

UNIVERSIDAD NACIONAL AGRARIA

LA MOLINA

FACULTAD DE INDUSTRIAS ALIMENTARIAS



**“PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN
DE RAÍCES Y TUBÉRCULOS ANDINOS UTILIZANDO
INTELIGENCIA ARTIFICIAL”**

**TESIS PARA OPTAR EL TÍTULO DE INGENIERO EN INDUSTRIAS
ALIMENTARIAS**

ANDRES ISIDRO SOTO TORRES

LIMA-PERÚ

2024

**La UNALM es titular de los derechos patrimoniales de la presente investigación
(Art. 24 - Reglamento de Propiedad Intelectual)**

TURNITIN –ANDRES SOTO TORRES.pdf

INFORME DE ORIGINALIDAD

12%

INDICE DE SIMILITUD

11%

FUENTES DE INTERNET

3%

PUBLICACIONES

3%

TRABAJOS DEL
ESTUDIANTE

FUENTES PRIMARIAS

1

hdl.handle.net

Fuente de Internet

1%

2

repositorio.lamolina.edu.pe

Fuente de Internet

1%

3

sites.google.com

Fuente de Internet

1%

4

www.researchgate.net

Fuente de Internet

1%

5

diposit.ub.edu

Fuente de Internet

<1%

6

dspace.esPOCH.edu.ec

Fuente de Internet

<1%

7

www.slideshare.net

Fuente de Internet

<1%

8

es.acervolima.com

Fuente de Internet

<1%

9

repositorio.uncp.edu.pe

Fuente de Internet

<1%



Recibo digital

Este recibo confirma que su trabajo ha sido recibido por **Turnitin**. A continuación, podrá ver la información del recibo con respecto a su entrega.

La primera página de tus entregas se muestra abajo.

Autor de la entrega:	Andrés Soto
Título del ejercicio:	SUBIR TESIS ANDRES SOTO
Título de la entrega:	TURNITIN -ANDRES SOTO TORRES.pdf
Nombre del archivo:	TURNITIN_-ANDRES_SOTO_TORRES.pdf
Tamaño del archivo:	2.65M
Total páginas:	118
Total de palabras:	33,425
Total de caracteres:	164,077
Fecha de entrega:	16-abr.-2024 01:53p. m. (UTC-0500)
Identificador de la entrega...	2351932913

RESUMEN

El objetivo de esta investigación fue predecir la temperatura inicial de congelación (TI) de raíces y tubérculos andinos (mashua, maca, yacón, arracacha, olluco) mediante técnicas de Inteligencia Artificial, donde esta se revela como una propiedad física crucial, dada su influencia en diversas propiedades termo físicas como el calor específico, conductividad térmica y tiempo de congelación. Se emplearon redes neuronales artificiales (RNA) con diversas configuraciones de capas (3, 5, 10) y neuronas (5, 10, 20), basadas en datos de composición de la USDA (2023). Esta base de datos comprendió 31 conjuntos de datos y 6000 conjuntos generados dentro de los límites de la composición determinada, para analizar el efecto del aumento de datos de entrenamiento. Los datos de composición se utilizaron como entradas, y las temperaturas iniciales de congelación se determinaron mediante el modelo de Boonsupthip y Heldman (2007), siendo utilizados como variables de salida para el entrenamiento de las RNA. Se evaluaron ocho variables de entrada (agua, proteínas, grasas, monosacáridos, disacáridos, fibra, minerales y ácido ascórbico), así como cinco (reduciendo las de mayor peso molecular). Los resultados se validaron comparándolos con temperaturas iniciales de congelación teóricas y analizando la composición proximal y mineral de las raíces y tubérculos. La configuración más precisa fue con 31 conjuntos de datos, 5 variables de entrada, 3 capas ocultas y 5 neuronas, logrando un R^2 de 0.99 y un RMSE de 0.02 °C. Con esta configuración, se predijo la temperatura inicial de congelación de las raíces y tubérculos, validándolas al comparárlas con las mediciones experimentales de la arracacha, maca, olluco, yacón y mashua, obteniendo valores de -1.11, -2.03, -0.7, -1.37 y -0.86 °C respectivamente. La comparación reveló una diferencia absoluta promedio de 0.33 ± 0.17 °C y un porcentaje de error del 31.82%, validando la precisión de la red neuronal. Este estudio representa un avance significativo en la comprensión y aplicación de estas metodologías en la industria alimentaria.

Palabras clave: Raíces y tubérculos, composición, redes neuronales artificiales, temperatura inicial de congelación.

UNIVERSIDAD NACIONAL AGRARIA

LA MOLINA

FACULTAD DE INDUSTRIAS ALIMENTARIAS

**“PREDICCIÓN DE LA TEMPERATURA INICIAL DE
CONGELACIÓN DE RAÍCES Y TUBÉRCULOS ANDINOS
UTILIZANDO INTELIGENCIA ARTIFICIAL”**

Presentado por:

ANDRES ISIDRO SOTO TORRES

**TESIS PARA OPTAR EL TÍTULO DE INGENIERO EN INDUSTRIAS
ALIMENTARIAS**

Sustentado y aprobado ante el siguiente jurado:

Dra. Carmen E. Velezmoro Sánchez
PRESIDENTE

Dra. Indira M. Betalleluz Pallardel
MIEMBRO

Luis F. Vargas Delgado, PhD.
MIEMBRO

Dr. Julio M. Vidaurre Ruiz
ASESOR

M.Sc. Walter F. Salas Valerio
CO-ASESOR

Lima – Perú

2024

DEDICATORIA

A mi querida madre, Juana Torres Tirado, quien siempre ha sido mi fuente de amor incondicional. Su cariño ha sido mi sostén a lo largo de los años. En su amor encuentro fuerza y consuelo.

A mi padre Isidro Soto Hipólito, quien con su trabajo y valores ha sido un pilar fundamental en nuestras vidas. Su ejemplo de honestidad y respeto nos ha guiado siempre.

A mis queridos hermanos, Jorge y Arturo, cuya compañía y amor son el más valioso regalo que mis padres me han brindado.

A mi tío Segundo, a mi tía Rayda y a mi primo Miguel porque ya no me acompañan físicamente pero siempre estarán presentes en mi corazón.

AGRADECIMIENTO

- Al Dr. Julio Vidaurre Ruiz por su inquebrantable apoyo, valiosa enseñanza y la persistencia que me inspiró a creer en mí mismo.
- Al Mg. Francisco Salas Valerio por su apoyo en la realización de la investigación.
- A mis padres y hermanos por siempre apoyarme y tolerarme mientras realizaba la investigación.
- A mi madrina Yasmín Soto, por siempre impulsarme a ser un mejor profesional y haber estado presente en todo mi crecimiento.
- A mi mejor amigo y colega de tesis, Fernando Gutiérrez, por su invaluable amistad y constante apoyo durante la realización de nuestro proyecto de tesis.
- A la Universidad Nacional Agraria La Molina por haberme dado los mejores años de mi vida.

ÍNDICE GENERAL

RESUMEN

ABSTRACT

I. INTRODUCCIÓN.....	1
II. REVISIÓN DE LITERATURA	3
2.1. CONGELACIÓN DE ALIMENTOS.....	3
2.1.1. PROCESO DE CONGELACIÓN.....	3
2.1.2. CURVAS DE CONGELACIÓN	5
2.1.3. TEMPERATURA INICIAL DE CONGELACIÓN (Tf).....	8
2.1.4. DETERMINACIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (Tf)	9
2.2. RAÍCES Y TUBÉRCULOS ANDINOS	14
2.2.1. MASHUA	15
2.2.2. OLLUCO.....	19
2.2.3. MACA.....	23
2.2.4. ARRACACHA.....	26
2.2.5. YACÓN	31
2.3. INTELIGENCIA ARTIFICIAL	37
2.3.1. APRENDIZAJE CONTINUO O <i>MACHINE LEARNING</i>	37
2.3.2. APRENDIZAJE PROFUNDO O <i>DEEP LEARNING</i>	38
2.3.3. REDES NEURONALES	38
2.4. APLICACIONES DE LA INTELIGENCIA EN LA INDUSTRIA ALIMENTARIA.....	45
III. METODOLOGÍA	49
3.1. LUGAR DE ESTUDIO.....	49
3.2. MATERIAS PRIMAS	49
3.3. EQUIPOS Y MATERIALES	49
3.3.1. EQUIPOS.....	49
3.3.2. MATERIALES Y REACTIVOS	50
3.3.3. HERRAMIENTAS Y BIBLIOTECAS INFORMÁTICAS	50
3.4. MÉTODOS DE ANÁLISIS	53

3.4.1. CARACTERIZACIÓN PROXIMAL Y FISICOQUÍMICA DE LAS MATERIAS PRIMAS.....	53
3.5. DETERMINACIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN DE RAÍCES Y TUBÉRCULOS	54
3.5.1. RECOPIACIÓN DE DATOS PUBLICADOS DE LA COMPOSICIÓN Y LA TEMPERATURA INICIAL DE CONGELACIÓN (TF) DE VEGETALES	54
3.5.2. GENERACIÓN DE DATOS Y TEMPERATURAS INICIALES DE CONGELACIÓN.....	55
3.5.3. VERIFICACIÓN DE LOS SENSORES DATATRACE CON UNA DISOLUCIÓN DE NaCl A DIFERENTES CONCENTRACIONES.....	55
3.5.4. DETERMINACIÓN EXPERIMENTAL DE LA TEMPERATURA INICIAL DE CONGELACIÓN (TF)	57
3.6. PROCEDIMIENTO EXPERIMENTAL	58
3.6.1. DESARROLLO DE UNA RED NEURONAL ARTIFICIAL PROFUNDA PARA LA PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (TF) DE VEGETALES	58
3.6.2. DESARROLLO DE DIFERENTES CONFIGURACIONES DE REDES NEURONALES.....	64
3.6.3. PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (TF) DE RAÍCES Y TUBÉRCULOS ANDINOS Y VALIDACIÓN DE LA RED NEURONAL ARTIFICIAL PROFUNDA	65
3.7. ANÁLISIS ESTADÍSTICO.....	67
IV. RESULTADOS Y DISCUSIÓN	69
4.1. ETAPA I: OBTENCIÓN DE VALORES DE TEMPERATURA INICIAL DE CONGELACIÓN (TF) DE VEGETALES PARA ENTRENAR LA RED NEURONAL ..	69
4.1.1. COMPOSICIÓN PROXIMAL DE VEGETALES	69
4.1.2. PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (TF).....	75
4.1.3. CARACTERIZACIÓN FÍSICO QUÍMICA Y PROXIMAL DE RAÍCES Y TUBÉRCULOS EN ESTUDIO.....	81
4.2. ETAPA II: ENTRENAMIENTO DE REDES NEURONALES CON VARIACIONES EN CAPAS, NEURONAS Y CONJUNTOS DE DATOS DE ENTRADA PARA PREDECIR LA TEMPERATURA INICIAL DE CONGELACIÓN.	90
4.2.1. ESCENARIO 1	90

