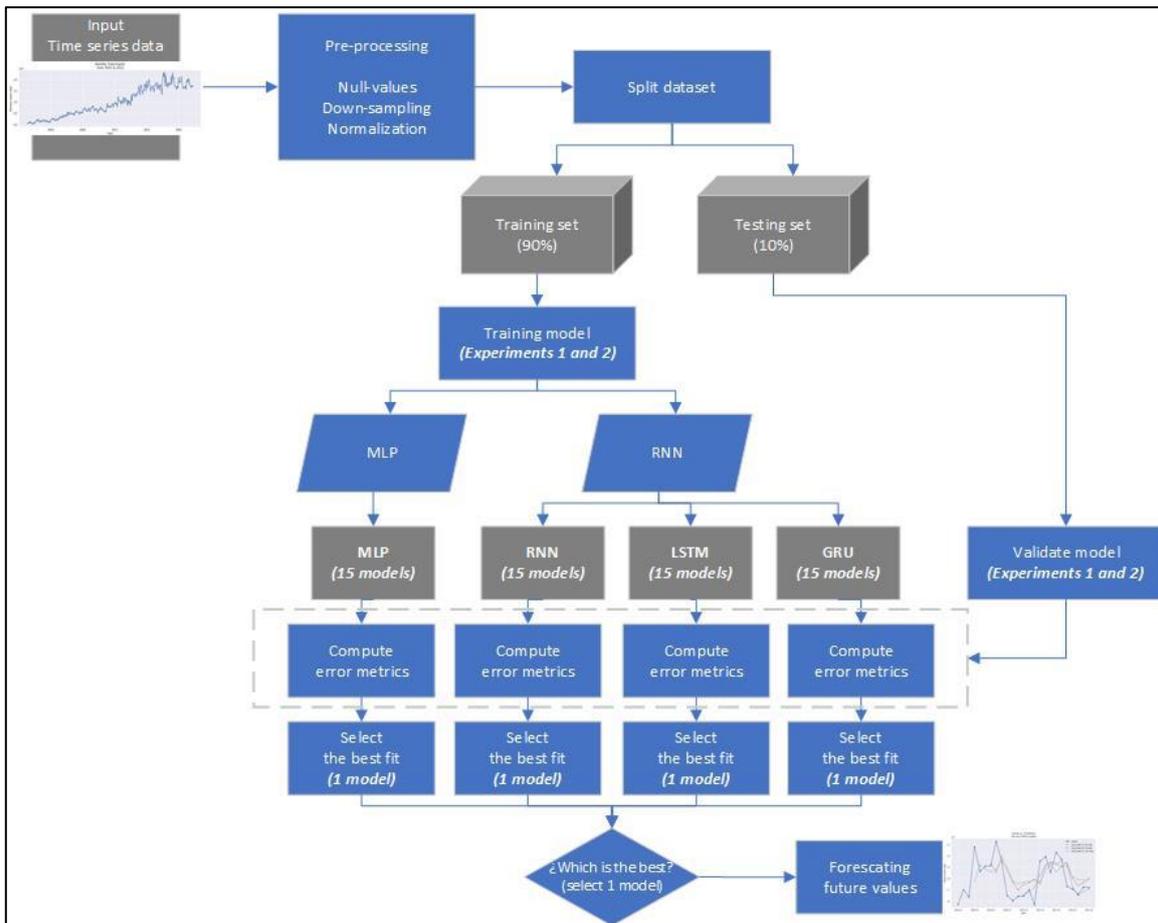
Tabla 13.

Modelos propuestos y configuración de sus hiper-parámetros.

Modelo	Hiper-Parámetros	Valores	Métricas de error
MLP	Look back	{3,6,12}	MSE, RMSE, MAE, MAPE, R ²
	Capa oculta	{1}	
	Neuronas por capa oculta	{4, 8, 16, 32, 64}	
	Optimizador	{Adam}	
RNN, LSTM y GRU	Look back	{3,6,12}	MSE, RMSE, MAE, MAPE, R ²
	Capa oculta	{1}	
	Unids. recurrentes por capa oculta	{8, 16, 32, 64, 128}	
	Optimizador	{Adam}	

Figura 28.

Flujograma del diseño de experimentos.



Elaborado a partir de “*Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model*” (Parmezan et al., 2019).

A continuación, se explica la dinámica de cada tipo de experimento, detallando la configuración de los hiper-parámetros de las redes neuronales puestas a prueba (revisar **Tabla 12** y **Tabla 13**)

7.3.1 Experimento tipo 1

El primer experimento consistió en validar el período retrospectivo más adecuado para el entrenamiento de cada red neuronal artificial (MLP, RNN, LSTM y GRU). Cada red neuronal se entrenó con 3 valores de periodo retrospectivo, también llamado *look back*. La finalidad de este experimento es elegir el *look back* que garantice la mayor precisión en el pronóstico de los valores de la serie de tiempo.

- **Look back:** Este hiper-parámetro representa el número de observaciones pasadas de la serie temporal, dado un tiempo terminado. El tamaño del *look back* influye en la cantidad de muestras para entrenar los algoritmos de aprendizaje automático (MLP,

RNN, LSTM y GRU). Por tal motivo, se testeó la performance de la red neuronal con un *look back* de 3 meses, 6 meses y 12 meses.

7.3.2 Experimento tipo 2

El segundo experimento consistió en validar la arquitectura más eficiente para cada tipo de red neuronal artificial evaluada (MLP, RNN, LSTM y GRU). Se evaluó diversas arquitecturas con la finalidad de elegir aquella que asegure obtener el menor error de predicción. En ese sentido, la arquitectura de red neuronal se configuró de la siguiente manera:

- **Número de capas ocultas:** En testeó el desempeño de cada red neuronal con 1 capa oculta para evitar el *overfitting* (sobre ajuste).
- **Número unidades recurrentes por capa:** La arquitectura de las redes neuronales recurrentes (RNN, LSTM y GRU) fueron testeadas con {8, 16, 32, 64, y 128} unidades recurrentes por capa oculta. Estos son potencia de 2 para optimizar el cálculo computacional.
- **Número de neuronas por capa:** La arquitectura de la red neuronal Perceptrón (MLP) se testeó con {4, 8, 16, 32, 64} neuronas por capa oculta.

Consecuentemente, se entrenó los cuatro tipos de red neuronal (MLP, RNN, LSTM y GRU) según las configuraciones del experimento tipo 1 y 2. Los hiper-parámetros de cada red neuronal fueron optimizados considerando minimizar la curva *loss* y aplicando el *trade-off* del bias-varianza (ver Sección 7.4.5).

Como resultado de todos los experimentos (ver Figura 28), se identificó la mejor arquitectura para cada tipo de red neuronal con el menor error de predicción posible. A partir de estos cuatro modelos elegidos, se seleccionó el modelo con mejor ajuste y mayor eficiencia en el pronóstico.

7.4 Técnicas y métodos

Esta sección presenta las técnicas y métodos empleados para el modelado de la serie de tiempo en estudio.

7.4.1 Re-muestreo

Las series temporales pueden ser re-muestreadas para aumentar o disminuir la frecuencia de tiempo de los datos, empleando métodos de agregación. Existen dos tipos de

métodos de re-muestreo de series de tiempo: *down-sampling* y *up-sampling* (Brownlee, 2020). La **Figura 29** representa la aplicación de ambas técnicas de re-muestreo a un conjunto de datos temporales.

i) Down-sampling

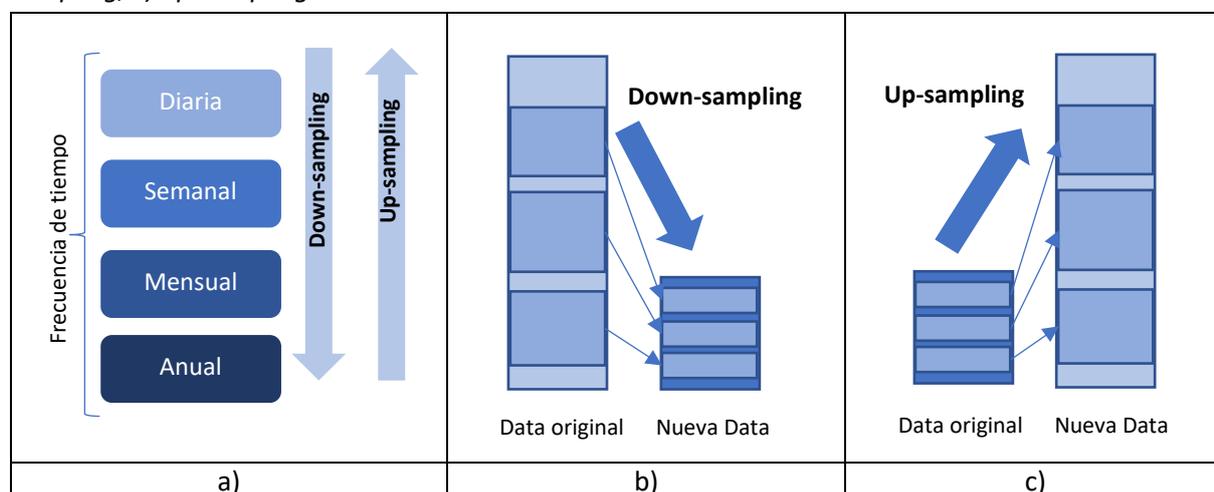
La técnica *down-sampling* permite generar observaciones a una escala más grande que la frecuencia de observación actual (Brownlee, 2020). El *down-sampling* reduce el número de muestras mediante la disminución de frecuencia de la serie de tiempo. Por ejemplo, cambiar la frecuencia de: (i) diario a semanal, (ii) semanal a mensual, (iii) mensual a trimestral, (iv) trimestral a anual, y así sucesivamente. Esta técnica aplica métodos de agregación tales como: suma, mínimo, máximo, conteo, media, mediana, entre otros.

ii) Up-sampling

La técnica *up-sampling* muestrea observaciones desde cualquier frecuencia de tiempo a una frecuencia más pequeña (Brownlee, 2020). El *up-sampling* aumenta el número de observaciones en la serie de tiempo. Por ejemplo, cambiar la frecuencia de: (i) anual a trimestral, (ii) trimestral a mensual, (iii) mensual a semanal, (iv) semanal a diario, y así sucesivamente. Este método se complementa con otras técnicas de interpolación para llenar valores vacíos.

Figura 29.

Técnicas de re-muestreo para para serie temporal: a) Cambios de las frecuencias de tiempo; b) down-sampling; c) up-sampling.



Elaborado a partir de "How to prepare data and develop models to predict the future" de (Brownlee, 2020).

Para el caso de la serie de tiempo de la exportación de banano orgánico peruano, la base de datos registra las exportaciones diarias (ver Sección 6.2.1). Por tal motivo, se aplicó la técnica *down-sampling*, con agregación de suma, para calcular el total de exportaciones mensuales de ene-2001 a set-2021.

7.4.2 Normalización

La normalización consiste en realizar un cambio de escala de los datos. De tal manera que se encuentren dentro del nuevo rango de $[0,1]$ para facilitar al cálculo computacional, minimizar el tiempo de entrenamiento y optimizar la curva de aprendizaje del algoritmo. En la presente investigación, se aplicó la técnica *min-max scaler* para normalizar los datos de la serie de tiempo de la exportación de banano orgánico peruano. Los datos normalizados se obtuvieron mediante la siguiente fórmula (Lara-Benítez et al., 2021):

$$x_{normalizado} = \frac{x_i - x_{min}}{x_{max} - x_{min}}$$

Donde:

x_i representa el valor original de la serie temporal (datos para entrenamiento).

x_{max} y x_{min} representan los valores máximo y mínimo de la secuencia original (inputs).

y_{norm} representa los valores normalizados (input del modelo).

Después de normalizar los datos originales x_i , el rango de datos obtenidos y_{norm} es $[y_{min}, y_{max}]$, dado $y_{min} = 0$ y $y_{max} = 1$.

7.4.3 División de datos (*training-set* y *testing-set*)

Los modelos predictivos con algoritmos de Machine Learning realizan la división del dataset (*training-set* y *testing-set*) de manera aleatoria. Ello aumenta la eficiencia en el proceso de entrenamiento del algoritmo de aprendizaje automático.

Sin embargo, las series de tiempo son observaciones secuenciales recopiladas en intervalos de tiempos iguales. Dado que estos períodos de tiempo son adyacentes entre sí, existe la dependencia temporal entre las observaciones. Por tal, la división del dataset de series de tiempo para entrenamiento y validación del modelo debe respetar la temporalidad de los datos. Los detalles del método usado para la división de datos están explicados en la Sección 7.5.5.

7.4.4 Métricas de error de predicción

Durante el proceso de entrenamiento del algoritmo de aprendizaje automático, se requiere evaluar su performance. La presente investigación empleó cinco métricas para evaluar la precisión de la predicción del modelo propuesto: Mean Squared Error (MSE), Root Relative Square Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE) y Factor de Correlación (R^2). Las métricas de error tal como MSE, RMSE, y MAE

dependen de la escala de medida. Sin embargo, MAPE y R^2 son métricas con escala independiente (sin unidad de medida).

Las métricas MAE, RMSE, MAPE permiten evaluar el nivel de error de los resultados de predicción respecto a los valores reales de la serie de tiempo. Mientras estas métricas sean más bajas, hay una mayor precisión de pronóstico. Por otro lado, la métrica R^2 permite evaluar las condiciones de ajuste entre los resultados de la predicción y los datos reales. Mientras que los valores de R^2 están más cerca de 1, se refleja el mejor ajuste del modelo.

Las fórmulas de cada métrica son presentadas, considerando que: y_i es el valor real observado, \hat{y}_i es el valor pronosticado con el modelo, y N es el tamaño de las muestras del dataset:

i) Mean Squared Error (MSE)

Mide el promedio de los errores de predicción. Calcula el promedio de la diferencia entre el valor pronosticado y el valor real. Se expresa de la siguiente manera (Abraham et al., 2020):

$$MAE(y_i - \hat{y}_i) = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}$$

ii) Root Mean Square Error (RMSE)

Es la medida de la desviación estándar de los errores de predicción; es decir, los residuos. Los residuos se refieren a la desviación de los puntos de datos alrededor de la línea de mejor ajuste. de la línea de regresión. Se determina con la siguiente expresión matemática (Kouadio et al., 2018):

$$RMSE(y_i - \hat{y}_i) = \sqrt{\frac{\sum_{i=1}^N (|y_i - \hat{y}_i|)^2}{N}}$$

iii) Mean Absolute Error (MAE)

Mide el promedio de los errores de predicción. Calcula el promedio de la diferencia absoluta entre el valor pronosticado y el valor real. Se expresa de la siguiente manera (Abraham et al., 2020):

$$MAE(y_i - \hat{y}_i) = \frac{\sum_{i=1}^N |y_i - \hat{y}_i|}{N}$$

iv) Mean absolute percentage error (MAPE)

Mide el promedio de los errores de predicción. Calcula la diferencia absoluta entre el valor pronosticado y el valor real; luego, lo promedia con las N muestras utilizadas para la validación del modelo. Se expresa, en valor porcentual (%), de la siguiente manera (Fang & Yuan, 2019):

$$MAPE(y_i - \hat{y}_i) = \frac{\sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i}}{N} (\%)$$

v) Factor de Correlación (R^2)

Es el cuadrado de la medida del coeficiente de correlación. Explica la relación de las variables; es decir, mide el ajuste de regresión lineal. Cuanto más se acerque este número a uno, más ajustado será el modelo. Sin embargo, una medida superior a 0,7 es satisfactoria. Se expresa de la siguiente manera (Kouadio et al., 2018) (Abraham et al., 2020):

$$R^2(y_i - \hat{y}_i) = \frac{\sum_{i=1}^N [(y_i - y_{mean})(\hat{y}_i - \hat{y}_{mean})]}{\sqrt{\sum_{i=1}^N (y_i - y_{mean})^2} \sqrt{\sum_{i=1}^N (\hat{y}_i - \hat{y}_{mean})^2}}$$

Donde:

N es el tamaño de las muestras del test set

y_i es el valor real observado

y_{mean} es el promedio de los valores real observados

\hat{y}_i es el valor pronosticado con el modelo

\hat{y}_{mean} es el promedio de los valores pronosticados

7.4.5 Trade-off: *bias* y *varianza*

Quando se trabaja en el entrenamiento y validación de modelos predictivos con algoritmos de aprendizaje supervisado, se recomienda construir un modelo con el menor *bias* frente a la *varianza* del conjunto de datos de entrenamiento.

i) **Bias**

El *bias*, o también llamado sesgo, indica la inexactitud de la predicción del modelo en comparación con el valor real. Un alto valor de *bias* aparece cuando se simplifica el modelo y se consiguen valores erróneos o inexactos en el proceso de entrenamiento. Este efecto es conocido como *under-fitting*.

ii) **Varianza**

La *varianza* indica las variaciones de los resultados de pronósticos del modelo cuando se emplean nuevos datos de entrenamiento. Una alta *varianza* aparece por el modelado del ruido presente en los datos de entrenamiento, lo que implica que el modelo es demasiado sensible a los datos de entrenamiento. Este efecto es conocido como *over-fitting*.

La **Figura 30** esquematiza la influencia de *bias* y la *varianza* en la exactitud y precisión de la predicción del modelo. La meta es construir un modelo que ofrezca un equilibrio entre

el *bias* y la varianza: menor error de predicción para valores futuros de la serie temporal, alta precisión para datos nuevos de entrenamiento, y moderada-baja complejidad computacional.