4. 2. 2. ESCENARIO 2	98
4. 2. 3. ESCENARIO 3 Y 4.....	104
4.3. ETAPA III: PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (TF) DE RAÍCES Y TUBÉRCULOS ANDINOS Y VALIDACIÓN DE LA RED NEURONAL ARTIFICIAL PROFUNDA	109
4. 3.1. DETERMINACIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN DE DISOLUCIONES DE NaCl A DIFERENTES CONCENTRACIONES	109
4. 3. 2. COMPARACIÓN ENTRE LAS TEMPERATURAS INICIALES DE CONGELACIÓN DE RAÍCES Y TUBÉRCULOS PREDICHAS MEDIANTE LAS CONFIGURACIONES ÓPTIMAS DE LAS REDES NEURONALES Y AQUELLAS OBTENIDAS EXPERIMENTALMENTE.....	112
4. 3. 3. DETERMINACIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN POR EL MODELO DE BOONSHUPHIP Y HELDMAN (2007) Y PREDICHOS POR REDES NEURONALES	112
V. CONCLUSIONES.....	121
VI. RECOMENDACIONES.....	122
VII.BIBLIOGRAFÍA.....	123
VIII.ANEXOS.....	139

ÍNDICE DE TABLAS

Tabla 1: Modelos polinomiales de una sola variable para predecir la temperatura inicial de congelación.....	10
Tabla 2: Nombre según la región de la <i>Tropaeolum tuberosum</i>	15
Tabla 3: Clasificación taxonómica de la mashua (<i>Tropaeolum Tuberosum</i>)	16
Tabla 4: Composición química de la mashua fresca en base húmeda	18
Tabla 5: Propiedades fisicoquímicas de la mashua fresca	19
Tabla 6: Clasificación taxonómica del olluco (<i>Ullucus Tuberosus</i>)	20
Tabla 7: Composición química del olluco en base húmeda.....	21
Tabla 8: Propiedades fisicoquímicas del olluco	22
Tabla 9: Clasificación taxonómica de la maca (<i>Lepidium meyenii</i>)	24
Tabla 10: Composición química de la maca fresca	25
Tabla 11: Propiedades fisicoquímicas de la maca fresca	26
Tabla 12: Clasificación taxonómica de la arracacha (<i>Arracacia xanthorrhiza</i>)	27
Tabla 13: Composición química de la arracacha	30
Tabla 14: Propiedades fisicoquímicas de la arracacha	31
Tabla 15: Clasificación Taxonómica del yacón (<i>Smallanthus sonchifolius</i>)	32
Tabla 16: Composición química del yacón.....	34
Tabla 17: Composición de carbohidratos del yacón	36
Tabla 18: Propiedades fisicoquímicas del yacón.....	36
Tabla 19: Funciones de activación.....	42
Tabla 20: Uso de redes neuronales artificiales (ANN) en matrices alimentarias	46
Tabla 21: Tratamientos a evaluar para mejorar la predicción de la red neuronal artificial desarrollada.....	63
Tabla 22: Composición proximal de vegetales obtenida de la base de datos del Departamento de Agricultura de Estados Unidos	73
Tabla 23: Pesos moleculares de los componentes de los vegetales	76
Tabla 24: Comparación entre el contenido de agua y la temperatura inicial de congelación de vegetales, predichas por el modelo propuesto por Boonsupthip y Heldman (2007) y datos obtenidos de la literatura	78
Tabla 25: Composición proximal obtenida de las raíces y tubérculos en estudio	81
Tabla 26: Propiedades fisicoquímicas de raíces y tubérculos en estudio	88

Tabla 27: Predicción de Tf (°C) mediante redes neuronales profundas con diferentes números de capas y neuronas utilizando los 31 datos	92
Tabla 28: Predicción de Tf (°C) mediante redes neuronales profundas con diferente número de capas y neuronas utilizando los 31 datos reduciendo las variables de entrada (sin proteínas, lípidos y fibra).....	99
Tabla 29: Temperatura inicial de congelación de NaCl a diferentes concentraciones.....	110
Tabla 30: Diferencia absoluta y porcentaje de error entre Tf (°C) experimental con Tf (°C) determinado por el modelo de Boonsupthip y Heldman (2007) y predichos por redes neuronales entrenada con 31 vegetales.....	115
Tabla 31: Diferencia absoluta y porcentaje de error entre Tf (°C) experimental con Tf (°C) determinado por el modelo de y predichos por redes neuronales entrenada con 6000 datos.....	119

ÍNDICE DE FIGURAS

Figura 1: Relación típica Temperatura-Tiempo durante el congelamiento de agua.....	6
Figura 2: Relación típica Temperatura-Tiempo durante el congelamiento de una solución acuosa	7
Figura 3: Curva de congelación. A: Agua, B: Solución acuosa de azúcar, C: Alimento, S: Sobre enfriamiento. a: Temperatura de cristalización del hielo, b: Temperatura inicial de congelación, c: Fin de congelación, d: Formación del primer cristal, e: Punto eutéctico	8
Figura 4: Diagrama esquemático de una configuración experimental para solución de azúcar y gel de almidón. T: Bloque aislante superior, B: Bloque aislante inferior, S: Bloque aislante lateral, R: Sonda de termopar, H: Soporte de muestra de acero inoxidable, D: Registrador de temperatura, C: Congelador de cofre.....	13
Figura 5: Curva de enfriamiento del jarabe de sacarosa 40 °Brix que muestra el sobre enfriamiento (punto a), el punto de congelación inicial (punto b) y el punto final de congelación (punto c)	14
Figura 6: Terminología en el campo de la inteligencia artificial	37
Figura 7: Red neuronal con 3 capas.....	38
Figura 8: Generación de 6000 conjunto de datos	56
Figura 9: Diagrama representativo del A) Módulo de ultracongelación; B) Sensores inalámbricos de temperatura; C) Tubo de plástico que contendrá a las muestras y D) Computadora donde se recibirán los datos de tiempo y temperatura de la curva de congelación de los alimentos.....	57
Figura 10: Ejemplo de importaciones de librerías y datos de entrenamiento a utilizar para programar una red neuronal profunda capaz de predecir la Tf.....	59
Figura 11: Esquema de la red neuronal artificial profunda con 8 valores de entrada, 1 valor de salida y 3 capas ocultas con 5 neuronas por capa. Donde A es el contenido de agua, P es el contenido de proteínas, L es el contenido de lípidos, M es el contenido de Monosacáridos, D es el contenido de Disacáridos, F es el contenido de Fibra, M es el contenido de minerales y A/B contenidos ácidos/bases	60
Figura 12: Esquema de la red neuronal artificial profunda con 8 valores de entrada, 1 valor de salida y con capas ocultas y neuronas variables. Donde A es el contenido de agua, P es el contenido de proteínas, L es el contenido de lípidos, M es el contenido de minerales, D es el	

contenido de disacáridos, F es el contenido de fibra, M es el contenido de monosacáridos y A/B contenidos ácidos/bases	62
Figura 13: Esquema experimental para la predicción de la temperatura inicial de congelación de tubérculos y raíces andinos utilizando una red neuronal artificial profunda	67
Figura 14: Contenido de minerales en alimentos vegetales	72
Figura 15: Matriz de calor de la correlación existente entre variables de composición y la temperatura inicial de congelación	80
Figura 16: Evaluación del número de capas y neuronas con la red neuronal entrenada con 31 datos.....	91
Figura 17: Entrenamiento de la red neuronal con 1000 épocas (31 conjuntos de datos, 8 variables de entrada, 3 capas ocultas, 5 neuronas y 1 variable de salida)	97
Figura 18: Evaluación del número de capas y neuronas con la red neuronal entrenada con 31 datos reduciendo las variables de entrada (sin proteínas, lípidos y fibra)	102
Figura 19: a) Correlación entre temperaturas iniciales de congelación con red neuronal (8 variables de entrada, 3 capas ocultas, 5 neuronas) entrenada con 31 datos vs. modelo de Boonsupthip y Heldman (2007). b) Correlación entre temperaturas iniciales de congelación con red neuronal (5 variables de entrada, 3 capas ocultas, 5 neuronas) entrenada con 31 datos vs. modelo de Boonsupthip y Heldman (2007)	103
Figura 20: a) Evaluación del número de capas y neuronas con la red neuronal entrenada con 6000 datos. b) Evaluación del número de capas y neuronas con la red neuronal entrenada con 6000 datos reduciendo las variables de entrada (sin proteínas, lípidos y fibra)	107
Figura 21: a) Correlación entre temperaturas iniciales de congelación con red neuronal (8 variables de entrada, 3 capas ocultas, 5 neuronas) entrenada con 6000 datos vs. modelo de Boonsupthip y Heldman (2007). b) Correlación entre temperaturas iniciales de congelación con red neuronal (5 variables de entrada, 3 capas ocultas, 5 neuronas) entrenada con 6000 datos vs. modelo de Boonsupthip y Heldman (2007).....	108
Figura 22: Temperatura inicial de congelación del NaCl a diferentes concentraciones....	111
Figura 23: Curva de congelación de las raíces y tubérculos.....	113
Figura 24: Velocidad de congelación de raíces y tubérculos.....	113

ÍNDICE DE ANEXOS

ANEXO 1: CÓDIGOS PARA LA GENERACIÓN DE UNA MATRIZ DE CALOR A TRAVÉS DE GOOGLE COLABORATORY	139
ANEXO 2: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE AGUA DE RAÍCES Y TUBÉRCULOS	140
ANEXO 3: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE PROTEÍNA DE RAÍCES Y TUBÉRCULOS	141
ANEXO 4: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE GRASA DE RAÍCES Y TUBÉRCULOS	142
ANEXO 5: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE FIBRA DE RAÍCES Y TUBÉRCULOS	143
ANEXO 6: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE CALCIO DE RAÍCES Y TUBÉRCULOS	144
ANEXO 7: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE FÓSFORO DE RAÍCES Y TUBÉRCULOS	145
ANEXO 8: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE MAGNESIO DE RAÍCES Y TUBÉRCULOS	146
ANEXO 9: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE POTASIO DE RAÍCES Y TUBÉRCULOS	147
ANEXO 10: ANÁLISIS DE VARIANZA PARA LA VITAMINA C DE RAÍCES Y TUBÉRCULOS.....	148
ANEXO 11: ANÁLISIS DE VARIANZA PARA EL pH DE RAÍCES Y TUBÉRCULOS.....	149
ANEXO 12: ANÁLISIS DE VARIANZA PARA LA ACIDEZ DE RAÍCES Y TUBÉRCULOS.....	150
ANEXO 13: ANÁLISIS DE VARIANZA PARA SÓLIDOS SOLUBRES DE RAÍCES Y TUBÉRCULOS.....	151
ANEXO 14: CÓDIGOS DE VARIABLES DE ENTRADA Y DE SALIDA DE LAS DIFERENTES CONFIGURACIONES DE REDES NEURONALES.....	152

ANEXO 15: ARQUITECTURA DE RED NEURONAL CON 8 VARIABLES DE ENTRADA, 3 CAPAS OCULTAS, 5 NEURONAS Y 1 VARIABLE DE SALIDA.....	153
ANEXO 16: ARQUITECTURA DE RED NEURONAL CON 5 VARIABLES DE ENTRADA, 5 CAPAS OCULTAS, 5 NEURONAS Y 1 VARIABLE DE SALIDA.....	154
ANEXO 17: ARQUITECTURA DE RED NEURONAL CON 5 VARIABLES DE ENTRADA, 9 CAPAS OCULTAS, 5 NEURONAS Y 1 VARIABLE DE SALIDA.....	155
ANEXO 18: ARQUITECTURA DE RED NEURONAL CON 5 VARIABLES DE ENTRADA, 3 CAPAS OCULTAS, 5 NEURONAS Y 1 VARIABLE DE SALIDA.....	156
ANEXO 19: ANÁLISIS DE VARIANZA PARA EL Tf DE RAÍCES Y TUBÉRCULOS	157
ANEXO 20: CÓDIGOS DEL ENTRENAMIENTO DE LA RED NEURONAL ÓPTIMA (5 VARIABLES DE ENTRADA, 1 VARIABLE DE SALIDA, 3 CAPAS OCULTAS Y 5 NEURONAS) CON 31 CONJUNTO DE DATOS	158

RESUMEN

El objetivo de esta investigación fue de predecir la temperatura inicial de congelación (T_f) de raíces y tubérculos andinos (mashua, maca, yacón, arracacha, olluco) mediante técnicas de Inteligencia Artificial, donde esta se revela como una propiedad física crucial, dada su influencia en diversas propiedades termo físicas como el calor específico, conductividad térmica y tiempo de congelación. Se emplearon redes neuronales artificiales (RNA) con diversas configuraciones de capas (3, 5, 10) y neuronas (5, 10, 20), basadas en datos de composición de la USDA (2023). Esta base de datos comprendió 31 conjuntos de datos y 6000 conjuntos generados dentro de los límites de la composición determinada, para analizar el efecto del aumento de datos de entrenamiento. Los datos de composición se utilizaron como entradas, y las temperaturas iniciales de congelación se determinaron mediante el modelo de Boonsupthip y Heldman (2007), siendo utilizados como variables de salida para el entrenamiento de las RNA. Se evaluaron ocho variables de entrada (agua, proteínas, grasas, monosacáridos, disacáridos, fibra, minerales y ácido ascórbico), así como cinco (reduciendo las de mayor peso molecular). Los resultados se validaron comparándolos con temperaturas iniciales de congelación teóricas y analizando la composición proximal y mineral de las raíces y tubérculos. La configuración más precisa fue con 31 conjuntos de datos, 5 variables de entrada, 3 capas ocultas y 5 neuronas, logrando un R^2 de 0.99 y un RMSE de 0.02 °C. Con esta configuración, se predijo la temperatura inicial de congelación de las raíces y tubérculos, validándolas al compararlas con las mediciones experimentales de la arracacha, maca, olluco, yacón y mashua, obteniendo valores de -1.11, -2.03, -0.7, -1.37 y -0.86 °C respectivamente. La comparación reveló una diferencia absoluta promedio de 0.33 ± 0.17 °C y un porcentaje de error del 31.82%, validando la precisión de la red neuronal. Este estudio representa un avance significativo en la comprensión y aplicación de estas metodologías en la industria alimentaria.

Palabras clave: Raíces y tubérculos, composición, redes neuronales artificiales, temperatura inicial de congelación.

ABSTRACT

The objective of this research was to predict the initial freezing temperature (T_f) of Andean roots and tubers (mashua, maca, yacon, arracacha, olluco) using Artificial Intelligence techniques. T_f emerges as a crucial physical property, influencing thermophysical properties such as specific heat, thermal conductivity, and freezing time. Artificial neural networks (ANNs) were employed with varying layer configurations (3, 5, 10) and neurons (5, 10, 20), based on composition data from the USDA (2023). The database comprised 31 datasets and 6000 generated sets within established composition limits to analyze the effect of increased training data. Composition data served as inputs, and freezing temperatures were determined by the Boonsupthip and Heldman (2007) model, used as output variables for ANN training. Eight input variables were evaluated (water, proteins, fats, monosaccharides, disaccharides, fiber, minerals, and ascorbic acid), along with five (with reduced molecular weight). Results were validated by comparing them with theoretical freezing temperatures and analyzing the proximal and mineral composition of roots and tubers. The most accurate configuration utilized 31 datasets, 5 input variables, 3 hidden layers, and 5 neurons, achieving an R² of 0.99 and an RMSE of 0.02 °C. Using this configuration, freezing temperatures of roots and tubers were predicted and validated by comparing them with experimental measurements of arracacha, maca, olluco, yacon, and mashua, obtaining values of -1.11, -2.03, -0.7, -1.37, and -0.86 °C, respectively. The comparison revealed an average absolute difference of 0.33 ± 0.17 °C and a percentage error of 31.82%, confirming the accuracy of the neural network. This study represents a significant advancement in understanding and applying these methodologies in the food industry.

Keywords: Roots and tubers, composition, artificial neural networks, initial freezing temperature.

I. INTRODUCCIÓN

La Inteligencia Artificial (IA) representa una innovadora herramienta computacional empleada para abordar problemas de la vida real en diversas áreas, incluyendo el modelamiento, clasificación y análisis de datos. Esta disciplina implica la programación de computadoras para emular tareas que demandan inteligencia, juicio y experiencia humana, abarcando facetas como el aprendizaje automático (*Machine Learning*), el aprendizaje profundo (*Deep Learning*) y las redes neuronales (*Neuronal Networks*) (Addanki *et al.*, 2022). Según Rejeb *et al.* (2022), la IA ha experimentado un crecimiento vertiginoso y ha generado una transformación significativa en diversos sectores económicos. Sin embargo, aún persiste una carencia en la comprensión integral de su potencial para mejorar la industria alimentaria, y se observa una notable escasez de investigaciones sobre la influencia de la IA en los recursos agroalimentarios del Perú.

El aprendizaje profundo (*Deep Learning*) se posiciona como un método eficaz para construir arquitecturas profundas y generar modelos mediante iteraciones de funciones en múltiples capas. La efectividad de este método supera a los enfoques de aprendizaje continuo (*Machine Learning*) (Zhu *et al.*, 2021). Las redes neuronales, a su vez, representan actores potenciales en el ámbito agrícola. De acuerdo con Rejeb *et al.* (2022), la combinación de soluciones de visión artificial y algoritmos de IA en la agricultura posibilita la toma de decisiones y conlleva a múltiples beneficios, como la automatización de tareas, incremento de la rentabilidad y mejora de la calidad y seguridad de los alimentos. Aunque el aprendizaje profundo se muestra como una opción viable para proporcionar herramientas avanzadas de análisis en el procesamiento de datos de manufactura, la literatura sobre esta alternativa es limitada en el contexto de la fabricación y su relación con la sostenibilidad (Jamwal *et al.*, 2022).

Investigaciones previas han explorado su aplicación en aspectos relativos a la salud, calidad y seguridad alimentaria, así como en la detección de elementos extraños.

No obstante, la información concerniente a la determinación de propiedades específicas de los alimentos se encuentra escasamente documentada, evidenciándose el uso de redes neuronales únicamente para la predicción del tiempo de congelación de alimentos, tal como se observa en los trabajos de Goñi *et al.* (2008) y Mittal y Zhang (2000), sin abordar la predicción de la temperatura inicial de congelación de los alimentos.

Dado el contexto expuesto, el presente trabajo se centra en la necesidad de determinar la temperatura inicial de congelación (T_f) de raíces y tubérculos, tales como mashua, maca, yacón, arracacha y olluco, mediante el uso de herramientas de Inteligencia Artificial.

Para ello se obtuvo como objetivo general:

Predecir la temperatura inicial de congelación (T_f) de raíces y tubérculos, tales como mashua, maca, yacón, arracacha y olluco, utilizando Inteligencia Artificial.

Los objetivos específicos fueron:

- Desarrollar y entrenar una red neuronal profunda capaz de predecir la T_f de vegetales, utilizando valores de composición proximal y T_f previamente publicados.
- Generar 6000 conjuntos de datos de composición para evaluar su influencia en la capacidad de predicción de la red neuronal.
- Identificar los componentes proximales significativos en la predicción de la temperatura inicial de congelación de los vegetales.
- Validar la red neuronal profunda desarrollada a través de la determinación experimental de la temperatura inicial de congelación de mashua, maca, yacón, arracacha y olluco.

II. REVISIÓN DE LITERATURA

2.1. CONGELACIÓN DE ALIMENTOS

La congelación de los alimentos se realiza con el propósito de preservarlos durante un largo periodo de tiempo manteniendo su calidad. Este proceso provoca un cambio en el estado físico del agua, que se transforma en hielo al extraer energía mediante el enfriamiento por debajo de la temperatura de congelación, teniendo como resultado la concentración de la fase no congelada (Rahman, 2008).

Desde una perspectiva de ingeniería, Jie *et al.* (2003) señalan que la congelación de alimentos es un fenómeno de transferencia de calor no estacionario. Esto implica que el alimento pierde calor a través de la convección en su superficie y por conducción en su interior.

Al diseñar y simular los equipos utilizados en el congelamiento de alimentos es necesario considerar diversos elementos. Estos elementos incluyen la cantidad de energía que debe ser extraída, tanto en términos de entalpías (sensible y latente), la composición y concentración de los alimentos, así como la forma del alimento (homogénea o heterogénea) y sus dimensiones (área, altura, longitud, radio, grosor y ancho). También es crucial tener en cuenta las propiedades físicas del alimento, como su punto de congelación, densidad, calor latente, calor específico y conductividad térmica (Rahman, 2008).