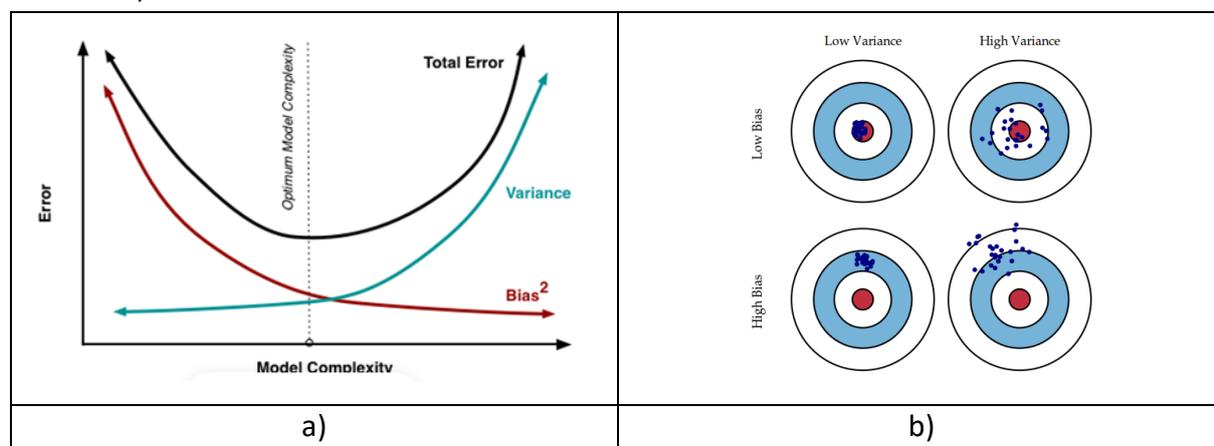
Para afrontar este desafío, la literatura recomienda aplicar las siguientes técnicas en el proceso de entrenamiento y validación del modelo predictivo:

- **Simplificar el modelo:** Usar menos capas o menos neuronas para hacer la red neuronal más pequeña, y de menor complejidad computacional.
- **Reducir la dimensionalidad en los datos de entrenamiento:** Entrenan el modelo con datos en una dimensión más pequeña para disminuir la complejidad del modelo.
- **Usar más datos para el entrenamiento:** Entrenar el modelo con la mayor cantidad posible de datos disponible. Se pueden emplear *up-sampling* (re-muestreo) para aumentar el número de observaciones en la serie temporal.
- **Aplicar *early stopping* en el entrenamiento:** Aplicar “parada anticipada” en el entrenamiento, cuando la curva del *testing-set* no haya mejorado después de varias iteraciones de entrenamiento.
- ***Cross-validation*:** Dividir los datos de entrenamiento inicial en *K-fold* subconjuntos y entrena el modelo *K* veces. En cada entrenamiento, utiliza un subconjunto como datos de entrenamiento y el resto como datos de validación.

En ese sentido, luego de evaluar la relevancia y factibilidad cada técnica ante el modelado y pronóstico de la serie de tiempo en estudio, se aplicó las siguientes técnicas: modelo simplificado, datos con baja dimensionalidad, re-muestreo de datos, y *early stopping*.

Figura 30.

Trade-off: Efectos del bias y la varianza en a) error de predicción del modelo, b) exactitud y precisión de valores pronosticados.



Adaptado de “Evaluating time series forecasting models” (Cerqueira et al., 2020).

7.5 Dataset

Esta sección presenta los resultados de un análisis exploratorio y descriptivo del dataset que contiene los datos reales de la variable a modelar.

7.5.1 Variable temporal

La variable de la presente investigación es la demanda internacional del banano orgánico peruano a lo largo de los últimos 20 años. En ese sentido, la demanda internacional es cuantificada mediante el volumen de exportación año a año. Cabe recalcar que las exportaciones de banano orgánico provienen de cosechas en diversas ciudades del país.

Para fines la presente investigación, esta variable es definida como una serie de tiempo univariable. Asimismo, se seleccionó el siguiente el período de tiempo para estudiar exportación de banano orgánico peruano: desde enero de año 2001 hasta setiembre de 2021 (fecha de corte). En ese sentido, los valores secuenciales de la serie de tiempo nos permiten estudiarla para realizar el modelado y, posteriormente, el pronóstico de sus valores futuros.

7.5.2 Fuente de datos

Los datos originales de la serie de tiempo empleados en esta investigación se recopilaron de su fuente principal: Sunat-Perú. Los datos históricos de las exportaciones (diarias y a nivel nacional) están alojados en el “Registro de Declaraciones de Exportación Definitiva” de Aduanet-Sunt-Perú. Por tal, este repositorio es representativo y relevante para la presente investigación.

El dataset en mención fue descargado vía la web oficial de la Operatividad Aduanera de Sunat-Perú^{19 20}. A este registro nacional de exportaciones se aplicó el filtro “Código de Partida Arancelaria”. Para el caso de exportaciones de banano orgánico, se usó la Partida Arancelaria N°0803901100-*bananas orgánicas verdes frescas en cajas*.

7.5.3 Calidad de datos

En el dataset, se identificó errores de tipeo por causas humanas: error en consignar la partida arancelaria, error en la descripción comercial (referencia a otro agro-producto), y/o descripción de presentación. Para fines del caso de estudio, se eliminó todo registro de exportación que no haya consignado la partida arancelaria y como descripción comercial al banano orgánico. La **Tabla 14** resume la fase de la exploración de datos siguiendo los

¹⁹ <http://www.aduanet.gob.pe/operatividadAduana/>

²⁰ <http://www.aduanet.gob.pe/aduanas/informgest/ExpoDef.htm>

lineamientos de Shearer (2000). Se concluye que la base de datos tiene una media-alta madurez.

Tabla 14.

Dataset: revisión explotaría - analítica.

Categoría	Detalle	Descripción
Relevancia	Alta	La BD almacena todas las exportaciones de banano orgánico desde el año 2001 a la fecha (2021). La BD cuenta con más de 10 variables en el registro de cada declaración de exportación.
Calidad	Media	No hay valores nulos ni vacíos, pero hay errores de tipeo por causas humanas.
Frecuencia	Diario	La BD registra a diario cada declaración de exportación presentado ante Aduanas.
Granularidad	Media	El nivel de detalle se concentra en variables como fecha (día, mes y año), el país de destino, RUC del exportador, y aforo

Elaborado a partir de “*The CRISP-DM Model: The New Blueprint for Data Mining*” (Shearer, 2000).

7.5.4 Tamaño de la base de datos

Los datos originales de la serie de tiempo se recolectados en una frecuencia de tiempo diario, a lo largo de 7,577 días de enero del año 2001 a setiembre del año 2021 (20 años, 8 meses, y 29 días). Aplicando la técnica *down-sampling* y agregación de suma, se obtiene la serie de tiempo mensual y la serie anual, la cuales contienen 249 muestras y 21 muestras respectivamente. El tamaño del dataset es fijo debido a que sólo cuenta con datos en el período de tiempo indicado.

La **Tabla 15** presenta el número de muestras para cada frecuencia de tiempo. Complementariamente, se sugiere revisar el Capítulo 6, Sección 6.2.1, donde se presentan las gráficas *time-plot* de estas cuatro series temporales.

Tabla 15.

Tamaño del dataset según frecuencia de tiempo.

Down-sampling	Frecuencia de tiempo	Muestras
	Diario (original)	7,577
	Semanal	1,083
	Mensual (empleado en la tesis)	249
	Anual	21

7.5.5 Pre-procesamiento

Como parte de la metodología, se realizó un pre-procesamiento al dataset original, de acuerdo a lo propuesto por Hewamalage et al. (2021). A continuación, se describe los pasos que fueron realizados:

i) Data cleaning

Los datos de entrada son esenciales para el entrenamiento eficiente de los modelos de Machine Learning. Por ello, se realizó un *data cleaning*. Se verificó la cantidad de valores faltantes o valores nulos en el dataset. Por ejemplo, determinar en qué fecha no se registró datos en la serie de tiempo. Estos deben ser reemplazados por otros valores sustitutos, usando técnicas como la interpolación lineal o la media de valores cercanos. Luego de realizar en el dataset de las exportaciones de banano orgánico, no se encontraron valores faltantes, ni valores nulos.

ii) División de datos (train-test)

En los modelos de Machine Learning, la división de los datos para el entrenamiento y validación seguir una de estas proporciones: 70% y 30%, 80% y 20%, 90% y 10%. Con la finalidad de elegir el ratio *training-testing* más adecuado para el modelado de serie de tiempo, se analizó estudio la influencia del número de datos de entrenamiento para el ratio 80-20, 90-10 y 95-05. La **Tabla 16** describe cada una de estas opciones, detallando la cantidad de muestras que contiene y el intervalo de tiempo que representa. Asimismo, la **Figura 31** esquematiza la cantidad de datos el entrenamiento y validación aplicando los ratios definidos en la **Tabla 16**.

Dado la serie de tiempo que cuenta con 249 muestras, se decidió asignar la mayor cantidad de muestras posibles para el entrenamiento (*training-set*). Se estableció que el *testing-set* incluya al menos el último año de la serie de tiempo para modelar su estacionalidad.

Por tal, se empleó la siguiente proporción 90-10: 90% de datos para el *training-set* y 10% de datos para el *validation-set*. Es decir, el conjunto de datos de entrenamiento del modelo predictivo consta de las primeras 224 muestras (18 años aprox) del dataset; y las restantes 25 muestras (2 años aprox) para la validación del modelo. Estos datos se usan para desarrollar todos los experimentos definidos en el Capítulo7, Sección 7.2.

7.5.6 Software y hardware

Los experimentos fueron ejecutados con un equipo Intel(R) Core i3 - 7th Gen. Los experimentos fueron ejecutados con entorno de software Python 3.7. La **Tabla 17** presenta detalles adicionales del hardware y software.

Se empleó *Colaboratory* de *Google*, un entorno gratuito de *Jupyter notebook* que se ejecuta completamente en la nube. Los paquetes de librerías usados fueron *numpy*, *pandas*, *matplotlib*, *sklearn*, entre otros. Todos los experimentos fueron implementados con *Keras*, un software de código abierto para el cálculo numérico y gráficos de datos. El código fuente y el

dataset empleados en este estudio están disponibles para su descarga en: https://github.com/ealmeydaa/TSF_BananaExport.git

Tabla 16.

División del dataset según ratio training-testing.

Tamaño del dataset (período de tiempo)	Ratio (Train – Test)	Muestras (Train – Test)	Tiempo (Train / Test)
249 muestras (20 años y 9 meses)	95% - 5%	237 - 12	19 años y 9 meses / 1 año
	90% - 10%	224 - 25	18 años y 8 meses / 2 años y 1 mes
	80% - 20%	199 - 50	16 años y 7 meses / 4 años y 2 meses

Figura 31.

Training-set y testing-set según ratio: a) 95-05, b) 90-10, c) 80-20.

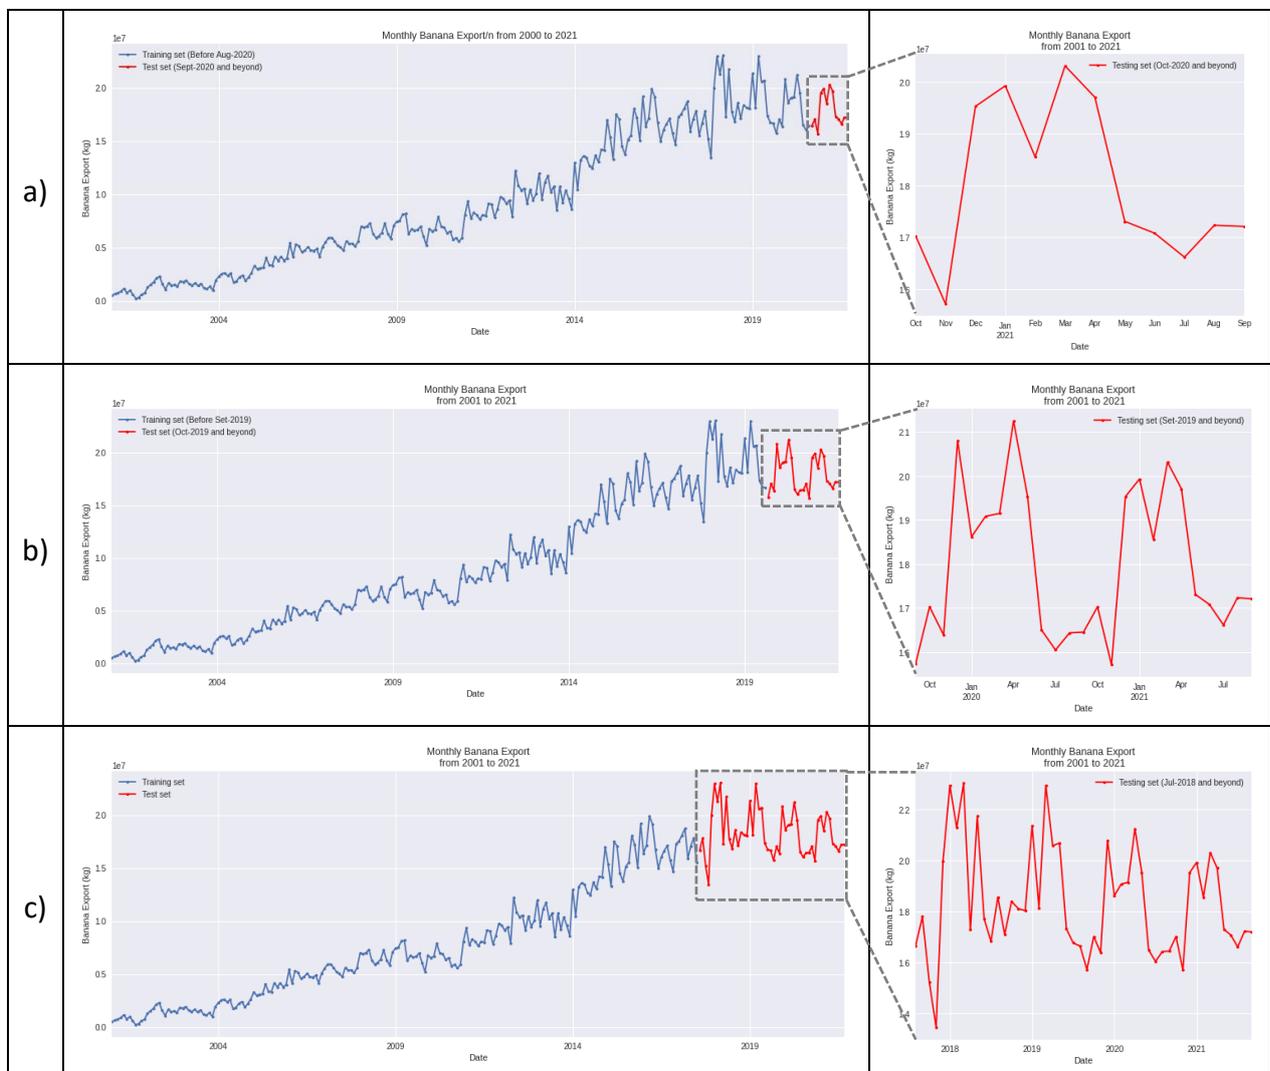


Tabla 17.*Especificaciones del hardware y software.*

Especificación	Recurso
CPU modelo	Intel(R) Core(TM) i3-7020U
CPU arquitectura	x64
Memoria (GB)	4.00
Framework	Colab de Google
Software environment	Jupyter notebook con Python 3.7.



Capítulo 8

Resultados y discusión

Este capítulo presenta los resultados de la evaluación de los modelos entrenados para el pronóstico de la exportación de banano orgánico. La sección 8.1 describe los resultados de las pruebas experimentales en los modelos MLP, RNN, LSTM, y GRU. Seguidamente, se presenta la arquitectura y los hiper-parámetros de la red neuronal artificial con mejor performance. La sección 8.2 discute los resultados del mejor modelo predictivo respecto a los resultados reportados en el Estado del Arte.

8.1 Resultados

En esta sección se presenta los resultados derivados del diseño de experimentos (revisar Capítulo 7, Sección 7.2) para el entrenamiento y validación de los modelos de aprendizaje automático supervisado del tipo red neuronal artificial: MLP, RNN estándar, LSTM y GRU. Las redes neuronales fueron entrenadas con datos recolectados desde enero de 2001 a setiembre de 2021. Las pruebas experimentales se realizaron entre octubre, noviembre y diciembre de 2021. Se configuró 15 arquitecturas diferentes para cada red neuronal (60 modelos en total) para identificar aquel modelo que ofrezca mejor *fit* o el menor error de predicción en el pronóstico de la exportación de banano orgánico como serie de tiempo. Los resultados fueron analizados en base a:

- **Efecto del tamaño del look back:**

Se entrenó los modelos con diferentes valores del hiper-parámetro horizonte de retrosección: *look back*={3, 6, 12}. Para ello se analizó la curva *loss* y la eficiencia del entrenamiento en cada iteración. Esta curva de entrenamiento usó la función de pérdida MSE (*loss*) en cada iteración.

- **Efecto del número de unidades recurrentes:**

Se entrenó los modelos con diferentes valores de unidades recurrentes = {8, 16, 32, 64, 128} o neuronas = {4, 8, 16, 32, 64} en la arquitectura neuronal, analizando las métricas de error de predicción con los datos del *testing-set*; y analizando el tiempo de procesamiento que empleó cada modelo en la etapa de entrenamiento y validación.

- **Valores actuales vs pronosticados**

Se evaluó los modelos considerando el nivel de precisión de los datos reales de la serie de tiempo (*testing-set*) y los valores pronosticados con los mejores modelos entrenados en cada escenario de *look back*. Se ploteó los valores de forma gráfica para facilitar la visualización de la precisión en la tendencia y la estacionalidad de la serie de tiempo.

8.1.1 Modelo MLP

A continuación, el análisis de los resultados experimentales de los 15 modelos MLP:

i) Look back

La **Figura 32 a)** expone la curva *loss* de los datos del *testing-set* para tres diferentes valores de *look back*: 3, 6 y 12 meses. En los tres escenarios de *look back*, las curvas tuvieron complicaciones para converger. Particularmente, los modelos con pocas neuronas (4 y 8 neuronas) no favoreció al aprendizaje automático de la red neuronal: inician con valores de error muy altos, o se quedan en un mínimo local. Análogamente, para los tres escenarios de *look back*, el modelo MLP con 32 neuronas se comportan mejor que el resto; sin embargo, la curva *loss* presentó complicaciones para divergencia alrededor de las primeras iteraciones.

En ese sentido, la **Figura 32 b)** presenta los mejores modelos MLP para cada escenario de *look back*. Estos son los siguientes: 32 unidades, 32 unidades y 16 unidades para el *look back* de 3 meses, 6 meses y 12 meses respectivamente. Considerando estos tres modelos, el modelo MLP con mejor performance se consiguió configurando el parámetro *look back* de 6 meses con 32 neuronas.

ii) Número de neuronas

La **Tabla 18** tabula los valores de las métricas de error para la red neuronal MLP con diferentes números de neuronas por capa oculta. Se observa que para un mismo valor de *look back*, el error de predicción disminuyó conforme aumentó el número de neuronas. Sin embargo, para la red neuronal MLP con 64 unidades recurrentes en los tres escenarios de *look back*: aumentó significativamente el error de predicción respecto al resto de modelos entrenados.

En ese sentido, la **Figura 33** traza los valores de error de predicción para los modelos MLP entrenados con diferentes el número de neuronas y tamaños de *look back* (3, 6 y 12 mese). Para los tres escenarios de *look back*, los modelo MLP con 32 unidades recurrentes obtuvo el error más pequeño, lo cual indica que es un buen modelo para el pronóstico de la serie temporal. Finalmente, el mejor modelo MLP se consiguió configurando un *look back* de 12 meses y con 32 unidades recurrentes.

Figura 32.

Modelo MLP: Efecto de la variación del look back en la curva Loss del testing-set.

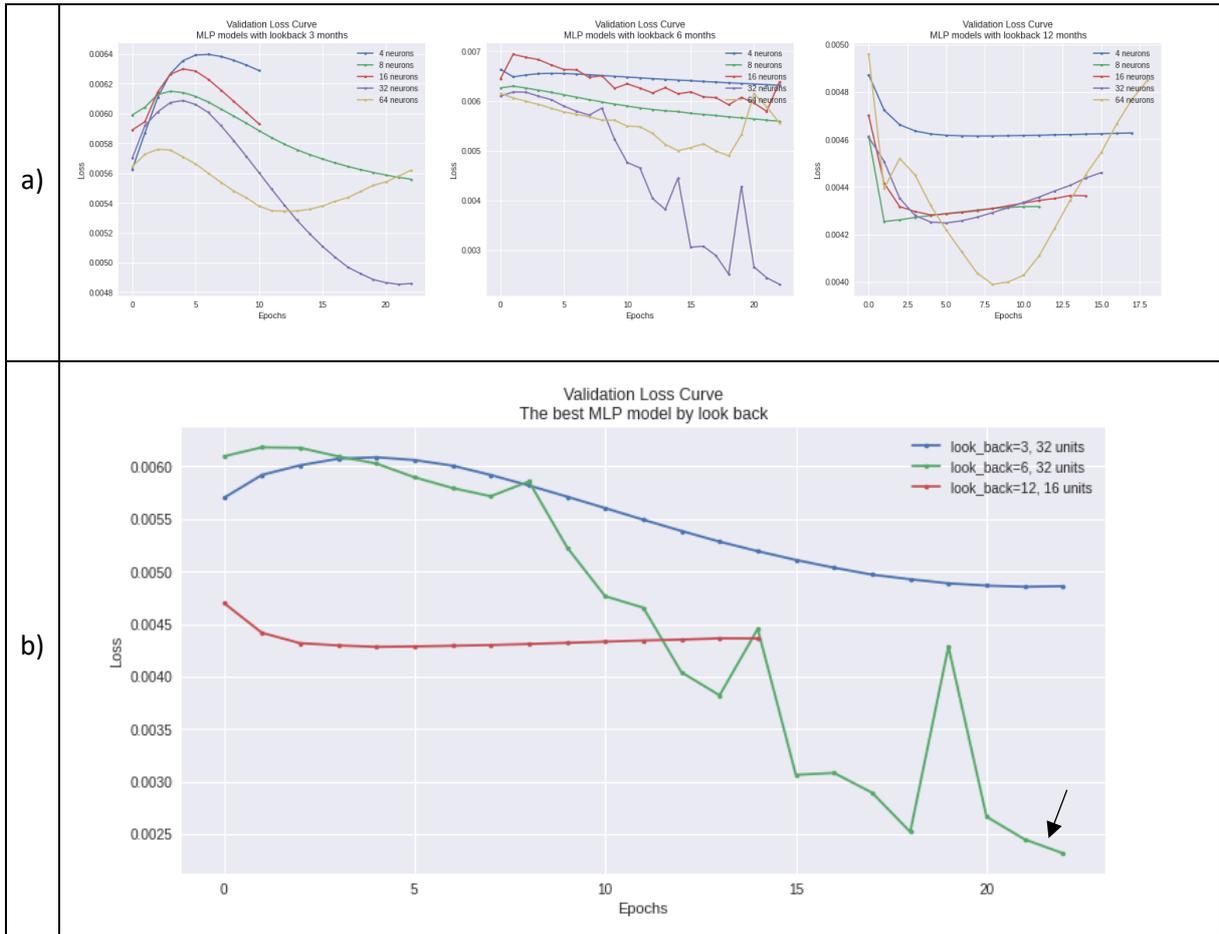


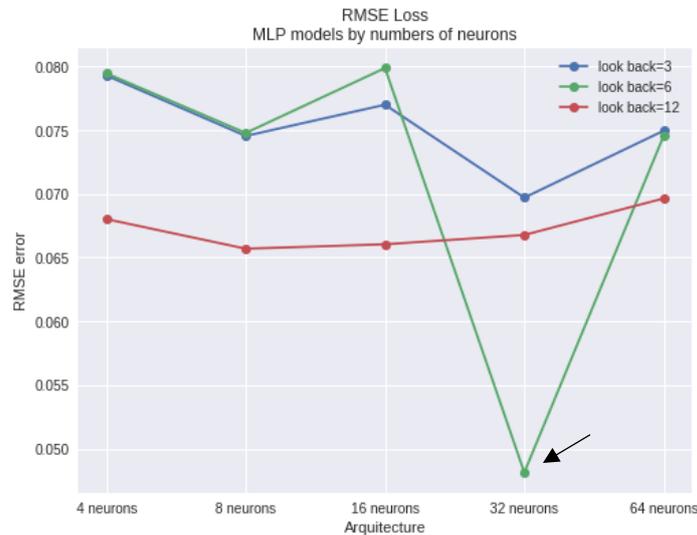
Tabla 18.

Modelo MLP: Performance en testing-set con diferentes valores parámetros.

Look back (meses)	Neuronas	MSE	RMSE	MAE	MAPE	R ²	T. Train (seg.)	T. Test (seg.)
3	4	0.00629	0.07930	0.05796	5.79601	-1.16	12.34	0.29
	8	0.00556	0.07456	0.05601	5.60100	-1.99	23.39	0.25
	16	0.00593	0.07701	0.05612	5.61166	-1.56	12.88	0.26
	32	0.00486	0.06972	0.05902	5.90201	-2.91	26.15	0.25
	64	0.00562	0.07497	0.06479	6.47909	-6.07	41.29	0.27
6	4	0.00632	0.07948	0.06840	6.83972	-3.96	25.75	0.26
	8	0.00559	0.07480	0.06422	6.42210	-3.96	25.53	0.28
	16	0.00638	0.07989	0.06881	6.88142	-6.11	32.16	1.29
	32	0.00232	0.04813	0.03903	3.90303	0.05	55.02	0.24
	64	0.00556	0.07455	0.06503	6.50334	-4.11	28.46	0.25
12	4	0.00463	0.06803	0.06289	6.28886	-12.98	28.94	0.26
	8	0.00432	0.06571	0.05958	5.95823	-6.32	16.01	0.63
	16	0.00436	0.06605	0.05996	5.99615	-7.26	22.87	0.24
	32	0.00446	0.06678	0.06137	6.13713	-11.00	33.49	0.27
	64	0.00485	0.06965	0.06444	6.44362	-16.53	41.97	0.23

Figura 33.

Modelo MLP: Efecto del número de neuronas en el cálculo del error RMSE del testing-set.



iii) Pronóstico vs real

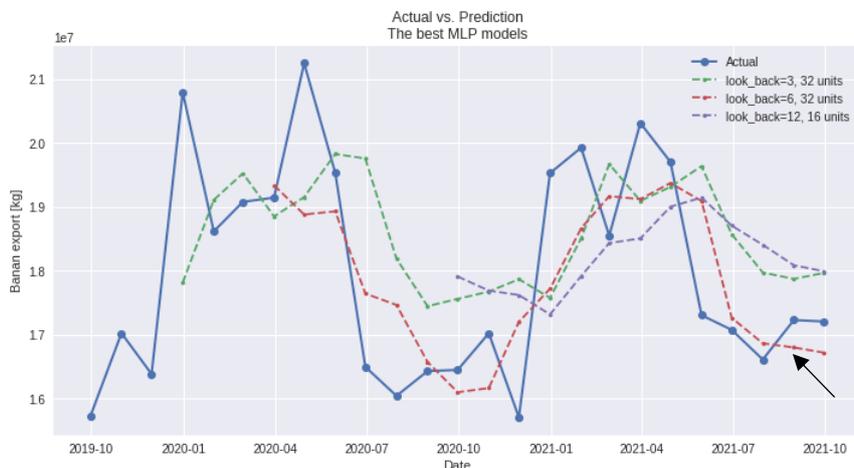
La **Figura 34** grafica los valores pronosticados con los mejores modelos MLP para cada escenario de *look back*. De los tres modelos seleccionados, sólo el modelo MLP de 32 neuronas y *look back* de 6 meses ofreció la mayor precisión para aproximarse a la tendencia y la estacionalidad de la serie de tiempo original. Mientras que los otros dos modelos presentan *under-fitting* (*high bias*) en los valores pronosticados.

iv) MLP: El mejor fit

De acuerdo a lo explicado anteriormente, y evaluando el *trade-off* entre *bias* y varianza, el mejor modelo MLP se configura con los siguientes hiper-parámetros: *look back*= 6 meses y unidades recurrentes=32.

Figura 34.

Los mejores modelos MLP: Valores reales vs valores pronosticados.



8.1.2 Modelo RNN

A continuación, el análisis de los resultados experimentales de los 15 modelos RNN estándar:

i) Look back

La **Figura 35 a)** presenta la curva *loss* de los datos del *testing-set* para tres diferentes valores de *look back*: 3, 6 y 12 meses. Para estos tres escenarios de *look back*, el modelo con 8 unidades recurrentes ofreció un incipiente entrenamiento, debido a que la curva *loss* disminuyó lentamente. Similarmente, en los tres escenarios del *look back*, el modelo con 128 unidades recurrentes impactó negativamente en el entrenamiento, debido a que su arquitectura neuronal está saturada y demanda mayor esfuerzo computacional: error aumenta y el tiempo de entrenamiento también.

En el escenario *look back* = 3 meses, las curvas *loss* disminuyeron en cada iteración, a excepción de los modelos con 64 y 128 unidades recurrentes, aquellas curvas divergieron a partir de la iteración n°5. En el escenario *look back* = 6 meses, las curvas *loss* descendieron progresivamente en cada iteración. Sin embargo, el gradiente del modelo con 64 unidades recurrentes ubicó un mínimo local al inicio del entrenamiento, con lo cual no puedo continuar con la disminución del *loss*. Mientras que el modelo con 128 unidades recurrentes estuvo muy inestable para converger al valor mínimo. En el escenario del *look back* = 12 meses, las curvas *loss* de los modelos con 32 y 64 unidades recurrentes decrecieron rápidamente en cada iteración y lograron converger al mínimo valor.

Luego del análisis anterior, la **Figura 35 b)** presenta los mejores modelos RNN estándar para cada escenario de *look back*. Estos son los siguientes: 32 unidades, 32 unidades y 64 unidades para el *look back* de 3 meses, 6 meses y 12 meses respectivamente. Considerando estos tres modelos, el modelo RNN estándar con mejor performance se consiguió configurando el parámetro *look back* igual a 12 meses y con 64 unidades recurrentes.

ii) Número de unidades recurrentes

La **Tabla 19** expone los valores de las métricas de error para la red neuronal RNN con diferentes unidades recurrentes. Se observa que para un mismo valor de *look back*, el error disminuyó conforme aumentó el número de unidades recurrentes. Asimismo, mientras aumentó el tamaño del *look back*, el error de predicción fue más pequeño. En ese sentido, mientras se define más datos de entrada para entrenar la red neuronal (*look back* más grande) y más unidades recurrentes, aumenta la precisión del pronóstico de valores de la serie de tiempo.

Figura 35.

Modelo RNN simple: Efectos de la variación del look back en la curva Loss del testing-set.

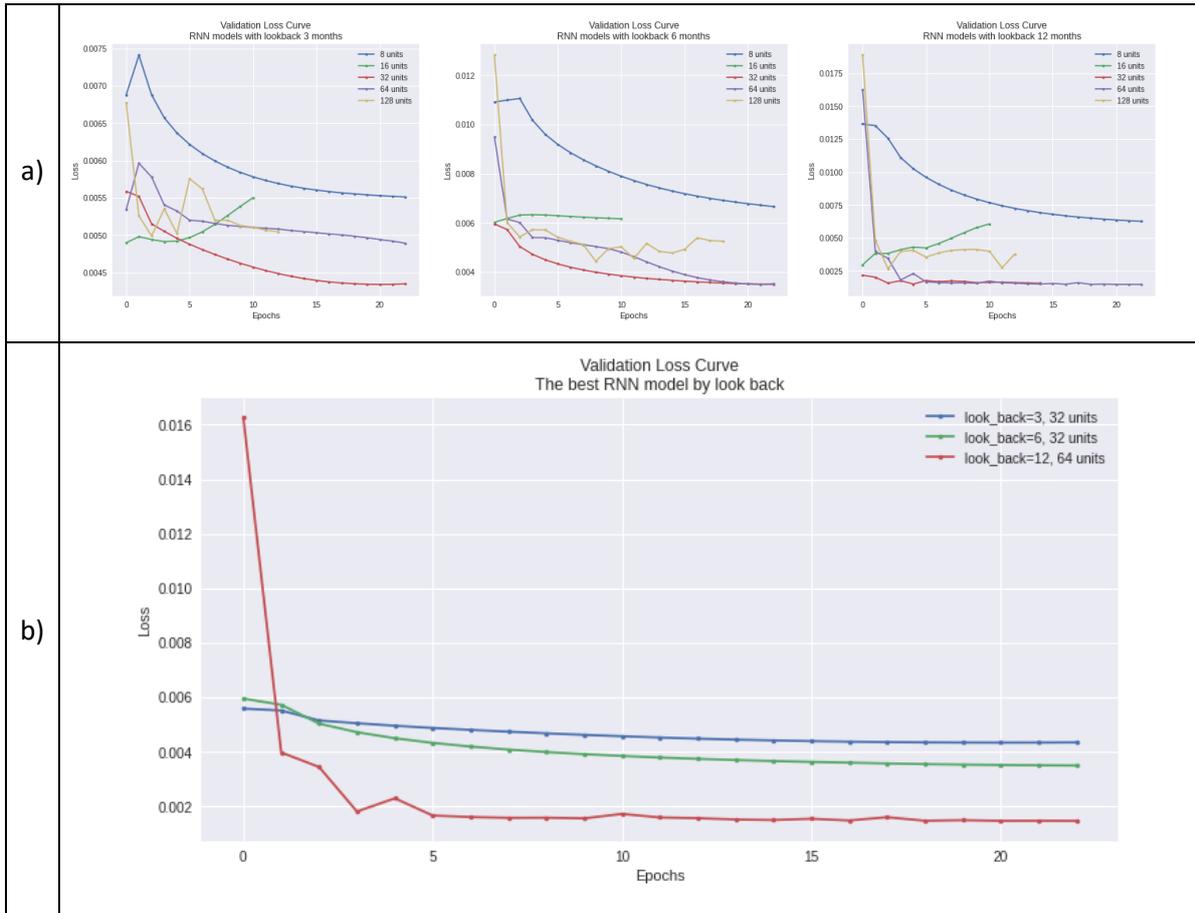


Tabla 19.

Modelo RNN simple: Performance en testing-set con diferentes valores parámetros.

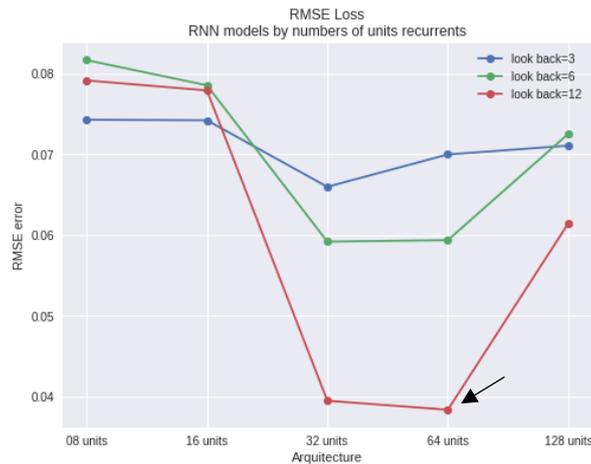
Look back (meses)	UR*	MSE	RMSE	MAE	MAPE	R ²	T. Train (seg.)	T. Test (seg.)
3	8	0.00551	0.07424	0.06364	6.36389	-3.38	16.08	0.20
	16	0.00550	0.07418	0.06410	6.40981	-7.26	7.62	0.23
	32	0.00435	0.06595	0.05630	5.63016	-4.86	20.60	0.21
	64	0.00489	0.06995	0.05195	5.19521	-1.91	23.77	0.24
	128	0.00505	0.07104	0.05296	5.29582	-1.37	13.13	0.22
6	8	0.00666	0.08162	0.07202	7.20237	-7.55	23.10	0.25
	16	0.00616	0.07850	0.07021	7.02070	-7.64	11.91	0.21
	32	0.00350	0.05917	0.05024	5.02407	-1.45	24.34	0.26
	64	0.00352	0.05935	0.05000	4.99959	-1.47	22.36	0.23
	128	0.00526	0.07251	0.06360	6.36014	-2.87	20.70	0.21
12	8	0.00626	0.07910	0.07076	7.07626	-4.88	23.80	0.26
	16	0.00606	0.07787	0.06780	6.78042	-5.00	13.86	0.25
	32	0.00156	0.03949	0.02990	2.99008	0.31	17.83	0.22
	64	0.00147	0.03838	0.02885	2.88516	0.44	25.85	0.22
	128	0.00377	0.06144	0.05006	5.00594	-1.28	15.55	0.59

*Unidades recurrentes

La **Figura 36** esboza los valores de error de predicción para los modelos RNN entrenados con diferentes valores de unidades recurrente y tamaños de *look back* (3, 6 y 12 meses). Para los tres escenarios de *look back*, los modelo RNN estándar con 32 y 64 unidades recurrentes obtuvieron los errores más pequeños. Finalmente, el mejor modelo RNN estándar se consiguió configurando un *look back* de 12 meses y con 64 unidades recurrentes.

Figura 36.

Modelo RNN simple: Efecto del número de unidades recurrentes en el error RMSE del testing-set.