2.1.1. PROCESO DE CONGELACIÓN

a. SOBRE ENFRIAMIENTO (ΔT_s)

Cuando el hielo y el agua coexisten a presión atmosférica, la temperatura del sistema alcanza el punto de congelación del agua pura ($T_f = 0\text{ }^{\circ}\text{C}$) siempre y cuando ambas fases

líquida y sólida estén presentes. La cantidad de hielo permanece constante mientras no se añada ni se retire energía de la mezcla. Sin embargo, para que el agua efectivamente se congele, es necesario enfriarla a temperaturas considerablemente inferiores al punto de congelación

Este enfriamiento adicional, denominada como sobre enfriamiento (ΔT_s), es necesario para que ocurra el proceso de nucleación (Sun, 2012).

La congelación de sistemas alimentarios es más compleja que la congelación de agua pura, ya que estos contienen agua y solutos, teniendo un comportamiento similar a soluciones acuosas. En soluciones acuosas, el sobre enfriamiento generalmente es menor en soluciones acuosas que en agua pura, ya que el soluto agregado promueve la nucleación heterogénea (Sun, 2012).

b. NUCLEACIÓN

La nucleación se refiere al proceso por el cual se forma el mínimo cristal con un radio crítico que luego puede expandirse y crecer. Durante la nucleación se libera el calor latente de solidificación; las moléculas se agregan en una partícula ordenada de un tamaño suficiente para establecerse y servir como sitio para el crecimiento de cristales (Evans, 2008).

La nucleación puede ser homogénea o heterogénea, la nucleación homogénea sólo ocurre en agua libre de impurezas, mientras que la nucleación heterogénea se produce cuando las moléculas de agua se agrupan alrededor de impurezas o partículas grandes que actúan como superficies activas para la formación de núcleos de hielo. La nucleación heterogénea es más común en los sistemas alimentarios. La tasa de nucleación depende de la temperatura del medio de congelación, del sobre enfriamiento y de la viscosidad del líquido, a mayor sobre enfriamiento mayor tasa de nucleación (Sun, 2012).

Durante la formación de un núcleo de hielo estable, es posible un mayor crecimiento mediante la agregación de moléculas a la interfase sólido-líquido. Es importante destacar que este crecimiento no es instantáneo y está controlado por dos factores clave: la tasa de

eliminación del calor latente liberado durante el cambio de fase y la tasa de transferencia de masa en el caso de soluciones (Sun, 2012).

Sin embargo, la transferencia de calor no es el único factor que gobierna el crecimiento de los cristales o la tasa de propagación del hielo. Durante la cristalización del hielo a partir de una solución, los solutos son rechazados de la región ocupada por los cristales de hielo puro. Por lo tanto, el crecimiento del hielo también depende de la transferencia de masa, donde las moléculas se difunden y se agregan al cristal de hielo en crecimiento, al mismo tiempo que los solutos deben migrar fuera del cristal. El tamaño de los cristales varía inversamente con el número de núcleos formados. En situaciones de congelación a altas tasas, se genera múltiples núcleos y la masa de hielo se distribuye en una gran cantidad de cristales pequeños (Sun, 2012).

2.1.2. CURVAS DE CONGELACIÓN

a. CONGELACIÓN DE AGUA PURA

En la Figura 1 se muestra las relaciones típicas de tiempo y temperatura durante la congelación de muestras pequeñas (sin gradientes térmicos) de agua pura. El enfriamiento de agua pura involucra en la primera etapa, la remoción de calor sensible ($4.18 \text{ kJ/kg } ^\circ\text{C}$). La nucleación es necesaria para que se inicie la congelación y la temperatura puede descender por debajo de $0 \text{ } ^\circ\text{C}$ sin la formación de cristales de hielo. El punto S indica el sobre enfriamiento del líquido antes de que comience la cristalización. Este es un estado en no equilibrio, metaestable, análogo a una energía de activación necesaria para el proceso de nucleación (Akyrut *et al*, 2002). Una vez que se alcanza la masa crítica de núcleos, el sistema nuclea en el punto S (Figura 1) y libera su calor latente eliminado para el sistema.

El aumento abrupto de la temperatura (del punto S al punto B), debido a la liberación del calor de solidificación después del sobre enfriamiento inicial, representa el inicio de la cristalización del hielo (Sun, 2012).

Una vez la cristalización comienza, la temperatura alcanza el punto B, que vendría a ser la temperatura inicial de congelación del agua pura ($0 \text{ } ^\circ\text{C}$). Mientras que el sólido y el líquido

están en equilibrio, la temperatura permanece en el punto de congelación hasta que toda el agua se ha convertido en hielo (punto C). En agua pura, la “meseta” de B a C representa el tiempo durante el cual crece a los cristales y cuando termina el crecimiento de estos se da una solidificación que elimina calor adicional resultando la disminución de temperatura hacia el punto D (Sun, 2012).




Figura 1: Relación típica Temperatura-Tiempo durante el congelamiento de agua

FUENTE: Sun (2012)

b. CONGELACIÓN DE SISTEMAS ALIMENTARIOS

La congelación de sistemas alimentarios se torna más compleja que la de agua pura, dado que estos incluyen tanto agua como solutos, y su comportamiento se asemeja al de una solución acuosa (Sun, 2012).

Al congelar soluciones acuosas (Figura 2), se observa también un fenómeno de sobre enfriamiento (punto S), seguido de la nucleación en dicho punto. El calor de cristalización liberado eleva la temperatura de S hasta B. El punto B representa la temperatura inicial de congelación de la solución, que es más bajo que el punto de congelación del agua pura. La

depresión del punto de congelación está determinada por el número de moléculas de soluto disueltas, además en soluciones acuosas, el sobre enfriamiento es generalmente más bajo que en agua pura, dado que el soluto agregado promueve la nucleación heterogénea, acelerando el proceso de nucleación (Sun, 2012).

Sun (2012) menciona que, en soluciones altamente concentradas, a veces es difícil inducir el sobre enfriamiento. Desde el punto B hasta el punto C en la Figura 2, se produce un enfriamiento adicional que conlleva al crecimiento de cristales y a una formación sustancial de hielo. A medida que el agua se convierte en cristales de hielo, se observa un aumento gradual en la concentración de soluto. La pendiente negativa de la curva de B a C en la Figura 2 refleja este cambio en la concentración. La concentración de soluto aumenta durante el proceso de congelación y eventualmente alcanza su temperatura eutéctica. La sobresaturación existente en el punto C en la Figura 2, se puede observar antes de la cristalización del soluto. El calor latente de cristalización del soluto se libera en el punto C, lo que provoca un ligero aumento de la temperatura de C a D (Figura 2). En el punto D, la solución adquiere la composición de equilibrio eutéctico que se mantiene constante durante la solidificación eutéctica y a temperatura constante de D a E. Finalmente, el enfriamiento por debajo de la temperatura en el punto E se produce después de que la solución se haya solidificado por completo.




Figura 2: Relación típica Temperatura-Tiempo durante el congelamiento de una solución acuosa

FUENTE: (Sun, 2012)

2.1.3. TEMPERATURA INICIAL DE CONGELACIÓN (Tf)

Sun (2012) menciona que el punto inicial de congelación es una de las propiedades físicas más importantes de los alimentos debido a la discontinuidad de las propiedades termo físicas que se presentan en esta. Este se requiere para predecir las propiedades termo físicas de los alimentos congelados además para el diseño de nuevos métodos de congelación.

La temperatura de congelación inicial varía en función del contenido de agua, el peso molecular de los componentes, las interacciones entre estos y las características de unión con el agua. En la Figura 3, se aprecia en el punto "b" la temperatura inicial de congelación en agua, una solución acuosa de azúcar y un alimento. Dado que el contenido total de agua suele ser la parte predominante en la composición de diversos alimentos y es relativamente sencillo de medir, la mayoría de las correlaciones empíricas se basan en este parámetro. En la literatura, se han expresado correlaciones generalizadas entre el punto de congelación inicial y el contenido de agua mediante ecuaciones tanto lineales como no lineales (Sun, 2012).




Figura 3: Curva de congelación. A: Agua, B: Solución acuosa de azúcar, C: Alimento, S: Sobre enfriamiento. a: Temperatura de cristalización del hielo, b: Temperatura inicial de congelación, c: Fin de congelación, d: Formación del primer cristal, e: Punto eutéctico

FUENTE: Rahman (1995)

2.1.4. DETERMINACIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (Tf)

La temperatura inicial de congelación se puede definir como las condiciones de temperatura y presión en las cuales algunos cristales de hielo puro están en equilibrio con la solución líquida o la parte líquida de un alimento, esta debe mantenerse lo más constante posible (mediante uso de un sistema de regulación adecuado) para una medición correcta y la velocidad de enfriamiento, el tamaño de muestra y ubicación del sensor de temperatura deben permitir el monitoreo de una meseta de congelación con el tiempo (Guignon *et al.*, 2008).

a. ECUACIONES POLINOMIALES

Guignon *et al.* (2008) mencionan en su trabajo el modelo propuesto por Bridgman (1912) para representar la curva de congelación donde un polinomio simple se ajusta a puntos experimentales.

$$T_f = a \cdot P^2 + b \cdot P + c \quad (1)$$

Donde T_f (°C o K) es la temperatura inicial de congelación a una presión P (MPa). Para el agua, $a = -0.0722$, $b = -0.000155$ y $c = 0$.

Utilizando el mismo método, Zhu *et al.* (2006) han obtenido una relación entre la temperatura y presión mediante regresión sobre diez puntos, con un coeficiente (R^2) de 0.999, para la papa, espesantes y músculos de salmón y cerdo.

Estas ecuaciones dependen directamente de la precisión de las medidas y del número de datos ajustados; esta es una forma muy amigable de representar la curva de congelación involucrando solo tres parámetros.

En la Tabla 1 se presentan modelos predictivos polinomiales para determinar la temperatura inicial de congelación de los alimentos a través de su contenido de agua o sólidos solubles.