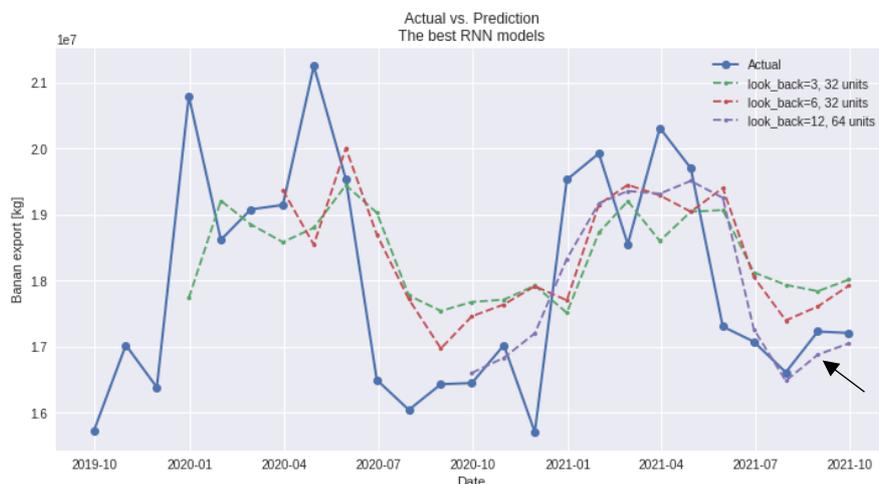


iii) Pronóstico vs real

La **Figura 37** presenta los valores pronosticados con los mejores modelos RNN para cada escenario de *look back*. En general, los valores pronosticados consiguieron acercarse a los valores reales de la serie de tiempo. De estos modelos seleccionados, los dos modelos RNN con 32 unidades recurrentes presentaron similares resultados para los escenarios con *look back* de 3 y 6 meses. En contraste, el modelo RNN con 64 unidades recurrentes y *look back* de 12 meses se ajusta más a las estacionalidades de la serie temporal en los meses de baja demanda de la exportación de banano.

Figura 37.

Los mejores modelos RNN simple: Valores reales vs valores pronosticados.



iv) RNN estándar: El mejor fit

De acuerdo a lo explicado anteriormente, y evaluando el *trade-off* entre *bias* y *varianza*, el modelo RNN simple con mejor *fit* se configura con los siguientes hiperparámetros: *look back*=12 meses y unidades recurrentes=64.

8.1.3 Modelo LSTM

A continuación, el análisis de los resultados experimentales de los 15 modelos LSTM:

i) Look back

La **Figura 38 a)** expone la curva *loss* de los datos de validación (*testing-set*) para tres diferentes valores de *look back*: 3, 6 y 12 meses. En los tres escenarios de *look back* (3, 6 y 12 meses), los modelos con 8, 16 y 32 unidades recurrente ofrecieron un incipiente entrenamiento, debido a que la curva *loss* divergió desde las primeras iteraciones. Una posible causa está relacionada al tamaño del *learning rate*: con un *learning rate* muy grande, la curva *loss* empieza a divergir; y, por ende, la red neuronal no aprende a generalizar.

En contraste, en los tres escenarios de *look back*, los modelos con 64 y 128 unidades recurrentes ofrecieron un comportamiento favorable en el entrenamiento de la red neuronal. Debido a que la curva *loss* disminuyó constantemente hasta la iteración n°15; sin embargo, empezó a divergir de ahí en adelante.

En ese sentido, la **Figura 38 b)** presenta los mejores modelos LSTM. Estos son los siguientes: 128 unidades, 128 unidades y 128 unidades para el *look back* de 3 meses, 6 meses y 12 meses respectivamente. Considerando estos tres modelos, el modelo LSTM con mejor performance se consiguió configurando el *look back* de 12 meses y con 128 unidades recurrentes.

ii) Número de unidades recurrentes

La **Tabla 20** tabula los valores de las métricas de error para la red neuronal LSTM con diferentes unidades recurrentes. Se observa que para un mismo valor de *look back*, el error disminuyó conforme aumentó el número de unidades recurrentes. En ese sentido, mientras se definió más datos de entrada para entrenar la red neuronal (*look back* más grande) y más unidades recurrentes, aumentó la precisión del pronóstico de valores de la serie de tiempo.

La **Figura 39** expone los valores de error de predicción para los modelos LSTM entrenados con diferentes valores de unidades recurrente y tamaños de *look back* (3, 6 y 12 meses). Para los tres escenarios de *look back*, los modelo LSTM con 128 unidades recurrentes lograron obtener los errores más pequeños que el resto de modelos. De manera general, se infiere que el error disminuyó mientras aumenta el *look back* y el número de unidades recurrentes. Finalmente, el mejor modelo LSTM se consiguió configurando un *look back* de 12 meses con 128 unidades recurrentes.

Figura 38.

Modelo LSTM: Efecto de la variación del look back en la curva Loss del testing-set.

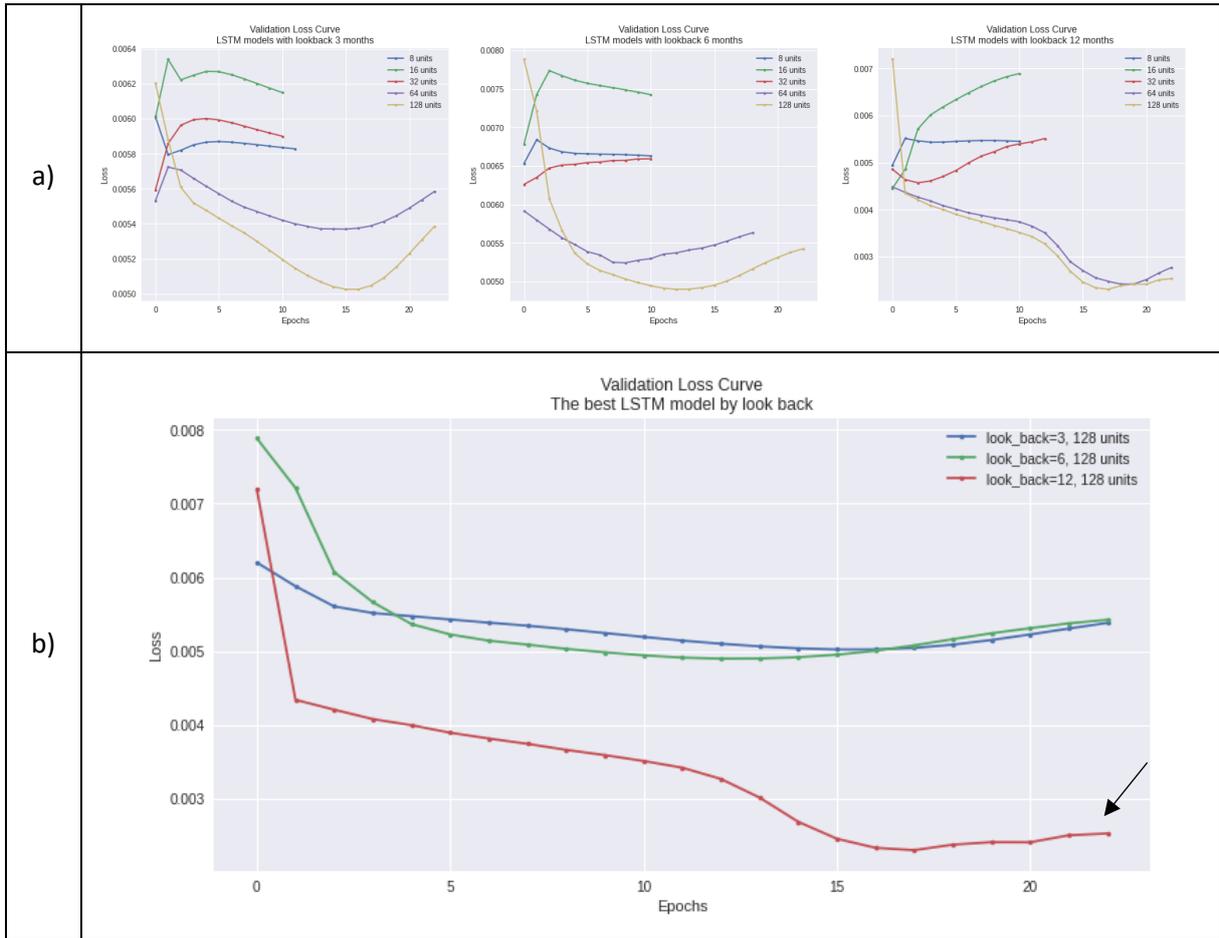


Tabla 20.

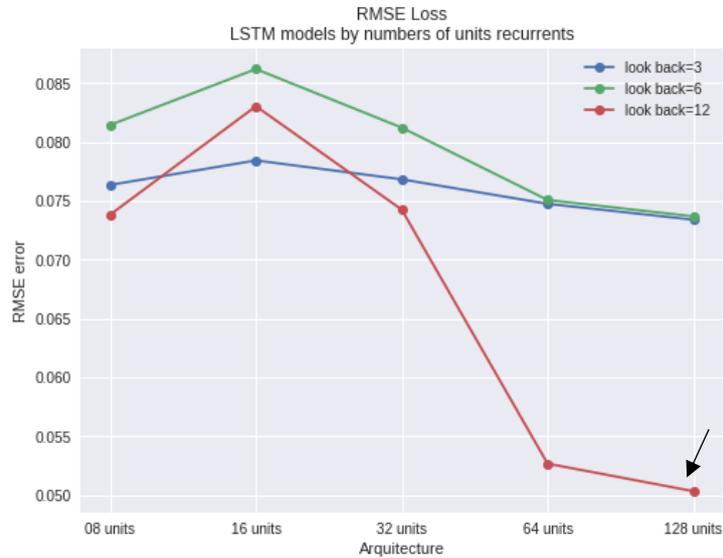
Modelo LSTM: Métricas de error de predicción según look back.

Look back (meses)	UR*	MSE	RMSE	MAE	MAPE	R ²	T. Train (seg.)	T. Test (seg.)
3	8	0.00583	0.07634	0.05835	5.83515	-2.22	16.01	0.59
	16	0.00615	0.07842	0.05950	5.95016	-2.23	13.90	0.58
	32	0.00590	0.07681	0.05897	5.89648	-2.51	14.09	1.05
	64	0.00559	0.07473	0.06304	6.30351	-5.11	27.15	0.59
	128	0.00539	0.07339	0.06257	6.25733	-7.37	28.93	0.53
6	8	0.00663	0.08143	0.07124	7.12428	-7.42	13.71	0.60
	16	0.00743	0.08618	0.07572	7.57150	-9.94	14.29	0.49
	32	0.00659	0.08120	0.07094	7.09381	-8.41	15.71	0.55
	64	0.00563	0.07506	0.06587	6.58741	-7.61	25.53	0.53
	128	0.00543	0.07367	0.06493	6.49274	-8.74	46.13	0.52
12	8	0.00545	0.07381	0.06782	6.78223	-18.68	15.76	0.46
	16	0.00689	0.08302	0.07431	7.43101	-134.86	19.17	0.54
	32	0.00551	0.07424	0.06859	6.85856	-33.76	29.63	0.59
	64	0.00278	0.05267	0.04415	4.41474	-0.74	51.92	0.54
	128	0.00253	0.05033	0.04293	4.29295	-0.84	77.81	0.50

*Unidades recurrentes

Figura 39.

Modelo LSTM: Efecto del número de unidades recurrentes en el error RMSE del testing-set.

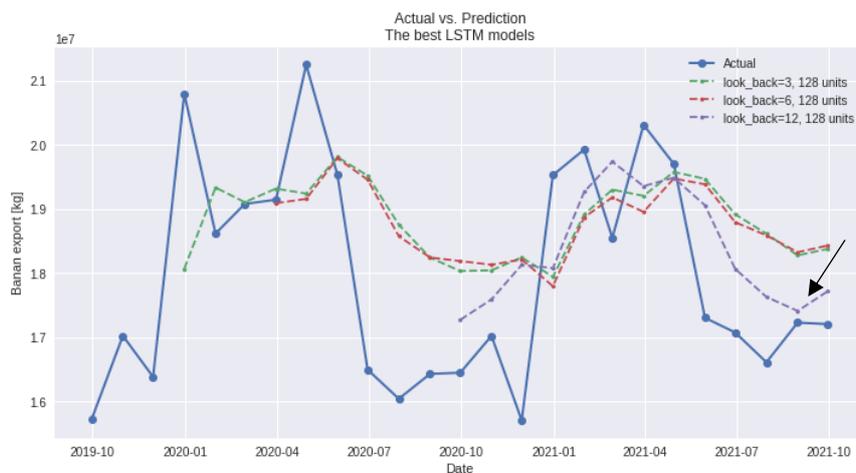


iii) Pronóstico vs real

La **Figura 40** plotea los valores pronosticados con los mejores modelos LSTM para cada escenario de *look back*. De estos modelos seleccionados, los dos modelos LSTM con 128 unidades recurrentes para los escenarios con *look back* de 3 y 6 meses, evidencia un *under-fitting* (*high bias*). Es decir, bajo nivel de precisión en los valores pronosticados respecto a los valores reales de la serie de tiempo. En contraste, el modelo LSTM con 128 unidades recurrentes y *look back* de 12 meses se ajustaron mejor a las estacionalidades de la serie temporal en estudio.

Figura 40.

Los mejores modelos LSTM: Valores reales vs valores pronosticados.



iv) LSTM: El mejor fit

De acuerdo a lo explicado anteriormente, y evaluando el *trade-off* entre *bias* y *varianza*, el modelo LSTM con mejor *fit* se configura con los siguientes hiper-parámetros: *look back*=12 meses y unidades recurrentes=128.

8.1.4 Modelo GRU

A continuación, el análisis de los resultados experimentales de los 15 modelos GRU:

i) Look back

La **Figura 41 a)** expone la curva *loss* de los datos del *testing-set* para tres diferentes valores de *look back*: 3, 6 y 12 meses. Para estos tres escenarios de *look back*, el modelo con 8 unidades recurrentes ofreció el peor desempeño, debido a que la curva *loss* obtuvo los mayores valores de *loss*. En los tres escenarios del *look back*, ningún modelo consiguió valores óptimos del *loss*. En algunos casos particulares, la curva *loss* presentó un comportamiento anómalo y divergió a partir de la iteración n°5 (*look back*=3 meses) e iteración n°15 (*look back*=12 meses). Ello demostró un deficiente entrenamiento con las arquitecturas de la red neuronal del modelo GRU.

En el escenario del *look back* = 12 meses, las curvas *loss* del modelo con 64 y 128 unidades recurrentes presentaron el mejor desempeño respecto al resto. La curva *loss* decreció progresivamente en cada iteración hacia converger en un valor mínimo.

Luego del análisis anterior, la **Figura 41 b)** presenta los mejores modelos GRU para cada escenario de *look back*. Estos son los siguientes: 128 unidades, 128 unidades y 64 unidades para el *look back* de 3 meses, 6 meses y 12 meses respectivamente. Considerando estos tres modelos, el modelo GRU con mejor performance se consiguió configurando el parámetro *look back* de 12 meses con 64 unidades recurrentes.

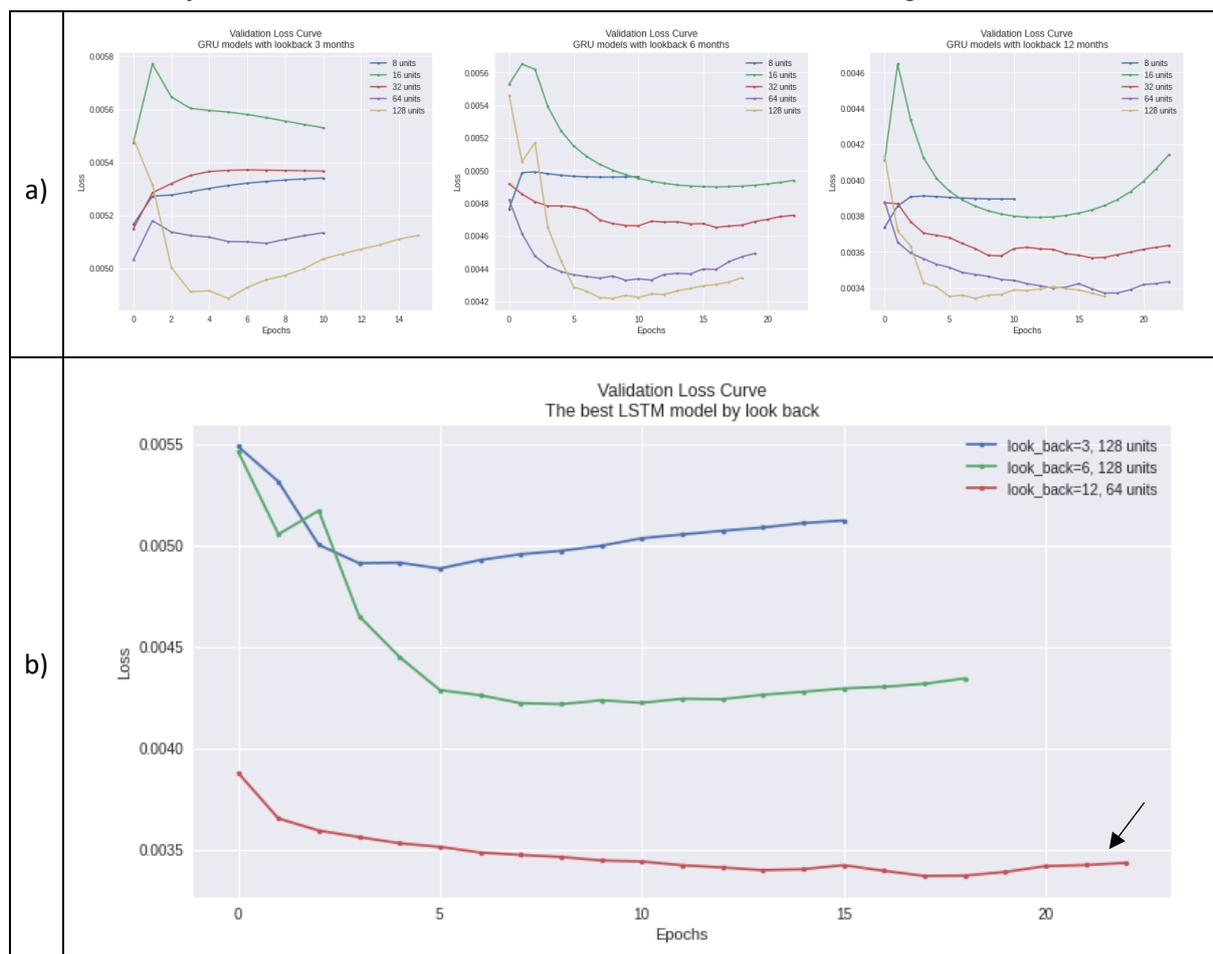
ii) Número de unidades recurrentes

La **Tabla 21** tabula los valores de las métricas de error para la red neuronal GRU con diferentes unidades recurrentes. Se observa que para un mismo valor de *look back*, el error disminuye conforme aumente el número de unidades recurrentes. Asimismo, mientras aumenta el tamaño del *look back*, el error de predicción es más pequeño.

La **Figura 42** traza los valores de error de predicción para los modelos GRU entrenados con diferentes valores de unidades recurrente y tamaños de *look back* (3, 6 y 12 meses). Particularmente, los modelos GRU con *look back* de 12 meses obtuvieron los mínimos errores respecto al resto. Finalmente, el mejor modelo GRU se obtuvo configurando un *look back* de 12 meses con 64 unidades recurrentes.

Figura 41.

Modelo GRU: Efecto de la variación del look back en la curva Loss del testing-set.

**Tabla 21.**

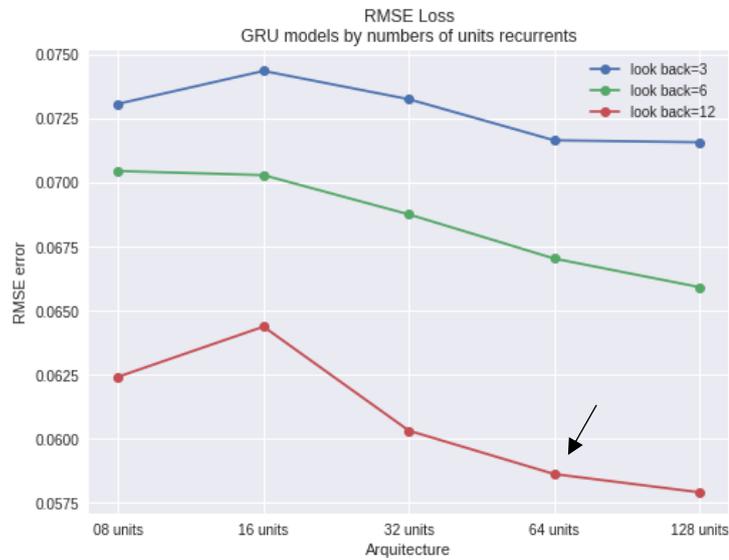
Modelo GRU: Métricas de error de predicción según look back.

Look back (meses)	UR*	MSE	RMSE	MAE	MAPE	R ²	T. Train (seg.)	T. Test (seg.)
3	8	0.00534	0.07308	0.05523	5.52256	-1.40	14.14	0.56
	16	0.00553	0.07437	0.05549	5.54883	-1.56	14.30	0.57
	32	0.00537	0.07326	0.05505	5.50544	-1.76	15.47	0.55
	64	0.00514	0.07166	0.05332	5.33227	-1.82	14.41	0.46
	128	0.00512	0.07158	0.05360	5.36022	-2.07	21.02	0.49
6	8	0.00496	0.07046	0.05754	5.75428	-1.65	15.21	0.46
	16	0.00494	0.07030	0.05904	5.90371	-2.10	29.62	0.52
	32	0.00473	0.06876	0.05685	5.68512	-1.78	35.46	0.57
	64	0.00449	0.06704	0.05508	5.50842	-1.90	32.55	0.53
	128	0.00435	0.06592	0.05274	5.27441	-1.90	31.97	0.53
12	8	0.00390	0.06242	0.05367	5.36651	-1.94	19.46	0.54
	16	0.00415	0.06438	0.05806	5.80595	-3.47	46.03	1.32
	32	0.00364	0.06032	0.05267	5.26673	-2.05	51.18	0.54
	64	0.00344	0.05862	0.05166	5.16595	-2.42	53.21	0.49
	128	0.00335	0.05791	0.04586	4.58602	-1.92	44.84	0.52

*Unidades recurrentes

Figura 42.

Modelo GRU: Efecto del número de unidades recurrentes en el error RMSE del testing-set.

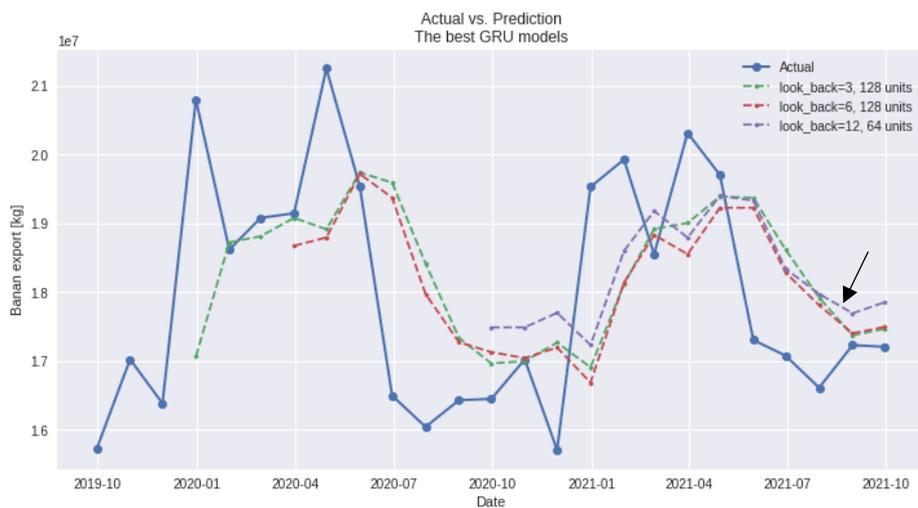


iii) Pronóstico vs real

La **Figura 43** grafica los valores pronosticados con los mejores modelos GRU para cada escenario de *look back*. Los tres mejores modelos entrenados obtuvieron resultados similares. Los valores pronosticados consiguieron aproximarse al comportamiento a la estacionalidad de los datos reales a lo largo del tiempo; no obstante, ofrecen un bajo nivel de precisión.

Figura 43.

Las mejores modelos GRU: Valores reales vs valores pronosticados.



iv) GRU: El mejor fit

De acuerdo a lo explicado anteriormente, y evaluando el *trade-off* entre *bias* y varianza, el mejor modelo GRU se configura con los siguientes hiper-parámetros: *look back*=12 meses y unidades recurrentes=64.

8.1.5 Mejores modelos

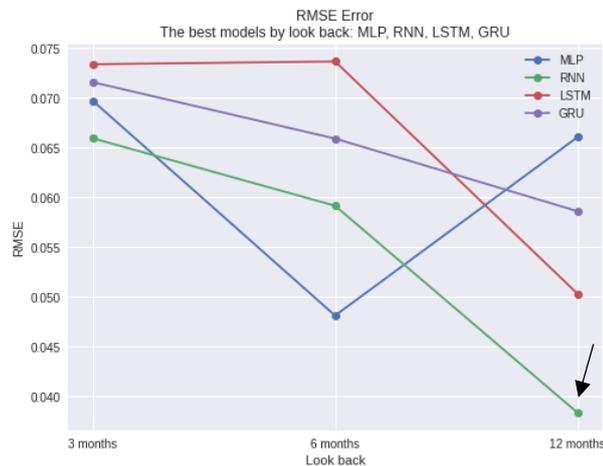
Consolidando los resultados, se reportan los 03 mejores modelos entrenados del total de 60 modelos testeados para el pronóstico de exportación de banano orgánico. Estos modelos son presentados de acuerdo a su performance: horizonte de retrospección (*look back*), *curva loss*, valores pronosticados, métricas de error alcanzadas, tiempo de procesamiento, e hiperparámetros.

i) Horizonte de retrospección

La **Figura 44** confirma que los modelos entrenados con datos de los últimos 12 meses (*look back* = 12) obtuvieron el mejor performance en la predicción de la serie temporal. Aquello se cumple para los modelos RNN, LSTM y GRU. No obstante, el modelo MLP consigue su mejor performance con datos de entrenamiento de los últimos 6 meses.

Figura 44.

Mejores modelos entrenados y la influencia del look back en el error RMSE del testing-set.



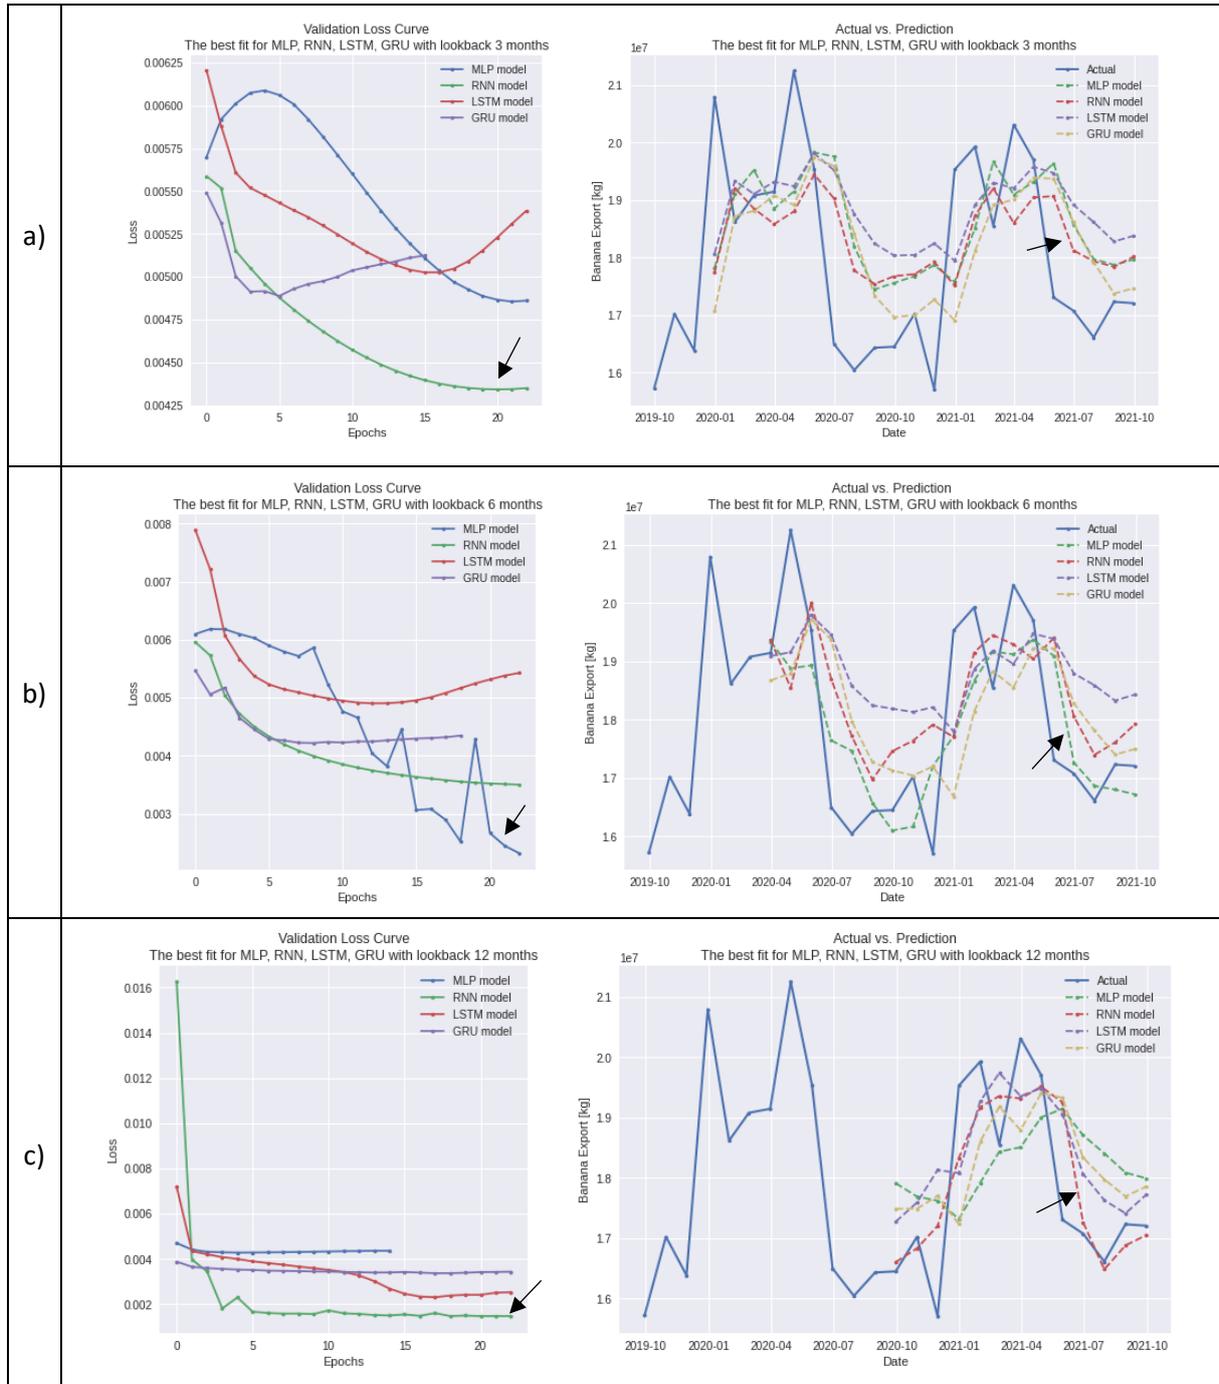
ii) Curva *loss* y valores pronosticados

La **Figura 45** agrupa el mejor modelo entrenado para cada tipo de red neuronal (ver secciones 8.1.1, 8.1.2, 8.1.3 y 8.1.4). Para un *look back* de 3 meses, el modelo RNN tiene mejor performance en la curva de aprendizaje; sin embargo, tiene un alto *bias* y por ende los valores pronosticados no se ajustan a los valores reales de la serie temporal. En el caso de un *look back* de 6 meses, el modelo MLP se aproxima significativamente a modelar la estacionalidad de la serie temporal; no obstante, el modelo RNN tiene mejor performance en la curva de aprendizaje. Finalmente, los modelos entrenados con un *look back* de 12 meses, son aquellos que obtienen el menor error de predicción en los datos del *testing-set*. En este caso particular, el modelo RNN cumple con obtener el mejor *fit* (menor error de predicción y valores pronosticados con una adecuada precisión en la tendencia y estacionalidad de la serie de tiempo real). Por lo tanto, el mejor modelo entrenado es la red neuronal RNN estándar de 1 capa con 64 neuronas y con *look back* de 12 meses.

Adicionalmente, se observó que mientras más compleja sea la arquitectura de la red neuronal recurrente, la curva de aprendizaje tiende a divergir. Por lo cual, se necesita ajustar los hiper-parámetros y entrenar el algoritmo con más iteraciones para alcanzar valores mínimos de error de predicción.

Figura 45.

Mejores modelos entrenados MLP, RNN, LSTM y GRU: Curva loss del testing-set y valores pronosticados para a) 3 meses, b) 6 meses y c) 12 meses de look back.



iii) Hiper-parámetros

En la **Tabla 22** se presenta los hiper-parámetros de los mejores modelos entrenados para cada tipo de red neuronal testada. Complementariamente, la **Figura 46** plotea los valores pronosticados de estos cuatro mejores modelos entrenados versus los valores reales de la serie de tiempo.

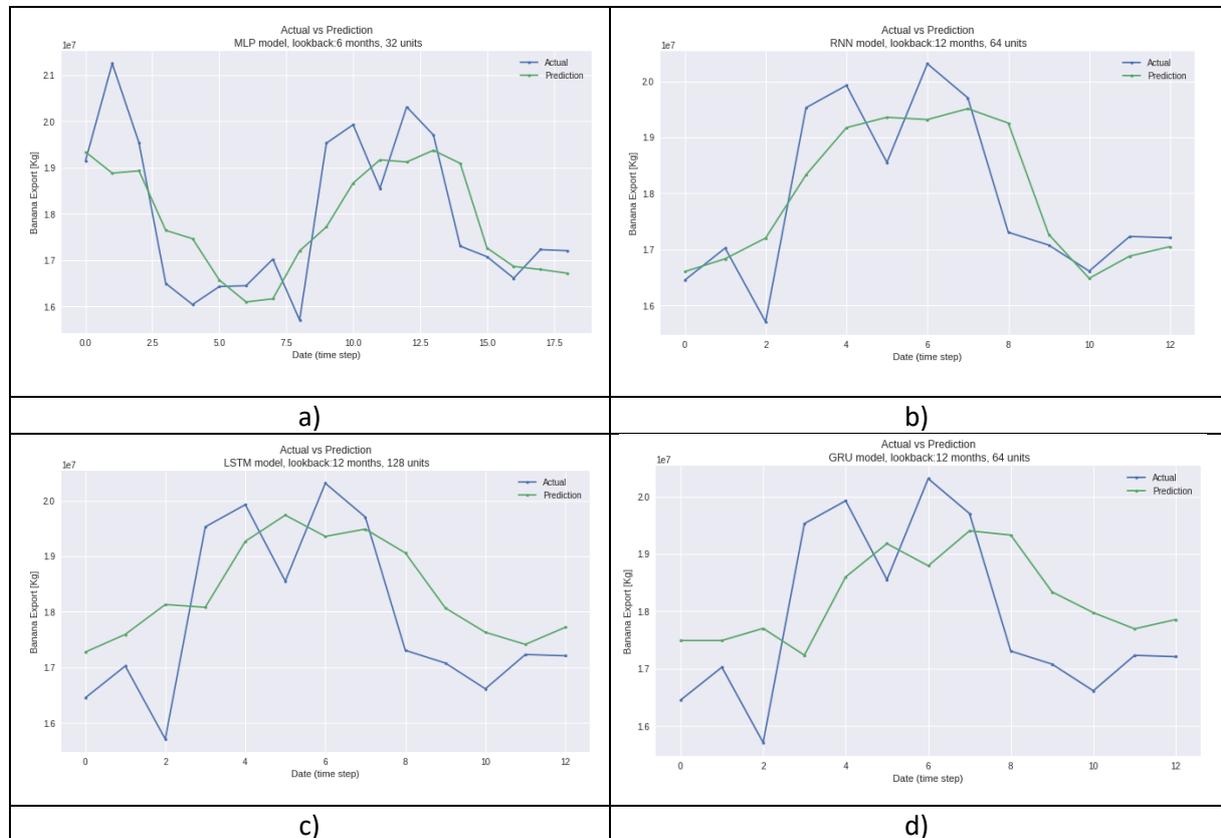
Tabla 22.

Mejores modelos entrenados: configuración de sus hiper-parámetros.

Parámetros	MLP	RNN	LSTM	GRU
Look back (meses)	{6}	{12}	{12}	{12}
Hidden Layer	{1}	{1}	{1}	{1}
Neuronas ó Unidades recurrentes	{32}	{64}	{128}	{64}
N° Epochs	25	25	25	25
Learning rate	{0.001}	{0.001}	{0.001}	{0.001}
Función de activación	ReLu	tanH	tanH	tanH
Loss function	MSE	MSE	MSE	MSE
Optimizer	{Adam}	{Adam}	{Adam}	{Adam}
Early stopping	Sí	Sí	Sí	Sí
Dropout	No	No	No	No-
Batch size	8	8	8	8
Normalization	minmax	minmax	minmax	minmax

Figura 46.