Tabla 1: Modelos polinomiales de una sola variable para predecir la temperatura inicial de congelación

Modelo	Alimento	Ecuación	Variable
	Carne	$\Delta T_f = 1.9 + (1.47)X_w$	Contenido de agua
Chang y Tao (1981)	Frutas y Verduras	$\Delta T_f = -14.46 + 49.19X_w - 37.07(X_w)^2$	Contenido de agua
	Jugo	$\Delta T_f = 152.63 - 327.35X_w - 176.49(X_w)^2$	Contenido de agua
Chen <i>et al.</i> (1990)	Frutas, Verduras y Jugos	$\Delta T_f = 10X_s + 50(X_s)^3$	Contenido de sólidos solubles
Jie <i>et al.</i> (2003)	Frutas	$T_f = 1.146694 - 0.19555(X_s)$	Contenido de sólidos solubles

b. ECUACIÓN DE SIMON-LIKE

Las ecuaciones de Simon-like son ecuaciones empíricas adaptadas de curvas experimentales de fusión de sólidos (Guignon *et al.*, 2008):

$$\frac{P-P_t}{a} = \left(\frac{T_f}{T_t} \right)^c - 1 \quad (2)$$

Donde T_t y P_t son las coordenadas del punto triple, T_f es la temperatura inicial de congelación a una presión P , donde a y c son parámetros de ajuste. Kechin (2001) introdujo modificaciones a los datos experimentales para hacerlos más universales, la siguiente ecuación es una de tipo Simon-like para ajustar la curva de fusión entre hielo y agua.

$$\frac{P}{P_o} = \left[1 - \alpha \cdot \left(1 - \frac{T_f^\beta}{T_o} \right) + \chi \cdot \left(1 - \frac{T_f^\delta}{T_o} \right) \right] \quad (3)$$

Donde α , β , χ , δ , T_o y P_o son parámetros para realizar ajustes; T_f (K) y P (MPa) caracterizan el punto de congelación inicial. Wagner *et al.* (1994) proporcionaron los siguientes parámetros ajustados para la curva de fusión de agua-hielo: $\alpha = 626000$, $\beta = -3$, $\chi = 197135$, $\delta = 21.2$, $T_o = 273.16$ y $P_o = 0.000611657$.

Guignon *et al.* (2008) mencionan que las ecuaciones Simon-like se han aplicado para gran cantidad de sustancias, compuestos aromáticos, vegetales y soluciones acuosas. Las ventajas de estas ecuaciones son su simplicidad, capacidad de extrapolación y su formulación general que permite describir curvas de transición de fase entre líquido y hielo.

c. LEY MODIFICADA DE RAOULT

Guignon *et al.* (2008) mencionan que el punto inicial de congelación de sistemas acuosos y alimentos se puede estimar a partir de la composición utilizando la ley de Raoult modificada:

$$\ln X_a = \frac{\lambda_f}{R} \left(\frac{1}{T_o} - \frac{1}{T} \right) \quad (4)$$

Donde R es la constante de los gases (8.314 kJ/kmol.K), T es la temperatura inicial de congelación (K), T_o es la temperatura de congelación del agua pura (K), λ_f es el calor molar de fusión del hielo (J.mol⁻¹) y X_a es la fracción molar de una solución (g.mol⁻¹).

d. MODELO EMPÍRICO PROPUESTO POR BOONSUPTHIP Y HELDMAN (2007) BASADO EN LA LEY MODIFICADA DE RAOULT

Boonsupthip y Heldman (2007); Waraporn Boonsupthip, Sajjaanantakul y Heldman (2009) propusieron el siguiente modelo semi empírico para determinar la temperatura inicial de congelación en diversos alimentos:

$$\frac{1}{T_f} = \frac{1}{T_{fo}} - \frac{RM_w}{\lambda} \ln \left[\frac{(X_u - X_b)/M_w}{(X_u - X_b)/M_w + \sum_i (X_i/M_i)} \right] \quad (5)$$

Donde X_u es la fracción de agua del vegetal; X_b es la fracción de agua no congelable, M_w es el peso molecular del agua (18.02 g/mol); T_{fo} es el punto de fusión del agua (273.15 K); R es la constante de los gases ideales (8.314 kJ/kmol.K); λ es el calor latente de fusión para el agua (333.64 kJ/kg) y X_i y M_i son las fracciones y pesos moleculares, respectivamente, de los componentes importantes en la predicción de la T_f , los cuales pueden ser: Agua, proteínas, lípidos, monosacáridos, disacáridos, fibra, minerales (Na, K, Mg, Ca, P, Cl) y ácidos y bases (Ascórbico, Cítrico (iso), Málico, Oxálico, Nitratos).

Calcularon el agua no congelable o ligada (X_b), definida como agua que no se congela a -40°C , utilizando el modelo empírico propuesto por Schwartzberg (1976) (Ec. 6):

$$X_b = a X_s \quad (6)$$

Donde a es un coeficiente experimental definido para tipos específicos de productos alimenticios y X_s es la suma de fracciones másicas de: proteínas, carbohidratos, lípidos, cenizas y fibras. Según Schwartzberg (1976), el valor de a para verduras está entre 0.25 y 0.18.

e. DETERMINACIÓN A TRAVÉS DE CURVAS DE CONGELAMIENTO

Rahman *et al.* (2002) presentaron detalles del método de curva de enfriamiento para medir la temperatura inicial de congelación. En la Figura 4 se muestra el diagrama experimental donde utilizaron sacarosa a 40 °Brix para probar el método, donde utilizaron un cilindro de acero inoxidable aislado en la parte superior, inferior y lateral con espuma de poliestireno como se muestra en la figura (donde uno de sus objetivos era medir el impacto del aislamiento en la medición), manteniendo tres cuartos llenos de su capacidad para todos los experimentos. El termómetro se calibró midiendo el punto de congelación del agua destilada y tenía una precisión de 0.1 °C.




Figura 4: Diagrama esquemático de una configuración experimental para solución de azúcar y gel de almidón. T: Bloque aislante superior, B: Bloque aislante inferior, S: Bloque aislante lateral, R: Sonda de termopar, H: Soporte de muestra de acero inoxidable, D: Registrador de temperatura, C: Congelador de cofre

FUENTE: Rahman et al. (2002)

En la Figura 5 (a), presentada por Rahman *et al.* (2002), se ilustra la curva de enfriamiento de la sacarosa. En el punto (a), se aprecia el fenómeno de sobre enfriamiento, mientras que la temperatura inicial de congelación se identificó en el punto (b), registrando -4.8°C para una solución de sacarosa con una concentración de 40 °Brix. Este dato coincide de manera cercana con el obtenido por Chen y Nagy (1987), quienes reportaron -4.7°C . Además, en la Figura 5 (b), se observa nuevamente la temperatura inicial de congelación en la parte plana de la pendiente (marcada como punto b). A medida que la formación de hielo disminuye, la pendiente comienza a aumentar hasta alcanzar su valor máximo.

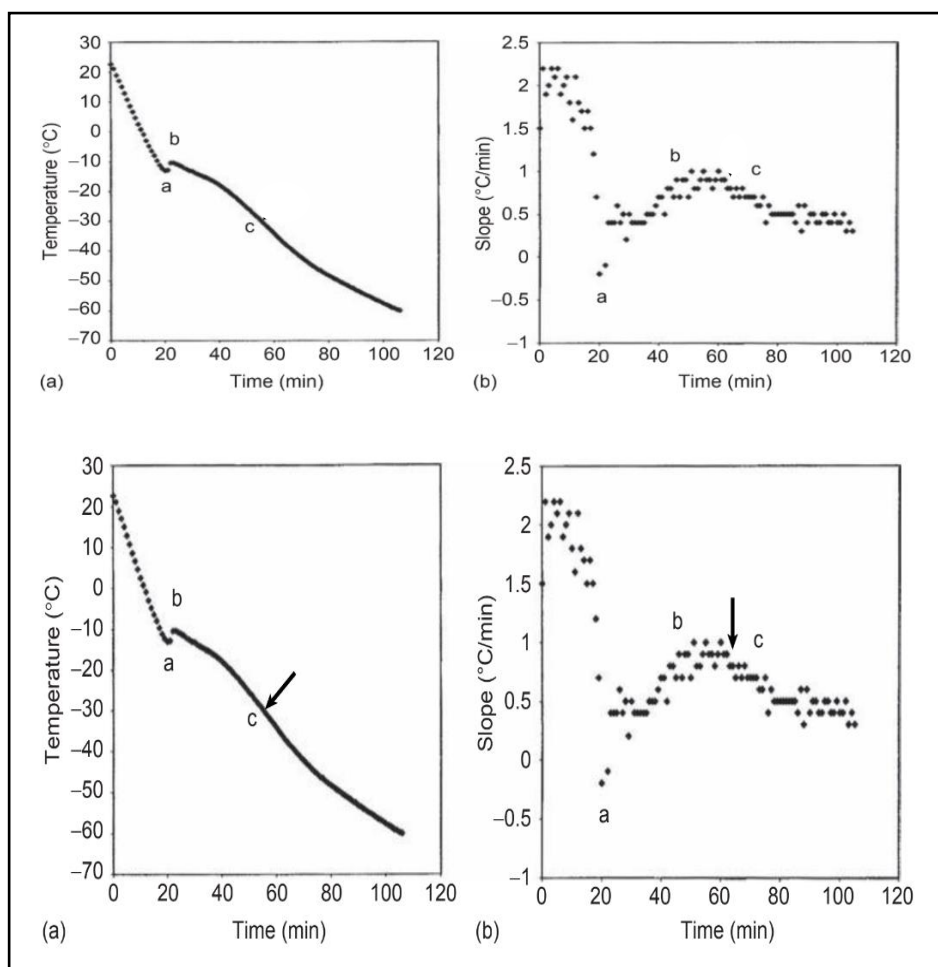


Figura 5: Curva de enfriamiento del jarabe de sacarosa 40 °Brix que muestra el sobre enfriamiento (punto a), el punto de congelación inicial (punto b) y el punto final de congelación (punto c)

FUENTE: Rahman et al. (2002)

2.2. RAÍCES Y TUBÉRCULOS ANDINOS

La región andina es famosa por su rica diversidad de raíces y tubérculos, los cuales representan alimentos fundamentales en la dieta de la población rural debido a su elevado contenido de carbohidratos, especialmente almidón. Estas plantas se destacan por su amplia gama de formas, sabores y métodos de preparación, desempeñando un papel vital en la dieta local. Algunos ejemplos notables de raíces y tubérculos andinos incluyen la mashua (*Tropaeolum tuberosum*), el olluco (*Ullucus tuberosus*), la arracacha (*Arracacia xanthorriza*), la maca (*Lepidium meyenii*) y el yacón (*Smallanthus sonchifolius*) (Valcárcel-Yamani et al., 2013).