Mejores modelos entrenados: pronóstico vs real de a) MLP, b) RNN, c) LSTM, d) GRU.



iv) Métricas de error

La **Tabla 23** presenta el resumen de la performance de los mejores modelos entrenados, considerando el valor de la función de pérdida alcanzada (error MSE de la curva *loss*) durante el entrenamiento (*training-set*) y la validación (*testing-set*). En general, los modelos MLP y RNN obtuvieron las métricas de error MSE más bajas con los datos del *training-set*. En ese sentido, el modelo RNN logró registrar el mínimo valor de error MSE en la curva de pérdida con el conjunto de datos del *testing-set*.

Seguidamente, la **Tabla 24** presenta los valores de las métricas de error de predicción (*testing-set*) de los mejores modelos entrenados (ver secciones 8.1.1, 8.1.2, 8.1.3, y 8.1.4). de los cuatro tipos de red neuronal, el modelo RNN ofrece los menores errores MSE, RMSE, MAE y MAPE. Por tal, se confirma que el modelo entrenado con la arquitectura RNN logra el mejor *fit* respecto al resto de modelos evaluados para el pronóstico de las exportaciones de banano orgánico de Perú.

Tabla 23.

Mejores modelos predictivos y métricas de performance en el training-set y testing-set.

Error MSE	MLP	RNN	LSTM	GRU
Training-set	0.0060	0.0069	0.0165	0.0105
Testing-set	0.0023	0.0015	0.0025	0.0034

Tabla 24.

Mejores modelos y sus errores de predicción en el testing-set.

Métricas de error	MLP	RNN	LSTM	GRU
MSE	0.00232	0.00147	0.00253	0.00344
RMSE	0.04813	0.03838	0.05033	0.05862
MAE	0.03903	0.02885	0.04293	0.05166
MAPE (%)	3.90303	2.88516	4.29295	5.16595

Tabla 25.

Mejores modelos: Tiempo computacional para el entrenamiento y validación.

Tiempo (seg.)	MLP	RNN	LSTM	GRU
Entrenamiento	55.02	25.85	77.81	53.21
Validación	0.24	0.22	0.50	0.49
Total	55.26	26.07	78.31	53.70

v) Tiempo de procesamiento

El tiempo de procesamiento es otro aspecto que fue evaluado. La **Tabla 25** presenta los tiempos de procesamiento incurridos en el entrenamiento y validación de cada modelo predictivo. Los modelos MLP y GRU registraron tiempos de procesamiento similares, alrededor de 54 seg. En contraste, el modelo RNN es el más rápido: 26 seg. Mientras que el modelo LSTM obtuvo demora hasta tres veces más: 78 seg. Se infiere que el modelo LSTM

tiene una alta complejidad en su arquitectura neuronal y en la dinámica de sus celdas de memoria, las cuales perjudica a la precisión del pronóstico de la serie de tiempo en estudio.

8.1.6 Modelo predictivo propuesto

Esta sección presenta los lineamientos del desarrollo y evaluación del modelo predictivo para el pronóstico de la exportación de banano orgánico de Perú. Adicionalmente, se explica la secuencia del algoritmo de aprendizaje supervisado del modelo RNN. Finalmente, se presentan los valores reales de la serie de tiempo estudiada y los valores pronosticados con el algoritmo entrenado.

i) Lineamientos para el modelado predictivo

La **Tabla 26** detalla las variables a considerar para el modelado y pronóstico de la serie temporal del registro de exportaciones de banano orgánico de Perú, aplicando algoritmos de aprendizaje automático del tipo red neuronal recurrente.

Tabla 26.

Modelo propuesto: Variables para el modelado y pronóstico.

Serie de tiempo	Exportación mensual de banano orgánico
Tipología	Univariable
Período de muestreo	Ene-2001 a Set-2021
Estrategia de pronóstico	<i>One-step ahead</i>
Algoritmos testeados	MLP, RNN, LSTM y GRU
Algoritmo seleccionado	RNN
División train/test	90% / 10%
Objetivos de análisis	Descripción, modelado y predicción

ii) Algoritmo

De acuerdo con Jin et al. (2021), el procedimiento para pronosticar series temporales con algoritmos de aprendizaje automático consta de tres pasos: pre-procesamiento, entrenamiento y pronóstico; y de-normalización. La **Tabla 27** detalla la secuencia de pasos del algoritmo para el modelado de la serie de tiempo en estudio.

Paso 1: Pre-procesamiento

Limpiar y re-muestrear la serie de tiempo original. La nueva serie temporal se divide en conjunto de datos entrenamiento y conjunto de datos validación. Los datos de la serie temporal se normalizan mediante la técnica *minmax_scaler* (valores entre [0,1]). Los datos de entrenamiento se usan como entrada de la red neuronal RNN.

El algoritmo de red neuronal recurrente RNN emplea una entrada 3D (*num_samples*, *num_timesteps*, *num_features*). Se crea una función auxiliar para remodelar los datos de entrada. La red neuronal RNN tiene 12 entradas correspondientes a los últimos 12 meses de la serie temporal.

Paso 2: Entrenamiento y pronóstico

La red neuronal RNN se entrena, principalmente, ajustando el los hiper-parámetros del número de unidades recurrentes, número de capas ocultas, y optimizador. La red neuronal RNN genera pronósticos (valores entre [0,1]) de la serie temporal en base a la función de pérdida (*loss*), el cual indica el progreso del aprendizaje del algoritmo.

Paso 3: De-normalización

El pronóstico obtenido en el paso 2 son de-normalizados; es decir, los valores pronosticados son convertidos de [0,1] a la magnitud original de la serie de tiempo. Posteriormente, se evalúa los resultados para comprobar el rendimiento del modelo entrenado según métricas de error de predicción.

Tabla 27.

Secuencia del algoritmo para el modelo de serie de tiempo.

Algoritmo: Pronóstico de la exportación de banano orgánico usando red neuronal recurrente

Input: Datos de exportación mensual (X)

Paso 1:

Tomar la matriz X con data de exportaciones anuales

Aplicar la técnica down-sampling para re-muestrear la serie temporal (de anual a mensual).

Dividir la matriz X en un conjunto de datos de:

- Entrenamiento: 90%, matriz (E)
- Validación: 10%, matriz (V)

Aplicar la técnica de normalización minmaxscaler a la matriz E y V:

$$x_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}}$$

Paso 2:

While

- i. Crear el vector de entrada a la red neuronal, vector: look back
- ii. Tomar la matriz E con los 12 valores de la serie temporal, vector: 12x1
- iii. Configurar los hiper-parámetros del algoritmo (*capa_oculta=1, unidades_recurrentes= 64, épocas=25, learning_rate=0.001, función_de activación=tanH, optimizador=Adam, batch size=8*)
- iv. Entrenar la red neuronal con datos de la matriz E
- v. Graficar la función de pérdida MSE (curva *loss*) y evaluar el progreso del entrenamiento del algoritmo
- vi. Calcular las métricas de error de predicción (MSE, RMSE, MAE, MAPE) usando los datos de la matriz V
- vii. Evaluar la performance de la red neuronal RNN: *trade-off* entre el *bias* y varianza
- viii. Almacenar los hiper-parámetros y pesos de la red neuronal

End while

Paso 3:

Des-normalizar a la magnitud original de la serie de tiempo.

Graficar los valores reales vs pronosticados con el algoritmo entrenado.

Output: Futuro valores de exportación mensual (Y).

iii) Valores pronosticados

La **Tabla 28** presenta el pronóstico de los valores de serie de tiempo con un intervalo de confianza de 90%. Finalmente, la **Figura 47** grafica la serie de tiempo con los datos reales y datos pronosticados.

Figura 47.

Modelado de la serie de tiempo: pronóstico vs real.

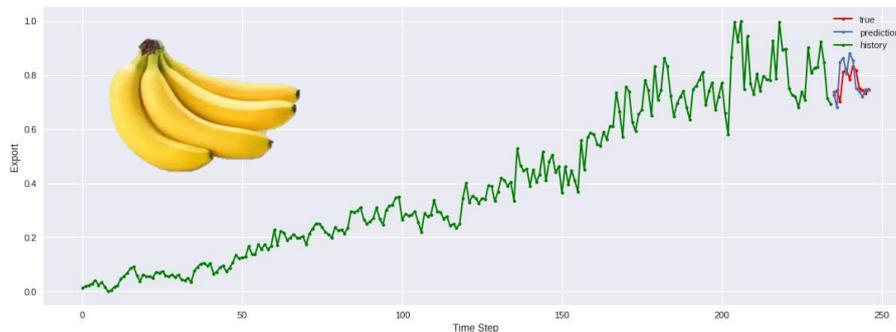


Tabla 28.

Pronóstico de la serie de tiempo con intervalo de confianza.

Fecha	Valor real	Valor pronosticado con el modelo propuesto	Intervalo de confianza (90%)	
			Valor Min	Valor Max
Sep-2020	16,451,422	16,604,218	14,647,768	18,560,668
Oct-2020	17,024,554	16,833,846	14,877,396	18,790,296
Nov-2020	15,709,816	17,203,708	15,247,258	19,160,158
Dic-2020	19,528,295	18,330,742	16,374,292	20,287,192
Ene-2021	19,926,226	19,172,598	17,216,148	21,129,048
Feb-2021	18,551,035	19,357,248	17,400,798	21,313,698
Mar-2021	20,311,535	19,316,222	17,359,772	21,272,672
Abr-2021	19,703,575	19,510,776	17,554,326	21,467,226
May-2021	17,306,133	19,253,558	17,297,108	21,210,008
Jun-2021	17,077,916	17,267,916	15,311,466	19,224,366
Jul-2021	16,614,065	16,485,102	14,528,652	18,441,552
Ago-2021	17,231,371	16,881,148	14,924,698	18,837,598

8.2 Discusión

Esta sección discute los resultados obtenidos en la presente tesis respecto a los resultados reportados por publicaciones sobre el modelado y pronóstico de series de tiempo

de demanda o producción de productos agro-industriales. El Apéndice 5 presenta un resumen de los algoritmos implementados y las métricas reportadas en el Estado del Arte.

De acuerdo con el Estado del Arte, existen pocas publicaciones sobre el pronóstico de series de tiempo de agro-productos. Se infiere que esta área de conocimiento está en vías de crecimiento. En ese sentido, ninguno de estas publicaciones ha trabajado con datos de exportación de banano orgánico. El único estudio similar fue reportado por Carrasco et al. (2021), el cual implementó la técnica ARIMA para pronosticar el volumen de producción nacional del banano peruano. Sin embargo, las métricas de error reportadas son mayores a las obtenidas con el modelo propuesto en la presente tesis. En ese sentido, el presente estudio es uno de los pioneros en analizar, comprender y pronosticar valores futuros de la exportación de banano orgánico peruano, empleando algoritmos de redes neuronales recurrentes.

Por un lado, la mayoría de las publicaciones del Estado del Arte han implementaron métodos estadísticos clásico como: ARIMA, SARIMA, regresión lineal múltiple o *exponential smoothin*. (ver Apéndice 4). Este es el caso de las investigaciones desarrolladas por Devi et al. (2021), Eyduran et al. (2020), Hossain et al. (2016), A. Rehman et al. (2018), y Carrasco et al. (2021), las cuales reportaron resultados con baja precisión. Por otro lado, las publicaciones de Abraham et al. (2017, 2020) y Devi et al. (2021) han reportado resultados más precisos, debido a que implementaron redes neuronales clásicas o algoritmos híbridos. En la presente tesis, el mejor modelo fue aquel modelo entrenado con el algoritmo de red neuronal recurrente RNN de 1 capa, 64 neuronas y 12 meses de *look back*, el cual logró obtener las siguientes métricas de error de predicción: MSE: 0.00147, RMSE: 0.03838, MAE: 0.02885, MAPE: 2.88516. Estos valores son menores respecto a las métricas de error reportadas en el Estado del Arte (ver Apéndice 4). Estos resultados superan a investigaciones similares que han realizado pronósticos de series de tiempo usando enfoque de ML, tales como: producción soya (Abraham et al., 2020) y producción de trigo (Devi et al., 2021). Por tal, se evidencia que el modelo RNN (entrenado, desarrollado en la presente investigación), logra posicionarse significativamente en esta área de conocimiento.

De acuerdo con Carrasco et al. (2021), la serie de tiempo del banano no es estacionaria y se caracteriza por presentar patrones no lineales, tales como la estacionalidad y algunas fluctuaciones significativas a lo largo del tiempo. Por ello, se realizó una adecuada selección del horizonte de predicción móvil (*look back* de 3 meses, 6 meses, y 12 meses) para pronosticar valores futuros, tal como lo proponen Escudero et al. (2021) y Parmezan et al. (2019)

En el marco del pronóstico de series de tiempo no lineales, e tipo algoritmo de ML a ser entrenado es otro elemento fundamental para el desarrollo del modelo predictivo. De acuerdo con Hajirahimi & Khashei (2019), los modelos ML (modelo no-paramétrico) ofrecen un mejor rendimiento que modelos paramétricos como el ARIMA o SARIMA. En este anunciado no corroboró parcialmente, debido a que la presente tesis estudió el modelado

únicamente con algoritmos de ML (cuatro tipos de redes neuronales), obteniendo resultados aceptables. Ninguna técnica paramétrica fue testada en la presente tesis; sin embargo, es una oportunidad para considerarlo como próximo trabajo futuro.

En el presente estudio se entrenaron y validaron algoritmos de redes neuronales artificiales, tales como MLP, RNN, LSTM y GRU. Diversos autores, entre ellos Parmezan et al. (2019), aseguran que las redes neuronales recurrentes ofrecen un proceso de aprendizaje más preciso y rápido para el pronóstico de series de tiempo. Ello se logró comprobar, debido a que el modelo RNN (red neuronal recurrente) obtuvo una mejor performance en comparación con el modelo MLP (red neuronal clásica). Adicionalmente, sólo tres publicaciones del Estado del Arte han reportado modelos predictivos usando redes neuronales artificiales, pero ninguna implementó redes neuronales recurrentes. En ese sentido, se reafirma que la presente tesis es uno de los pioneros en analizar, comprender y pronosticar valores futuros de la exportación de banano orgánico peruano, empleando algoritmos de redes neuronales recurrentes.

La dinámica del horizonte de retrosección en el entrenamiento del algoritmo es un aspecto que también fue estudiado. Se corroboró la fuerte influencia de aumentar al horizonte retrospectivo (*look back*) para optimizar el aprendizaje del algoritmo y disminuir el *bias*. Aquello es más notable en los modelos predictivos con 12 meses de *look back*. Es decir, si los datos de entrada del modelo abarcan el período retrospectivo de 1 año (12 meses), el modelo entrenará considerando no sólo la información de la tendencia de la serie de tiempo, sino también la información de su estacionalidad. Ello ayuda significativamente a identificar *insight* de la serie de tiempo y por ende realizar un mejor pronóstico.

Capítulo 9

Conclusiones

Este capítulo expone las conclusiones del estudio, las contribuciones de la tesis, y se propone futuros trabajos de investigación.

9.1 Conclusiones

En esta sección se exponen los principales hallazgos respecto al modelado y pronóstico de series de tiempo para la exportación de banano orgánico de Perú usando algoritmos de aprendizaje supervisado del tipo redes neuronales. Las conclusiones están orientadas a responder la pregunta de investigación planteada en el Capítulo 1 de la presente tesis: *¿Puede el modelado a base de Redes Neuronales Recurrentes (RNN, LSTM y GRU) superar el performance del modelo a base de redes neuronales artificiales clásicas (MLP)?*

En ese sentido, las principales conclusiones son las siguientes:

Un total de 60 modelos predictivos, diferentes entre sí, fueron entrenados para pronosticar la exportación de banano orgánico de Perú.

El modelado usando Redes Neuronales Recurrentes demostró un mejor proceso de entrenamiento, referente al aprendizaje de la dependencia temporal, la no-linealidad y la estacionalidad de la serie de tiempo. Ello debido a los atributos de las celdas de memoria, las cuales retienen y actualizan información de datos secuenciales.

Los cuatro modelos entrenados (MLP, RNN, LSTM, y GRU) realizaron el pronóstico de la serie de tiempo con un ligero *underfitting (high bias)*. Sin embargo, las redes neuronales recurrentes (RNN, LSTM, y GRU) consiguieron mayor precisión en la estimación de la estacionalidad de la serie temporal.

El modelo entrenado con la red neuronal RNN obtuvo el mejor *fit*, en comparación con los otros tipos de redes neuronales testados: MLP, LSTM y GRU. Es decir, el *trade-off* del *bias-varianza* y el error de predicción del modelo RNN fue significativamente superior al conseguido por el modelo MLP.

El algoritmo del tipo red neuronal recurrente RNN ofreció un proceso de entrenamiento más rápido y preciso para realizar los pronósticos de la serie temporal. Mientras que, el modelo LSTM demanda el triple de tiempo de procesamiento que el modelo RNN.

El diseño de experimentos facilitó realizar el entrenamiento y evaluación de los modelos, de forma ordenada y objetiva. El al proceso de optimización de hiper-parámetros: tamaño del horizonte de retrosección (*look back*), unidades recurrentes, *learning rate*, optimizador, entre otros.

El tamaño del horizonte de retrosección influyó la cantidad y calidad de datos de entrada para entrenar los modelos. Considerando todos los modelos entrenados, las mejores métricas de error de predicción se obtuvieron con un horizonte de retrosección de 12 meses (*look back*).

La elección del número de neuronas o unidades recurrentes por capa oculta de la red neuronal influyó en el aprendizaje y en la función de pérdida (*loss*). Considerando todos los modelos entrenados, la mejor performance del modelado y el pronóstico de la serie de tiempo fue registrado usando una arquitectura estándar de red neuronal recurrente, con una capa oculta y con sesenta y cuatro unidades recurrentes en la capa oculta.

Una arquitectura neuronal más densa y/o profunda (muchas unidades recurrentes en la capa oculta y operadores matemáticos más complejos en su celda de memoria) fue una desventaja en el proceso de entrenamiento. Este es el caso del modelo LSTM, el cual consiguió los errores de predicción más altos y con el mayor tiempo de entrenamiento.

9.2 Contribución

La presente tesis doctoral ha contribuido significativamente de la siguiente manera:

- Una revisión sistemática de publicaciones científicas internacionales relacionadas al modelado de series de tiempo para el pronóstico de demanda/oferta de agro-productos, implementando modelos paramétricos (algoritmos de Machine Learning) y modelos no-paramétricos.
- Una metodología para el modelado y pronóstico del volumen de exportación de banano orgánico de Perú. Esta metodología incluyendo las técnicas para el pre-procesamiento de datos temporales, y el procedimiento para el entrenamiento, validación y evaluación del modelo entrenado para el pronóstico de series de tiempo.
- Cuatro tipos de red neuronal artificial testeados para el pronóstico de serie de tiempo, incluyendo: a una red neuronal clásica (MLP) y tres redes neuronales recurrentes (RNN, LSTM, y GRU).

- Cuatro modelos entrenados con algoritmos de aprendizaje supervisado (MLP, RNN, LSTM, y GRU) para el pronóstico de la exportación de banano orgánico de Perú, usando datos históricos de 2001 al 2021.
- Un análisis comparativo del performance de los modelos entrenados, evaluando: horizonte de retrospección, curva *loss*, error de predicción, *trade-off* entre *bias* y varianza, y tiempo de procesamiento.
- Una implementación del algoritmo de aprendizaje supervisado del tipo red neuronal recurrente RNN en TensorFlow para el pronóstico de los datos temporales de la exportación de banano orgánico.

El pronóstico de serie de tiempo contribuye a extraer *insight* de los datos secuenciales con la finalidad de reducir la incertidumbre en escenarios futuros. En ese sentido, el modelo predictivo propuesto es de utilidad para: tomadores de decisiones en empresas agro-exportadoras (industria); investigadores y estudiantes interesados en banano y temas afines (academia) y formuladores de políticas a nivel regional y nacional (gobierno). Especialmente, este último grupo de *stakeholders* al tener a la mano información sobre la tendencia y la estacionalidad de la exportación de banano orgánico del Perú, podrán formular e implementar estrategias más óptimas (tecnológicas, operativas, políticas, financiamiento, etc.) para fortalecer la cadena de valor del banano y encaminarla a ser una cadena de valor agro-tecnológicamente sostenible, en coherencia con lo propuesto por Sharma, Kamble, et al. (2020).

9.3 Trabajos futuros

Respecto a los trabajos futuros orientados al modelado:

Desarrollar de un aplicativo web/móvil que tenga embebido el modelo predictivo. Esta herramienta digital sería el medio por el cual los *stakeholders* de la cadena de valor de banano podrían interactuar (de forma intuitiva, fácil de usar, segura, y confiable) con el algoritmo de ML para el pronóstico del volumen de exportación de banano orgánico de Perú.

Considerar un modelado de serie de tiempo multivariante con diversos tipos de variables de entrada, tales como: clima, acuerdo de TLC, macroeconomía, factores políticos, entre otros.

Implementar el método de capacidad de aprendizaje *on-line* para el pronóstico de serie de tiempo. Este es un método de aprendizaje local, el cual procesa tareas de aprendizaje en línea donde el número de muestras para el entrenamiento aumenta con el tiempo (agregar nuevos valores al conjunto de datos y no necesita volver a entrenarse cuando hay nuevos datos disponibles).

Respecto a los trabajos futuros orientados al alcance:

El alcance de la próxima investigación podría abarcar el desarrollo de modelos híbridos, incluyendo modelos paramétricos y no-paramétricos; por ejemplo: modelo con técnicas de ML y ARIMA. Con esta investigación, se obtendría un panorama amplio para seleccionar un nuevo modelo de pronóstico acorde con la naturaleza de la serie de tiempo de la exportación de banano orgánico de Perú.

Respecto a los trabajos futuros orientados a la data:

Considerar el desarrollo otro estudio tomando en cuenta el precio de exportación (FOB) que ha registrado el banano orgánico de Perú en los últimos 20 años. El modelado y pronóstico de esta serie de tiempo reduciría la incertidumbre futura de los precios del mercado internacional. Ello beneficiaría a los empresarios exportadores y las agencias de gobierno, pues conocerían, por adelantado, el probable valor del precio del banano orgánico. Esto ayudaría en la optimización de la gestión de recursos económicos y materiales en las empresas.

Referencias bibliográficas

- Abiodun, O., Jantan, A., Omolara, A., Dada, K., Mohamed, N., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), 1–23. <https://doi.org/10.1016/j.heliyon.2018.e00938>
- Abraham, E. R., dos Reis, J. G. M., Colossetti, A. P., de Souza, A. E., & Toloj, R. C. (2017). Neural network system to forecast the soybean exportation on Brazilian port of Santos. *IFIP Advances in Information and Communication Technology*, 514, 83–90. https://doi.org/10.1007/978-3-319-66926-7_10
- Abraham, E. R., Dos Reis, J. G. M., Vendrametto, O., Neto, P. L. de O. C., Toloj, R. C., de Souza, A. E., & Morais, M. de O. (2020). Time series prediction with artificial neural networks: An analysis using Brazilian soybean production. *Agriculture (Switzerland)*, 10(10), 1–18. <https://doi.org/10.3390/agriculture10100475>
- Almeyda, E., & Ipanaqué, W. (2022). Recent developments of artificial intelligence for banana: applications areas, learning algorithms, and future challenges. *Engenharia Agricola*, 42. <https://doi.org/10.1590/1809-4430-Eng.Agric.v42nepe20210144/2022 RECENT>
- Annosi, M. C., Brunetta, F., Monti, A., & Nat, F. (2019). Is the trend your friend? An analysis of technology 4.0 investment decisions in agricultural SMEs. *Computers in Industry*, 109(August 2019), 59–71. <https://doi.org/10.1016/j.compind.2019.04.003>
- Bai, S., Kolter, J. Z., & Koltun, V. (2018). An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling. *ArXiv Preprint*. <http://arxiv.org/abs/1803.01271>
- Bancayán, E. (2019). *Evaluación de láminas de riego y eficiencia en los sistemas, utilizando sensores de humedad y modelo Penman-Monteith para cultivos de banano y maíz en la localidad de Mallares, Sullana, Piura [Undergraduate thesis]* [Universidad Nacional de Piura]. <http://repositorio.unp.edu.pe/bitstream/handle/UNP/1948/AGR-BAN-ZEG-2019.pdf?sequence=1&isAllowed=y>
- Ben Ayed, R., & Hanana, M. (2021). Artificial Intelligence to Improve the Food and Agriculture Sector. *Journal of Food Quality*, 2021(MI). <https://doi.org/10.1155/2021/5584754>
- Benos, L., Tagarakis, A. C., Dolias, G., Berruto, R., Kateris, D., & Bochtis, D. (2021). Machine learning in agriculture: A comprehensive updated review. *Sensors*, 21(11), 1–55. <https://doi.org/10.3390/s21113758>
- Bontempi, G., Ben Taieb, S., & Le Borgne, Y. A. (2013). Machine learning strategies for time series forecasting. In *Lecture Notes in Business Information Processing* (pp. 62–77). https://doi.org/10.1007/978-3-642-36318-4_3

- Boutaba, R., Salahuddin, M. A., Limam, N., Ayoubi, S., Shahriar, N., Estrada-solano, F., & Caicedo, O. M. (2018). A comprehensive survey on machine learning for networking: evolution, applications and research opportunities. *Journal of Internet Services and Applications*, 9(16), 99. <https://jisajournal.springeropen.com/articles/10.1186/s13174-018-0087-2>
- Brownlee, J. (2020). Introduction to time series forecasting with Python - How to prepare data and develop models to predict the future. In *Machine Learning Mastery* (e-Book). Jason Brownlee. <https://github.com/Rumi381/All-Programming-E-Books-PDF/find/master>
- Carrasco, F., Villegas, M., & Sanchez, J. D. R. (2021). Análisis univariante para describir y pronosticar la producción de plátano en la región de piura. *Universidad Ciencia y Tecnología*, 25(109), 71–79. <https://doi.org/10.47460/uct.v25i109.450>
- Cedepas Norte. (2017). *Innovación tecnológica en el banano orgánico: Experiencias con organizaciones de productores de Piura y La Libertad*. https://www.academia.edu/36510589/INNOVACIÓN_TECNOLÓGICA_EN_EL_BANANO_ORGÁNICO_Experiencias_con_organizaciones_de_productores_de_Piura_y_La_Libertad
- Cerqueira, V., Torgo, L., & Mozetič, I. (2020). Evaluating time series forecasting models : an empirical study on performance estimation methods. *Machine Learning*, 109(11), 1997–2028. <https://doi.org/10.1007/s10994-020-05910-7>
- Chatfield, C. (2019). The analysis of time series: An introduction with R, 7th edition. In *CRC Press*. [https://doi.org/10.1016/0169-2070\(90\)90041-9](https://doi.org/10.1016/0169-2070(90)90041-9)
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *EMNLP 2014 - Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, 1724–1734. <https://doi.org/10.3115/v1/d14-1179>
- CIPCA - Centro de Investigación y Promoción del Campesinado. (2019). *Diagnóstico provincial de las condiciones que enfrenta la producción de banano orgánico en el alto Piura*. <http://www.cipca.org.pe/documento/diagnostico-provincial-de-las-condiciones-que-enfrenta-la-producción-de-banano-órgánico-en>
- Colonia Luy, D. P., & Carrillo Caceres, R. A. (2019). *Factores que influyeron en las exportaciones de banano orgánico en el marco del TLC Perú – Estados Unidos durante los años 2013 y 2017* [Universidad de Ciencias Aplicadas]. <http://hdl.handle.net/10757/625734>
- Das, N. K., & Roy, A. (2021). COVID-19 and agri-food value chain: a systematic review and bibliometric mapping. *Journal of Agribusiness in Developing and Emerging Economies*, October, 1–21. <https://doi.org/10.1108/JADEE-07-2021-0188>
- Demartini, M., Pinna, C., Tonelli, F., Terzi, S., Sansone, C., & Testa, C. (2018). Food industry digitalization: from challenges and trends to opportunities and solutions. *International Federation of Automatic Control (IFAC) Conference Paper*, 51(11), 1371–1378. <https://doi.org/10.1016/j.ifacol.2018.08.337>
- Devi, M., Kumar, J., Malik, D. P., & Mishra, P. (2021). Forecasting of wheat production in Haryana using hybrid time series model. *Journal of Agriculture and Food Research*, 5(May), 100175. <https://doi.org/10.1016/j.jafr.2021.100175>

- Dwivedi, Y., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. (2019). Artificial Intelligence: Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57, 101994. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>
- Elavarasan, D., Vincent, D., Sharma, V., Zomaya, A., & Srinivasan, K. (2018). Forecasting yield by integrating agrarian factors and machine learning models: A survey. *Computers and Electronics in Agriculture*, 155, 257–282. <https://doi.org/10.1016/j.compag.2018.10.024>
- Elman, J. L. (1990). Finding Structure in Time. *Cognitive Science*, 14(2), 179–211. https://doi.org/10.1207/s15516709cog1402_1
- Escobedo, J. (2018). *Efecto del número de hijos sobre el rendimiento y calidad del banano orgánico (Musa Paradisiaca) variedad William para exportación [Undergraduate thesis]* [Universidad Nacional de Piura]. <http://repositorio.unp.edu.pe/bitstream/handle/UNP/1667/AGR-ESC-ALB-2018.pdf?sequence=1&isAllowed=y>
- Escudero, P., Alcocer, W., & Paredes, J. (2021). Recurrent neural networks and ARIMA models for euro/dollar exchange rate forecasting. *Applied Sciences (Switzerland)*, 11(12). <https://doi.org/10.3390/app11125658>
- Esling, P., & Agon, C. (2012). Time-series data mining. *ACM Computing Surveys*, 45(1). <https://doi.org/10.1145/2379776.2379788>
- Eyduran, S. P., Akin, M., Eyduran, E., Çelik, Ş., Ertürk, Y. E., & Ercişli, S. (2020). Forecasting Banana Harvest Area and Production in Turkey Using Time Series Analysis. *Erwerbs-Obstbau*, 62(3), 281–291. <https://doi.org/10.1007/s10341-020-00490-1>
- Fang, X., & Yuan, Z. (2019). Performance enhancing techniques for deep learning models in time series forecasting. *Engineering Applications of Artificial Intelligence*, 85, 533–542. <https://doi.org/10.1016/j.engappai.2019.07.011>
- FAO - Food and Agriculture Organization for the United Nation. (2017). Producción de banano orgánico en Perú. In *Foro Mundial Bananero*. <http://www.fao.org/world-banana-forum/projects/good-practices/organic-production-peru/es/>
- FAO - Food and Agriculture Organization for the United Nation. (2020a). *Foro Mundial Bananero*. <http://www.fao.org/world-banana-forum/about-the-foro/es/>
- FAO - Food and Agriculture Organization for the United Nation. (2020b). Preliminary assessment of the impacts of the COVID-19 pandemic on trade in bananas and tropical fruits. In *Food Outlook – Biannual Report on Global Food Markets*. http://www.fao.org/3/cb1993en/cb1993en_commodity_focus.pdf
- FAO - Food and Agriculture Organization for the United Nation. (2020c). *Prospect for global production bananas and tropical fruits 2019-2028*.
- Faruk, D. Ö. (2010). A hybrid neural network and ARIMA model for water quality time series prediction. *Engineering Applications of Artificial Intelligence*, 23(4), 586–594. <https://doi.org/10.1016/j.engappai.2009.09.015>
- Gamboa, J. (2017). Deep Learning for Time-Series Analysis. *ArXiv Preprint*.

<http://arxiv.org/abs/1701.01887>

- Guerrero, J. (2017). *Evaluación de microorganismos entomopatógenos y trampas para el control de (Chaetanaphothrips Signipennis) Thrips "De La Mancha Roja" [Undergraduate thesis]* [Universidad Nacional de Piura]. <http://repositorio.unp.edu.pe/bitstream/handle/UNP/1260/AGR-GUE-URB-17.pdf?sequence=1&isAllowed=y>
- Hajirahimi, Z., & Khashei, M. (2019). Hybrid structures in time series modeling and forecasting: A review. *Engineering Applications of Artificial Intelligence*, 86(February), 83–106. <https://doi.org/10.1016/j.engappai.2019.08.018>
- Handayati, Y., Simatupang, T., & Perdana, T. (2015). Agri-food supply chain coordination: the state-of-the-art and recent developments. *Logistics Research*, 8(5), 1–15. <https://doi.org/10.1007/s12159-015-0125-4>
- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1), 388–427. <https://doi.org/10.1016/j.ijforecast.2020.06.008>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory Sepp. *Neural Computation*, 9(8), 2199–2207. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hossain, M. M., Abdulla, F., & Majumder, A. K. (2016). Forecasting of banana production in Bangladesh. *American Journal of Agricultural and Biological Science*, 11(2), 93–99. <https://doi.org/10.3844/ajabssp.2016.93.99>
- Hyndman, R., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice, 3th edition*. OTexts Online Textbook; OTexts. <https://otexts.com/fpp3/>
- Instituto de Estadística e Informática del Perú. (2020). *Informe técnico de producción nacional-Diciembre 2019 [report]*. http://m.inei.gob.pe/media/MenuRecursivo/boletines/02-informe-tecnico-n02_produccion-nacional-dic-2019.pdf
- Irani, Z., Sharif, A. M., Lee, H., Aktas, E., Topaloğlu, Z., van't Wout, T., & Huda, S. (2018). Managing food security through food waste and loss: Small data to big data. *Computers and Operations Research*, 98, 367–383. <https://doi.org/10.1016/j.cor.2017.10.007>
- Jha, K., Doshi, A., Patel, P., & Shah, M. (2019). A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*, 2, 1–12. <https://doi.org/10.1016/j.aiia.2019.05.004>
- Jin, N., Zeng, Y., Yan, K., & Ji, Z. (2021). Multivariate Air Quality Forecasting with Nested LSTM Neural Network. *IEEE Transactions on Industrial Informatics*, 3203(c). <https://doi.org/10.1109/TII.2021.3065425>
- Kamilaris, A., & Prenafeta-Boldú, F. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15–25. <https://doi.org/10.1016/j.bushor.2018.08.004>
- Kouadio, L., Deo, R. C., Byrareddy, V., Adamowski, J., Mushtaq, S., & Phuong Nguyen, V. (2018). Artificial intelligence approach for the prediction of Robusta coffee yield using soil fertility

- properties. *Computers and Electronics in Agriculture*, 155(December 2018), 324–338. <https://doi.org/10.1016/j.compag.2018.10.014>
- Kumar, I., Rawat, J., Mohd, N., & Husain, S. (2021). Opportunities of Artificial Intelligence and Machine Learning in the Food Industry. *Journal of Food Quality*, 2021. <https://doi.org/10.1155/2021/4535567>
- Lara-Benítez, P., Carranza-García, M., & Riquelme, J. C. (2021). An Experimental Review on Deep Learning Architectures for Time Series Forecasting. *International Journal of Neural Systems*, 31(3). <https://doi.org/10.1142/S0129065721300011>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors (Switzerland)*, 18(8), 2674. <https://doi.org/10.3390/s18082674>
- Mahto, A. K., Alam, M. A., Biswas, R., Ahmad, J., & Alam, S. I. (2021). Short-Term Forecasting of Agriculture Commodities in Context of Indian Market for Sustainable Agriculture by Using the Artificial Neural Network. *Journal of Food Quality*, 2021. <https://doi.org/10.1155/2021/9939906>
- Mateus, B. C., Mendes, M., Farinha, J. T., Assis, R., & Cardoso, A. M. (2021). Comparing LSTM and GRU models to predict the condition of a pulp paper press. *Energies*, 14(21), 1–21. <https://doi.org/10.3390/en14216958>
- Meshram, V., Patil, K., Meshram, V., Hanchate, D., & Ramkteke, S. D. (2021). Machine learning in agriculture domain: A state-of-art survey. *Artificial Intelligence in the Life Sciences*, 1, 100010. <https://doi.org/10.1016/j.aillsci.2021.100010>
- MINCETUR - Ministerio de Comercio Exterior y Turismo. (2021). *Estudio de aprovechamiento del TLC Perú-Unión Europea: 8vo año de vigencia del TLC*. Dirección General de Investigación y Estudios Sobre Comercio Exterior. http://www.acuerdoscomerciales.gob.pe/En_Vigencia/Union_Europea/Documentos/E_A_PeruUE_8periodo.pdf
- Ministerio de Agricultura y Riego del Perú. (2018). *Situación comercial del banano orgánico en el mercado europeo*. <http://repositorio.minagri.gob.pe/handle/MINAGRI/356>
- Ministerio de Agricultura y Riego del Perú. (2019). *Boletín estadístico mensual “El Agro en Cifras”-Junio 2019 [report]*. <https://www.minagri.gob.pe/portal/boletin-estadistico-mensual-el-agro-en-cifras>
- Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). *Foundations of machine learning* (2nd ed.). Cambridge, MIT Press. [https://d1rkab7tlqy5f1.cloudfront.net/EWI/Over de faculteit/Afdelingen/Intelligent Systems/Pattern Recognition Laboratory/PR/Reading Group/Foundations_of_Machine_Learning.pdf](https://d1rkab7tlqy5f1.cloudfront.net/EWI/Over%20de%20faculteit/Afdelingen/Intelligent%20Systems/Pattern%20Recognition%20Laboratory/PR/Reading%20Group/Foundations_of_Machine_Learning.pdf)
- Muhuri, P., Shukla, A. K., & Abraham, A. (2019). Industry 4.0: A bibliometric analysis and detailed overview. *Engineering Applications of Artificial Intelligence*, 78(September 2018), 218–235. <https://doi.org/10.1016/j.engappai.2018.11.007>
- Parmezan, A. R. S., Souza, V. M. A., & Batista, G. E. A. P. A. (2019). Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model. *Information Sciences*, 484, 302–337. <https://doi.org/10.1016/j.ins.2019.01.076>