2.2.1. MASHUA

a. GENERALIDADES

De acuerdo con Grau *et al.* (2003), la mashua (*Tropaeolum tuberosum*) es un cultivo andino de gran importancia que se sitúa como el cuarto más destacado en la región de los Andes, siguiendo a la papa, oca y olluco. Esta planta se encuentra ampliamente distribuida entre altitudes que oscilan entre los 2800 y 4000 metros sobre el nivel del mar en países como Bolivia, Colombia, Ecuador y Perú, donde crece tanto en estado silvestre como cultivada. Los tubérculos de mashua constituyen la fuente principal de alimentación para alrededor de 9 millones de personas que viven a lo largo de toda la cordillera de los Andes. La mashua se destaca por su alto rendimiento, su resistencia a las heladas y su facilidad de cultivo, lo que la convierte en el cultivo andino más productivo y adaptado a las condiciones de la región.

En diferentes regiones del Perú, como Ayacucho, Cajamarca, Huancayo, Cusco y Puno, se cultiva a una altitud superior a los 3000 metros sobre el nivel del mar (Grau *et al.*, 2003). Dependiendo del país donde se cultive, esta planta es conocida con diferentes nombres, como se muestra en la Tabla 2.

Tabla 2: Nombre según la región de la *Tropaeolum tuberosum*

Nombre	País
Cubio	Colombia
Mashua o Mashwa	Colombia, Ecuador, Perú y Bolivia
Añu	Perú y Bolivia
Mishwa	Perú y Bolivia
Isaño	Perú, Bolivia y Argentina
Apiña mama	Bolivia

FUENTE: Grau *et al.* (2003)

De acuerdo con Quispe (2017), en el idioma quechua, los clones y/o ecotipos de la mashua se distinguen por el color de sus tubérculos. Por ejemplo, Occe añu se refiere al color plumizo, Yana añu al negruzco, Puca añu al rojizo, Murua ñu al morado, Chhecce añu al gris, Zapallo añu al amarillo y Yurac añu al blanco.

b. TAXONOMÍA

Descripción de la clasificación taxonómica del cultivo de mashua (Tabla 3)

Tabla 3: Clasificación taxonómica de la mashua (*Tropaeolum Tuberosum*)

Taxón	Nombre
Reino	Plantae
Filo	Angiospermae
Clase	Dicotyledoneae
Orden	Brassicales
Familia	Tropaeolaceae
Género	<i>Tropaeolum</i>
Especie	<i>T. tuberosum</i> Ruiz & Pavón

FUENTE: Guerra (2014)

c. COMPOSICIÓN

En la Tabla 4 se presenta los valores de diversos componentes en la mashua según diferentes estudios. Se observa que la humedad varía desde un mínimo de 79.20g (Cuya, 2009) hasta un máximo de 93.80g (Grau *et al.*, 2003), mientras que las proteínas oscilan entre 0.84g (Valcárcel-Yamani *et al.*, 2013) y 2.70g (Grau *et al.*, 2003). En términos de grasa, los valores fluctúan entre 0.08g (Valcárcel-Yamani *et al.*, 2013) y 0.70g (Reyes *et al.*, 2009). Los carbohidratos totales presentan una variación desde 6.32g (Valcárcel-Yamani *et al.*, 2013)

hasta 13.10g (Grau *et al.*, 2003), y la fibra cruda va desde 0.50g (Valcárcel-Yamani *et al.*, 2013) hasta 1.50g (Cuya, 2009). En cuanto a ceniza, los valores se sitúan entre 0.47g (Valcárcel-Yamani *et al.*, 2013) y 1.10g (Grau *et al.*, 2003).

Los contenidos de calcio y fósforo van desde 7.00mg y 12.00mg respectivamente (Reyes *et al.*, 2009) hasta 42.00mg para ambos elementos (Salazar, 2014). En el caso del hierro, la variación es de 1.00mg (Reyes *et al.*, 2009) a 1.20mg (Salazar, 2014). Las vitaminas también muestran variaciones, con valores de 0.06 mg a 0.10 mg para tiamina, 0.08 mg a 0.12 mg para riboflavina y 0.60 mg a 0.67 mg para niacina. Por último, la vitamina C varía desde 67.00 mg (Salazar, 2014) hasta 77.50 mg (Reyes *et al.*, 2009 y Grau *et al.*, 2003). Estas variaciones en los componentes nutricionales de la mashua pueden tener implicaciones significativas para su valor como alimento en diferentes contextos y regiones.

La mashua contiene isotiocianatos que se encuentran en forma de glucosinolatos (Kjær *et al.*, 1978). Estos compuestos son similares a los presentes en otras crucíferas y también se conocen como aceites de mostaza. Los isotiocianatos son reconocidos por sus propiedades antibióticas, insecticidas, nematocidas y diuréticas, lo que respalda su amplio uso en la medicina popular andina (Jhons *et al.*, 1982). El sabor picante característico de la mashua se debe al isotiocianato de p-metoxibencilo, encontrando valores de 20 mg/100 g en la mashua cruda.

En la Tabla 5 se presenta las propiedades fisicoquímicas de la mashua según distintos estudios. En cuanto al pH, se observa una ligera variación, desde 5.5 (Ortiz, 2015) hasta 6.22 (Fernández y Martínez, 2015), mientras que no se proporciona información específica en el estudio de Samaniego (2010). En cuanto a la acidez, se registra un valor de 0.09 (% de ácido cítrico) según Ortiz (2015). Por último, los sólidos solubles presentan una variación desde 6.61°Brix (Samaniego, 2010) hasta 10.10°Brix (Fernández y Martínez, 2015), con un valor intermedio de 8°Brix proporcionado por Ortiz (2015). Estas diferencias en las propiedades de la mashua pueden influir en su sabor y versatilidad culinaria, lo que resalta la importancia de comprender y considerar estas variaciones en su cultivo y consumo.

Tabla 4: Composición química de la mashua fresca en base húmeda

Componente	Unidades	Espín <i>et al.</i> (2001)	Reyes <i>et al.</i> (2009)	Valcárcel-Yamani <i>et al.</i> (2013)	Salazar (2014)	Cuya (2009)	Grau <i>et al.</i> (2003)
Humedad	g	88.70	87.40	90.84	86.00	79.20	93.80
Proteínas	g	1.03	1.50	0.84	1.60	1.10	2.70
Grasa	g	0.52	0.70	0.08	0.60	0.50	0.90
Carbohidratos totales	g	8.52	9.80	6.32	11.60	7.00	13.10
Fibra cruda	g	0.67	0.90	1.43	0.80	0.50	1.50
Ceniza	g	0.54	0.60	0.47	0.80	0.60	1.10
Calcio	mg	-	12.00	-	7.00	-	-
Fósforo	mg	-	29.00	-	42.00	-	-
Hierro	mg	-	1.00	-	1.20	-	-
Tiamina	mg	-	0.10	-	0.06	-	-
Riboflavina	mg	-	0.12	-	0.08	-	-
Niacina	mg	-	0.67	-	0.60	-	-
Vitamina C	mg	77.37	77.50	-	67.00	-	77.50

Tabla 5: Propiedades fisicoquímicas de la mashua fresca

Propiedades	Samaniego (2010)	Fernández y Martínez (2015)	Ortiz (2015)
pH	5.56	6.22	5.50
Acidez (% de ácido cítrico)	-	-	0.09
Sólidos solubles (°Brix)	6.61	10.10	8.00

2.2.2. OLLUCO

a. GENERALIDADES

El olluco (*Ullucus tuberosus*), perteneciente a la familia Basellaceae, es un tubérculo cultivado en las elevadas altitudes de los Andes sudamericanos. Se destaca como el segundo tubérculo más relevante en la región, solo superado por la papa. Dependiendo de la zona geográfica, puede ser conocido bajo diversos nombres como melloco, olluco, chugua o ruba. Un rasgo distintivo del olluco radica en su piel, la cual presenta una amplia gama de colores, que van desde el amarillo hasta el púrpura, gracias a la presencia de betalainas, pigmentos naturales (Chuquilín *et al.*, 2020).

b. TAXONOMÍA

Cronquist (1981), clasifican taxonómicamente al olluco de la siguiente manera:

Tabla 6: Clasificación taxonómica del olluco (*Ullucus Tuberosus*)

Taxón	Nombre
Reino	Plantae
Clase	Dicotiledónea
Orden	Centrospermas
Familia	Basellaceae
Género	<i>Ullucus</i>
Especie	<i>Ullucus Tuberosus</i>

FUENTE: Cronquist (1981)

c. COMPOSICIÓN

La Tabla 7 proporcionada presenta los valores de diferentes componentes nutricionales en las variedades de papa Puka Lisa y Papa Lisa según el estudio de Márquez (2019), así como comparaciones con los valores de referencia de Leterme *et al.* (2006) y García (2021) para otra variedad no especificada.

En términos de humedad, ambas variedades de papa muestran valores cercanos, con Puka Lisa ligeramente más húmeda que Papa Lisa, con un máximo de 85.95g y 85.63g respectivamente. En cuanto a proteínas, Puka Lisa contiene 1.17g mientras que Papa Lisa contiene 1.04g, siendo Puka Lisa la variedad con el contenido de proteínas más alto. En lo que respecta a grasas, ambas variedades muestran cantidades mínimas, con Puka Lisa ligeramente superior con 0.15g. En términos de carbohidratos totales, Papa Lisa tiene un valor máximo de 12.42g, mientras que Puka Lisa muestra un valor máximo de 11.87g. La fibra cruda y la ceniza muestran valores similares en ambas variedades, con ligeras variaciones.

Tabla 7: Composición química del olluco en base húmeda

Componente	Unidades	Puka Lisa Márquez (2019)	Papa Lisa Márquez (2019)	Leterme <i>et al.</i> (2006)	Lescano (1994)	García (2021)
Humedad	g	85.95	85.63	-	83.4*	81.95
Proteína	g	1.17	1.04	-	10.01*	0.24
Grasa	g	0.15	0.12	-	1.24*	0.072
Carbohidratos totales	g	11.87	12.42	-	8.12*	17.24
Fibra cruda	g	0.90	0.85	-	2.63*	0.03
Ceniza	g	0.86	0.79	-	5.93*	0.47
Calcio	mg	-	-	8.00	0.02*	-
Fósforo	mg	-	-	38.00	0.263*	-
Potasio	mg	-	-	247.00	2.48*	-
Magnesio	mg	-	-	11.00	0.107*	-
Sodio	mg	-	-	1.00	0.03*	-
Cloro	mg	-	-	2.00	-	-
Azufre	mg	-	-	13.00	-	-
Vitamina C	mg	-	-	-	26.03	15.62

(*) Determinado en base seca.