- Prom Perú. (2020). *Oportunidades de exportación para frutas y hortalizas frescas peruanas en Suiza y Austria*. <https://recursos.exportemos.pe/oportunidades-exportacion-frutas-gortalizas-frescas-peruanas-suiza-austria.pdf>
- Pugliese, R., Regondi, S., & Marini, R. (2021). Machine learning-based approach: Global trends, research directions, and regulatory standpoints. *Data Science and Management*, 4(November), 19–29. <https://doi.org/10.1016/j.dsm.2021.12.002>
- Ratanamahatana, C. A., & Wanichsan, D. (2008). Stopping criterion selection for efficient semi-supervised time series classification. *Studies in Computational Intelligence*, 149, 1–14. https://doi.org/10.1007/978-3-540-70560-4_1
- Rathod, S., & Mishra, G. C. (2018). Statistical models for forecasting mango and banana yield of Karnataka, India. *Journal of Agricultural Science and Technology*, 20(4), 803–816. <http://jast.modares.ac.ir/article-23-19768-en.html>
- Rehman, A., Deyuan, Z., Hussain, I., Iqbal, M. S., Yang, Y., & Jingdong, L. (2018). Prediction of Major Agricultural Fruits Production in Pakistan by Using an Econometric Analysis and Machine Learning Technique. *International Journal of Fruit Science*, 18(4), 445–461. <https://doi.org/10.1080/15538362.2018.1485536>
- Rehman, T. U., Mahmud, M. S., Chang, Y. K., Jin, J., & Shin, J. (2019). Current and future applications of statistical machine learning algorithms for agricultural machine vision systems. *Computers and Electronics in Agriculture*, 156(October 2018), 585–605. <https://doi.org/10.1016/j.compag.2018.12.006>
- Scott, G. J. (2021). A review of root, tuber and banana crops in developing countries: past, present and future. *International Journal of Food Science and Technology*, 56, 1093–1114. <https://doi.org/10.1111/ijfs.14778>
- Sharma, R., Kamble, S. S., Gunasekaran, A., Kumar, V., & Kumar, A. (2020). A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. *Computers and Operations Research*, 119, 104926. <https://doi.org/10.1016/j.cor.2020.104926>
- Sharma, R., Shishodia, A., Kamble, S., Gunasekaran, A., & Belhadi, A. (2020). Agriculture supply chain risks and COVID-19: mitigation strategies and implications for the practitioners. *International Journal of Logistics Research and Applications*, 1–28. <https://doi.org/10.1080/13675567.2020.1830049>
- Shearer, C. (2000). The CRISP-DM Model: The New Blueprint for Data Mining. *Journal of Data Warehousing*, 5(4). <https://mineracaodedados.files.wordpress.com/2012/04/the-crisp-dm-model-the-new-blueprint-for-data-mining-shearer-colin.pdf>
- Shickel, B., & Rashidi, P. (2020). Sequential Interpretability: Methods, Applications, and Future Direction for Understanding Deep Learning Models in the Context of Sequential Data. *ArXiv Preprint*, 1–5. <http://arxiv.org/abs/2004.12524>
- Shukla, A. K., Janmajaya, M., Abraham, A., & Muhuri, P. K. (2019). Engineering applications of artificial intelligence: A bibliometric analysis of 30 years (1988–2018). *Engineering Applications of Artificial Intelligence*, 85(October 2019), 517–532. <https://doi.org/10.1016/j.engappai.2019.06.010>
- Tarekegn, K., Asado, A., Gafaro, T., & Shitaye, Y. (2020). Value chain analysis of banana in

- Bench Maji and Sheka Zones of Southern Ethiopia. *Cogent Food and Agriculture*, 6(1), 1–21. <https://doi.org/10.1080/23311932.2020.1785103>
- Tinzaara, W., Stoian, D., Ocimati, W., Kikulwe, E., Otieno, G., & Blomme, G. (2018). Challenges and opportunities for smallholders in banana value chains. In G. Kema & A. Drenth (Eds.), *Achieving sustainable cultivation of bananas* (pp. 1–27). Burleigh Dodds Science Publishing Limited. <https://doi.org/10.19103/as.2017.0020.10>
- Yu, L., Liang, S., Chen, R., & Lai, K. K. (2022). Predicting monthly biofuel production using a hybrid ensemble forecasting methodology. *International Journal of Forecasting*, 38(1). <https://doi.org/10.1016/j.ijforecast.2019.08.014>
- Zhou, L., Pan, S., Wang, J., & Vasilakos, A. (2017). Machine learning on big data: Opportunities and challenges. *Neurocomputing*, 237, 350–361. <https://doi.org/10.1016/j.neucom.2017.01.026>

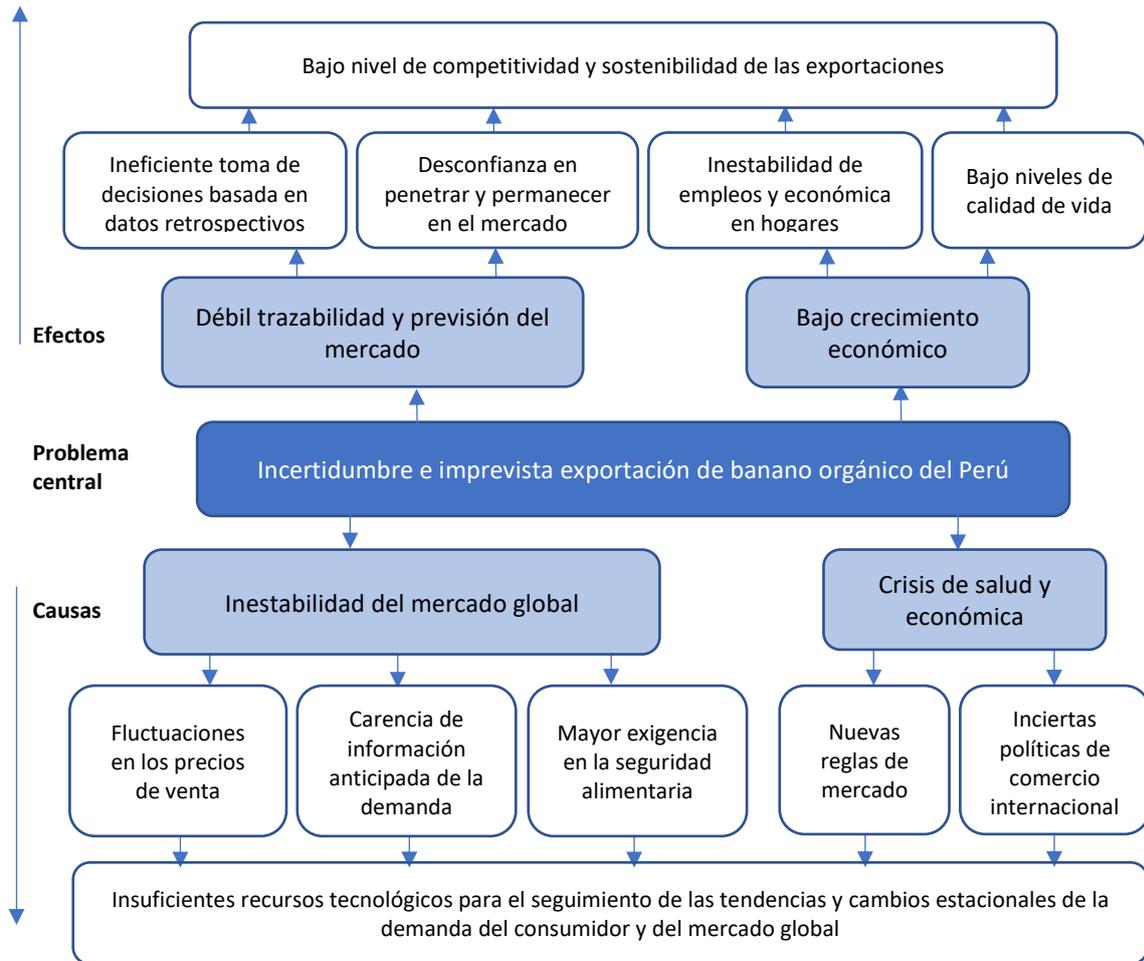


Apéndices





Apéndice 1. Árbol de problemas



Apéndice 2. Modelado de datos secuenciales

El modelado secuencial, también conocido como *sequential learning*, es aquel modelo de Machine Learning o Deep Learning que utilizan datos de secuencias como inputs u outputs (Bontempi et al., 2013; Shickel & Rashidi, 2020). El principal atributo del modelo secuencial consiste en que los datos, con los que se trabaja para entrenar el modelo, dependen uno del otro debido a la naturaleza de su orden secuencial (Fang & Yuan, 2019). Estos datos impliquen tiempo o noción de orden, tales como series de tiempo, secuencias de texto, clips de audio, videoclips, e imágenes. Es decir, el modelado de datos secuenciales tiene como el objetivo de predecir qué valor viene a continuación en la secuencia (número, letra, elemento, etc). Entre las principales aplicaciones, destacan las siguiente: pronóstico de series de tiempo, reconocimiento de voz, procesamiento de lenguaje natural, modelado de música polifónica, reconocimiento de escritura a mano, etc.

De forma general, los datos secuenciales se definen como una colección orden de muestras (Shickel & Rashidi, 2020):

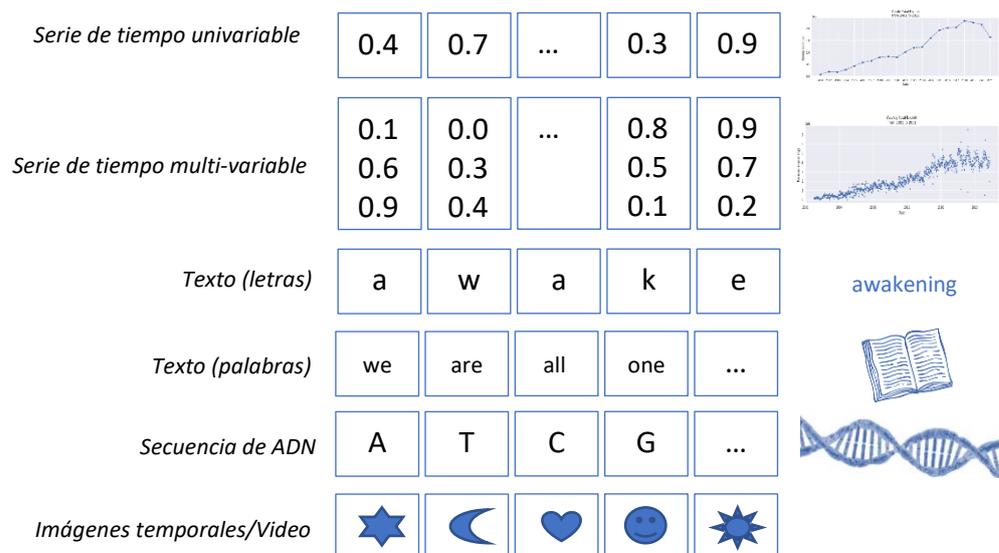
$$S = \{S_1, S_2, S_3, \dots, S_N\}$$

Donde N es el número de instancias u observaciones. Y cada $S_i = \{x_i^1, x_i^2, \dots, x_i^D\}$ se refiere a una única instancia secuencial compuesta por features D , siendo D el número de valores por paso de tiempo (*timestep*).

La Figura presenta algunos ejemplos de datos secuenciales empleados en este tipo de modelado:

Figura

Datos secuenciales según tipo de aplicación.



Adaptado de “*Sequential Interpretability: Methods, Applications, and Future Direction for Understanding Deep Learning Models in the Context of Sequential Data*” (Shickel & Rashidi, 2020).

Apéndice 3. Proyectos de investigación sobre banano en Piura**i) Proyecto sobre el diagnóstico de brechas tecnológicas y el fortalecimiento de extensionismo tecnológico del sector bananero de la región Piura:**

El proyecto tuvo como propósito obtener un diagnóstico de empresas y/o asociaciones de productores agroindustriales de cacao y banano orgánico que recibieron servicios de extensionismo tecnológicos para mejorar sus indicadores de calidad y/o productividad. Como resultados del proyecto se obtuvieron: diagnóstico de brechas tecnológicas de 16 entidades bananeras y de 5 entidades cacaoteras; 44 capacitaciones realizadas; 819 personas capacitadas en buenas prácticas en el proceso pos-cosecha de banano orgánico, uso de paneles solares en actividades agroindustriales y sus aplicaciones, nuevas tecnologías en los sistemas de monitoreo y gestión de la información; y 02 misiones tecnológicas internacionales a instituciones con trayectoria profesional y académica sobre banano y cacao.

ii) Proyectos de innovación tecnológica para aumentar la productividad de banano orgánico:**a) A cargo del Gobierno Regional de Piura:**

El proyecto tuvo como objetivo promover adecuadas capacidades competitivas de pequeños y medianos productores de banano orgánico de los valles: El Chira, Piura, Alto Piura y San Lorenzo. Como parte de los resultados del proyecto: se instalaron 10 estaciones meteorológicas en zonas bananeras de Piura, implementación de sistema de monitoreo, vigilancia y alerta temprana de plagas en el banano orgánico; y transferencia tecnológica a 11 parcelas respecto a los siguientes temas: cable vía, drenes, sistema de riego, cámara de frío, monitoreo de humedad del suelo y prevención y control de plagas. Asimismo, se desarrollaron 192 cursos-talleres dirigidos a asociaciones bananeras y se logró capacitar en total a 8 mil de agro-productores.

b) A cargo de Cedepas Norte:

El proyecto tuvo como objetivo desarrollar investigaciones adaptativas e innovaciones tecnológicas para mejorar la productividad de los pequeños y de calidad del banano orgánico de los valles de Jequetepeque (La Libertad) y Chira (Piura). Entre los principales resultados del proyecto, destaca: más de 300 pequeños productores capacitados, las parcelas que participaron en el proyecto incrementaron su indicador de productividad logrando pasar de 1,300 a 1,924 cajas/semana; el ratio de rendimiento (cajas/racimo) se incrementó de 0.9 a

1.2; y las mermas pasaron de estar en un rango 15% y 25% y ser reducidas al 10% debido a la aplicación de buenas prácticas agrícolas (BPA) y buenas prácticas de manufactura (BPM).

iii) Manejo técnico del cultivo de banano orgánico

(Bancayán, 2019) concluyó que la influencia del uso de tecnologías para la aplicación de riego favorece a la producción final de cultivos como el banano, logrando un incremento de 22.5 %. Demostró experimentalmente que el riego por microaspersión para banano orgánico utilizando sensores de humedad impactó positivamente en el ahorro del 14.8% de consumo de agua (m³/hectárea) en comparación con el riego por gravedad (canaletas en el suelo). Mientras que el riego presurizado por goteo representó un ahorro de 21.8% por debajo del riego por gravedad en el cultivo de banano.

(Escobedo, 2018) estudió la influencia del número de hijos en la planta de banano en el rendimiento y calidad del fruto. El cultivo con plantas con sólo 1 hijo alcanzó mayor nivel de productividad en comparación con cultivos con 2 o 3 hijos: 40.75 tn/ha, 40.60 tn/ha y 40.45 tn/ha respectivamente. Respecto al rendimiento por calidad de fruta exportable, las plantas con 1 hijo obtuvieron mejores ratios que el resto.

(Juárez, 2018) determinó el valle del Chira se caracteriza por tener un nivel de fertilidad del suelo en la categoría medio y bajo. Ello lo estudió experimentalmente usando una correlación entre las propiedades físicas y químicas del suelo y su nivel de fertilidad.

(Guerrero, 2017) logró disminuir la cantidad de la plaga Trips “de la mancha roja” (insectos/planta) en el estado de ninfa y estado adulto presentes en el cultivo de banano orgánico del Valle del Chira. Este estudio experimental usó trampas para capturar insectos en varios colores: azul, blanco y amarillo; siendo las trampas con colores claros las que atraen mayor cantidad de Trips.

Apéndice 4. Calendario-Plot de exportación de banano orgánico del Perú desde Enero-2012 a Setiembre-2021

Se elaboró un calendario en base a los volúmenes de exportación de banano orgánico Ene-2012 a Sep-2021. Donde:

El píxel en color verde corresponde al máximo volumen de exportación en el año.

El píxel en color blanco corresponde al mínimo volumen de exportación en el año.

El píxel en color gris corresponde a fechas donde no se hubo exportación.



Apéndice 5. Resumen de las métricas reportadas en el Estado del Arte

Autor (es)	País	Cultivo	Algoritmo (s) implementado (s)	El mejor modelo predictivo	MSE	RMSE	MAE	MAPE	R2	RMSPE	MPFE	TIC	Mean error
Tesis doctoral	Perú	Banana	MLP, RNN, LSTM, GRU	RNN	0.00147	0.03838	0.02885	2.88%	0.44	-	-	-	-
(Hossain et al., 2016)	Bangalesh	Banana	ARIMA	ARIMA(0,2,1)	-	-	-	-	-	19.577	17.60806	0.103167	-
(Abraham et al., 2017)	Brasil	Soja	ANN	ANN	-	-	-	-	-	-	-	-	12.57%
(Abraham et al., 2020)	Brasil	Soja	ANN	ANN	19.713	-	3.362	-	0.992	-	-	-	-
(A. Rehman et al., 2018)	Pakistán	Banana	Regresión lineal múltiple	Regresión lineal múltiple	-	-	-	-	-	-	-	-	60.02% (Acc.)
(Eyduran et al., 2020)	Turquía	Banana	ARIMA y exponential smoothing ²¹	Brown Exponential Smoothing	-	-	-	11.67%	0.988	-	-	-	-
(Devi et al., 2021)	India	Trigo	ARIMA, ANN, híbrido (ARIMA + ANN)	ARIMA + ANN	-	581.05.	-	-	-	-	-	-	-
(Carrasco et al., 2021)	Perú	Banana	ARIMA	ARIMA(1,0,1)	-	-	-	18.59%	-	-	-	-	-

²¹ Holt, Brown and Damped