En cuanto a los micronutrientes, las variedades muestran diferencias significativas. Por ejemplo, en términos de calcio, se observa una discrepancia notable entre los estudios de Márquez (2019) y Leterme *et al.* (2006). Similarmente, para fósforo, potasio, magnesio, sodio, cloro y azufre, los valores presentan diferencias marcadas entre los estudios. Finalmente, en cuanto a vitamina C, se observa que García (2021) reporta un valor de 15.62mg para una variedad no especificada.

En términos de contenido proteico varía entre un 10.8 % y un 15.7 % en base seca, que son valores cercanos a lo reportado por Lescano (1994) (10.01 %). El olluco no es una buena fuente de proteínas, en cuanto en aminoácidos esenciales, es deficiente en leucina, triptófano y treonina (King y Gershoff, 1987).

La Tabla 8 presenta diversas propiedades fisicoquímicas del olluco según los estudios de Pacheco (2014), Calderón y Peceros (2023), García (2021) y Yavar (2016).

En lo que respecta al pH, se observan variaciones entre las diferentes fuentes. Pacheco (2014) reporta un pH de 6.18, Calderón y Peceros (2023) muestran un valor de 5.74, García (2021) obtiene un pH de 3.95, y Yavar (2016) reporta un pH de 4.07.

En cuanto a la acidez expresada como porcentaje de ácido sulfúrico, Calderón y Peceros (2023) muestran un valor de 0.27% en olluco deshidratado. Los demás estudios no proporcionan información sobre este parámetro.

En el caso de los sólidos solubles medidos en °Brix, Pacheco (2014) indica un valor de 4.3. Los demás estudios no presentan datos disponibles para esta propiedad en relación con el olluco.

Tabla 8: Propiedades fisicoquímicas del olluco

Propiedades	Pacheco (2014)	Calderón y Peceros (2023)	García (2021)	Yavar (2016)
pH	6.18	5.74*	3.95	4.07
Acidez (% de ácido sulfúrico)	-	0.27*	-	-
Sólidos solubles (°Brix)	4.30	-	-	-

(*) Olluco deshidratado.

2.2.3. MACA

a. GENERALIDADES

Sifuentes *et al.* (2015) destacan la notable capacidad de la maca para resistir condiciones climáticas adversas, incluyendo granizadas, heladas y sequías prolongadas, lo que permite su cultivo en altitudes que oscilan entre los 3800 y 4500 metros sobre el nivel del mar. Esta planta, una herbácea anual perteneciente a la familia Brassicaceae, es originaria de los Andes centrales y constituye la única especie registrada del género *Lepidium* que presenta un órgano de almacenamiento subterráneo. Esta característica le confiere una fuerte adaptación al clima riguroso de la meseta andina central de alta altitud (Esparza *et al.*, 2015).

Canales *et al.* (2000) y Dini *et al.* (1994) señalan que, en las últimas dos décadas, la maca ha cobrado relevancia debido a los informes sobre sus notables propiedades medicinales, lo que la posiciona como un candidato prometedor en el mercado de los nutraceuticos. La maca exhibe tres fenotipos principales, los cuales se distinguen por el color del hipocótilo y el tallo: rojo, amarillo y negro. Los reportes publicados sugieren que las diferencias en la composición química de estos fenotipos están relacionadas con los efectos biológicos específicos o los objetivos médicos para los cuales se pueden utilizar. Por ejemplo, la maca negra se emplea para estimular la producción de esperma, mientras que la maca roja se muestra más efectiva en el tratamiento de la hiperplasia prostática benigna (Gonzales *et al.*, 2006).

b. TAXONOMÍA

Aliaga (2004) clasifica a la maca (*Lepidium meyenii*) de la siguiente manera:

Tabla 9: Clasificación taxonómica de la maca (*Lepidium meyenii*)

Taxón	Nombre
División	Magonoliophyta
Clase	Magnoliopsida o Dicotiledonea
Sub clase	Dilleniidae
Orden	Capparales
Familia	Brassicaceae o Cruciferae
Tribu	Lepidieae
Especie	<i>Lepidium meyenii</i> .

FUENTE: Aliaga (2004)

c. COMPOSICIÓN

La raíz de maca, según Dini *et al.* (1994) y Wang *et al.* (2007), presenta una composición rica en aminoácidos, comprendiendo entre 18 y 19, de los cuales 7 son esenciales. Es importante destacar que el contenido de aminoácidos es más elevado en comparación con las papas y zanahorias. En cuanto a los ácidos grasos, se observa que los insaturados, como el linoleico y oleico, representan entre el 52.7% y el 60.3% del total de ácidos grasos.

En términos de contenido mineral en base seca, García *et al.* (2009) señala que se destacan 247 mg de calcio, 183 mg de fósforo y 14.7 mg de hierro. Por otro lado, según el estudio de Reyes *et al.* (2017) basado en contenido en base húmeda, el hierro se presenta en mayor cantidad, con 49.9 mg, seguido del calcio con 37 mg. En relación con la composición proximal que se presenta en la Tabla 10, la maca contiene un 3.5% de proteínas, 1% de grasas y 13.2% de carbohidratos totales, con un contenido de humedad del 79.8%. Sin embargo, no se especifica el contenido de fibra cruda y algunos minerales como potasio, magnesio y sodio, y otros componentes como azufre no fueron mencionados en los estudios citados.

Tabla 10: Composición química de la maca fresca

Componente	Unidades	Contenido
Humedad	g	79.80
Proteína	g	3.50
Grasa	g	1.00
Carbohidratos totales	g	13.20
Fibra cruda	g	-
Ceniza	g	2.50
Calcio	mg	37.00
Fósforo	mg	0.00
Potasio	mg	-
Magnesio	mg	-
Sodio	mg	-
Hierro	mg	49.90
Azufre	mg	-
Vitamina C	mg	2.10

FUENTE: Reyes *et al.* (2017)

En la Tabla 11 se aprecia las propiedades fisicoquímicas de la maca, según los estudios de Flores y León (2006), Bendezú (1992) y Ponce (1999). En términos de pH, se registran valores similares, oscilando alrededor de 5.5. La acidez, medida en porcentaje de ácido sulfúrico, también presenta similitudes, situándose en 0.26. Sin embargo, en lo que respecta a sólidos solubles, solo se dispone de datos en el estudio de Flores y León, que indica un valor de 13°Brix para la maca fresca.

Tabla 11: Propiedades fisicoquímicas de la maca fresca

Propiedades	Flores y León (2006)	Bendezú (1992)	Ponce (1999)
pH	5.53	5.50	5.53
Acidez (% de ácido sulfúrico)	0.26	0.26	0.26
Sólidos solubles (°Brix)	13.00	-	-

2.2.4. ARRACACHA

a. GENERALIDADES

La arracacha (*Arracacia xanthorrhiza*) es la única umbelífera doméstica en América del Sur y su distribución principal se encuentra en este continente. Se propaga a través de métodos vegetativos y se caracteriza como una planta perenne. El estudio de las poblaciones silvestres de arracacha es crucial para comprender el origen de la agricultura en esta región, así como las razones que explican la propagación vegetativa de los cultivos sudamericanos, a diferencia de la agricultura basada en semillas en el Viejo Mundo (Herman y Heller, 1997).

Hermann y Heller (1997) señalan diversas razones que respaldan la consideración de la arracacha como uno de los cultivos más prometedores entre las raíces y tubérculos andinos. Además de su versatilidad culinaria, esta raíz carece de sustancias indeseables que limitan su aceptación, como sucede con la oca (con oxalatos), el ulluco (con mucílagos), la mashua (con isotiocianatos) y la mauka (con principios astringentes).

Por otro lado, Millán (2001) destaca que la arracacha se caracteriza por su amplia diversidad morfológica y se clasifica como un alimento energético debido a su composición proximal. Sobresale por su contenido de carbohidratos (almidones y azúcares totales) en comparación con otros nutrientes. Asimismo, constituye una buena fuente de vitamina A y niacina, y contiene cantidades significativas de minerales como calcio, fósforo y hierro. Los nombres

comunes de la arracacha varían según la región o el país donde se cultiva, siendo conocida como arracacha o racacha en Colombia, Venezuela, Perú, Bolivia y Centroamérica. En Venezuela se la conoce como apio criollo, en Ecuador y el norte de Perú como zanahoria blanca, y en el sur de Perú y Bolivia como virraca (NRC, 1989). Además, Millán (2001) menciona que la arracacha presenta diferentes colores en su piel, que van desde el amarillo claro, amarillo, rosado, hasta el blanco, y en su médula, desde el amarillo oscuro, amarillo, blanco, crema, hasta el morado oscuro.

b. TAXONOMÍA

La clasificación taxonómica de la arracacha según Soukup (1986) es la siguiente:

Tabla 12: Clasificación taxonómica de la arracacha (*Arracacia xanthorrhiza*)

Taxón	Nombre
División	Angiospermae
Clase	Dicotyledoneae
Sub clase	Archiclamydeae
Orden	Umbelliferae
Sub Orden	Umbelífera
Familia	Umbelliferae
Sub. Familia	Apioideae
Género	<i>Arracacia</i>
Especie	<i>Arracacia Xanthorrhiza</i>

FUENTE: Soukup (1986)

c. COMPOSICIÓN

La Tabla 13 proporciona el perfil de la arracacha de diferentes variedades y países. En términos de humedad, la arracacha amarilla presenta un contenido de 71.34g, mientras que la blanca y morada tienen contenidos de 73.63g y 73.86g respectivamente. Esto indica que la arracacha morada tiene el contenido de agua más alto entre las tres variedades.

En cuanto a proteínas, la arracacha amarilla tiene el contenido más alto con 0.76g, seguida por la blanca con 0.61g y la morada con 0.55g. Esto sugiere que la variedad amarilla tiene un mayor contenido de proteínas.

Se aprecia que en grasas, las tres variedades presentan valores muy similares, alrededor de 0.24g a 0.28g, sin diferencias significativas entre ellas.

Respecto a carbohidratos totales, la arracacha amarilla tiene el contenido más alto con 26.95g, seguida por la blanca con 24.78g y la morada con 24.76g. Esto indica que la variedad amarilla tiene un mayor contenido de carbohidratos.

En términos de minerales, la arracacha amarilla tiene el contenido más alto de calcio con 34.33mg, seguida por la morada con 32.77mg y la blanca con 30.67mg. En cuanto al fósforo, la amarilla también tiene el contenido más alto con 57.56mg, seguida por la blanca con 56.90mg y la morada con 46.00mg.

En cuanto a otros minerales como potasio, magnesio, zinc y hierro, no se observan diferencias significativas entre las tres variedades.

En términos de vitamina C, la blanca tiene el contenido más alto con 26.46mg, seguida por la amarilla con 24.78mg y la morada con 19.80mg. Esto indica que la blanca tiene un mayor contenido de vitamina C entre las tres variedades.

Rodas (1992) determinó la composición proximal de la arracacha en diferentes países y regiones de América (Latina). En términos de humedad, la variedad de arracacha de Perú

tiene el contenido más alto, con un 75.10g, seguida por la de América Latina con 74.4g, Ecuador con 71.00g y Guatemala con 73.00g.

En lo que respecta a proteínas, Guatemala y América Latina tienen los contenidos más bajos, con 0.08g, mientras que Ecuador y Perú muestran niveles más altos, con 1.00g y 0.70g respectivamente. Para el contenido de grasa, todas las variedades tienen valores muy bajos, oscilando entre 0.02g y 0.10g, sin diferencias notables.

En términos de carbohidratos totales, Ecuador tiene el contenido más alto con 26.90g, seguido por América Latina con 24.40g, Guatemala con 24.90g y Perú con 23.00g. En cuanto a fibra cruda, se observan diferencias significativas, siendo América Latina la variedad con el contenido más alto (1.00g), seguida por Perú (1.10g), Ecuador (0.60g) y Guatemala (0.60g).

Para los minerales como calcio, fósforo y hierro, Ecuador y Guatemala muestran valores más altos que América Latina y Perú.

En cuanto a vitamina C, Ecuador tiene el contenido más alto con 31.00mg, seguido por Guatemala con 28.00mg, y América Latina y Perú con 23.00mg cada uno. Estos resultados sugieren variaciones notables en la composición nutricional de la arracacha entre los diferentes países evaluados.

En la Tabla 14 se presenta las propiedades fisicoquímicas de la arracacha. Según los estudios de Pacheco *et al.* (2020) y Rincón *et al.* (2021), muestran algunas diferencias notables:

En términos de pH, Pacheco *et al.* (2020) reportan un valor de 6.8, mientras que Rincón *et al.* (2021) observan un pH ligeramente más bajo, de 6.2.

La acidez, expresada como porcentaje de ácido málico, es nula en el estudio de Pacheco *et al.* (2020), pero Rincón *et al.* (2021) registran un valor de 0.13.

Tabla 13: Composición química de la arracacha

Componentes	Unidades	A. Amarilla Palacios (2011)	A. Blanca Palacios (2011)	A. morada Palacios (2011)	A. amarilla ICBF (1992)	A. blanca ICBF (1992)	A. morada ICBF (1992)	Ecuador Rodas (1992)	Guatemala Rodas (1992)	América Latina Rodas (1992)	Perú Rodas (1992)
Humedad	g	71.34	73.63	73.86	72.80	74.50	71.90	71.00	73	74.4	75.10
Proteína	g	0.76	0.61	0.55	0.90	0.90	1.10	1.00	0.08	0.08	0.70
Grasa	g	0.28	0.24	0.24	0.10	0.10	0.10	0.10	0.02	0.02	0.02
Carbohidratos totales	g	26.95	24.78	24.76	24.00	22.30	24.90	26.90	24.90	24.40	23.00
Fibra cruda	g	0.95	0.89	0.85	1.00	0.70	0.80	0.60	0.60	1.00	1.10
Ceniza	g	0.67	0.74	0.59	1.20	1.40	1.20	0.90	1.10	1.20	1.00
Calcio	mg	34.33	30.67	32.77	26.00	23.00	24.00	19.00	29.00	26.00	28.00
Fósforo	mg	57.56	56.90	46.00	60.00	40.00	65.00	55.00	58.00	52.00	52.00
Potasio	mg	2.40	2.35	2.28	-	-	-	-	-	-	-
Magnesio	mg	69.98	68.94	55.97	-	-	-	-	-	-	-
Zinc	mg	5.98	5.20	5.07	-	-	-	-	-	-	-
Hierro	mg	11.96	9.52	7.91	0.70	1.10	0.70	0.90	1.20	0.09	0.09
Vitamina C	mg	24.78	26.46	19.80	20.00	15.00	20.00	31.00	28.00	23.00	23.00

En cuanto a los sólidos solubles, Rincón *et al.* (2021) encuentran un contenido más alto de 6.5 °Brix, en comparación con los 4.5 °Brix reportados por Pacheco *et al.* (2020).

Estos resultados indican que existen variaciones en las propiedades fisicoquímicas de la arracacha dependiendo del estudio y las condiciones específicas de cultivo y análisis.

Tabla 14: Propiedades fisicoquímicas de la arracacha

Propiedades	Pacheco <i>et al.</i> (2020)	Rincón <i>et al.</i> (2021)
pH	6.80	6.20
Acidez (% de ácido málico)	-	0.13
Sólidos solubles (°Brix)	4.50	6.50

2.2.5. YACÓN

a. GENERALIDADES

El yacón, también conocido como *Smallanthus sonchifolus*, es una vigorosa planta herbácea que se encuentra en la región de los Andes. Pertenece a la familia Compositae o Asteraceae y produce raíces tuberosas que se asemejan en apariencia a las batatas, pero con un sabor mucho más dulce y una textura crujiente. Estas plantas son excepcionalmente resistentes y pueden prosperar tanto en climas cálidos como fríos, lo que las hace versátiles en términos de cultivo. El yacón se encuentra comúnmente en valles templados y cálidos de los Andes, pero también se ha observado creciendo a altitudes de hasta 3200 metros sobre el nivel del mar (Zardini, 1991).

En la actualidad, se ha despertado un creciente interés en los alimentos nutraceuticos, los cuales van más allá de su valor nutricional básico para ofrecer beneficios fisiológicos (ANVISA, 2005). Entre estos alimentos, se encuentran los prebióticos como los

fructooligosacáridos (FOS) y la inulina, los cuales han demostrado mejorar funciones fisiológicas específicas. Estos compuestos promueven una respuesta inmune más efectiva y fortalecen la resistencia contra patógenos, como se ha mencionado en estudios anteriores (Vos *et al.*, 2007).

b. TAXONOMÍA

La clasificación taxonómica del yacón según Seminario *et al.* (2003) es la siguiente:

Tabla 15: Clasificación Taxonómica del yacón (*Smallanthus sonchifolius*)

Taxón	Nombre
Reino	Plantae
División	Magnoliophyta
Clase	Magnoliopsida
Orden	Asterales
Familia	Asteraceae
Subfamilia	Asteroideae
Tribu	<i>Millerieae smallanthus.</i>
Género	<i>S. sonchifolius</i>
Especie	<i>S. sonchifolius</i> (Poepp & Endl) H. Robinson

FUENTE: Seminario *et al.* (2003)

c. COMPOSICIÓN

La Tabla 16 presenta la composición química del yacón según varios estudios. Se observa que el contenido de humedad varía ampliamente, oscilando entre el 70% y el 93% según los análisis de Grau y Rea (1997), mientras que Manrique *et al.* (2004) y Hermann *et al.* (1999)

reportan valores entre el 85% y el 90%. En términos de proteínas, se encuentran en niveles relativamente bajos, con valores que van desde 0.1 a 0.5 g según Manrique *et al.* (2004). En cambio, Hermann *et al.* (1999) reporta un rango mayor, de 2.7 a 4.9 g.

En cuanto a las grasas, Grau y Rea (1997) y Manrique *et al.* (2004) indican que están presentes en cantidades muy bajas, entre 0.1 y 0.3 g. La ceniza, que representa la fracción mineral, también varía significativamente, con valores que oscilan entre 0.3 y 2 g según los estudios de Grau y Rea (1997) y Reyes *et al.* (2017).

Es importante resaltar que los carbohidratos totales son uno de los componentes principales del yacón. Mientras que Lachman *et al.* (2003) informa de un contenido de 13.8 g, Reyes *et al.* (2017) y Grau y Rea (1997) sugieren que este valor puede ser incluso mayor, llegando a 12.5 y hasta 13 g, respectivamente.

En lo que respecta a los micronutrientes, el yacón es una fuente moderada de minerales como fósforo y calcio, con contenidos que varían según los estudios. Por ejemplo, Hermann *et al.* (1999) informa de niveles de fósforo entre 182 y 309 mg, mientras que el calcio se encuentra en un rango de 6 a 131 mg según Manrique *et al.* (2004) y Grau y Rea (1997).

En términos de potasio, este mineral muestra una variabilidad importante, con contenidos que oscilan entre 185 y 295 mg según Manrique *et al.* (2004), y valores aún más elevados de 180 a 290 mg según Hermann *et al.* (1999) y Lachman *et al.* (2003).

Otros componentes como el hierro y el ácido ascórbico también se encuentran presentes en el yacón, aunque en menor medida. Por ejemplo, el hierro es reportado en cantidades de 0.3 mg según Grau y Rea (1997), mientras que el ácido ascórbico alcanza los 13.1 mg según Reyes *et al.* (2017).

La Tabla 17 proporciona información detallada sobre la composición de carbohidratos del yacón, según varios estudios. Se observa que la fructosa es el principal carbohidrato presente, con valores que varían significativamente. Mientras que Moscatto *et al.* (2006)

Tabla 16: Composición química del yacón

Componentes	Unidades	Grau y Rea (1997)	Manrique <i>et al.</i> (2004)	Hermann <i>et al.</i> (1999)	Lachman <i>et al.</i> (2003)	Reyes <i>et al.</i> (2017)
Humedad	g	70.00 – 93.00	85.00-90.00	-	81.3	86.60
Proteína	g	0.40 – 2.00	0.10 - 0.50	2.70 – 4.90	1.0	0.30
Grasa	g	0.10 – 0.30	-	0.11– 0.46	0.10	0.30
Ceniza	g	0.30 – 2.00	-	4.30 – 6.00	1.10	0.30
Fibra cruda	g	0.30 – 1.70	-	3.10 – 4.10	0.90	-
Carbohidratos totales	g	-	-	9.00 – 13.00	13.80	12.50
Fósforo	mg	21.00		182.00 – 309.00	34.00	21.00
Calcio	mg	23.00	6.00 – 13.00	56.00 – 131.00	12.00	23.00
Potasio	mg	-	185.00 – 295.00	180.00 – 290.00	334.00	-
Hierro	mg	0.30	-	-	-	-
Ácido ascórbico	mg	13.00	-	-	-	13.10

reporta un contenido de 4.13 g, Lobo *et al.* (2007) y Habib *et al.* (2011) indican valores mucho más elevados, alcanzando 13.51 g y 26 g respectivamente.

La Tabla 17 proporciona información detallada sobre la composición de carbohidratos del yacón, según varios estudios. Se observa que la fructosa es el principal carbohidrato presente, con valores que varían significativamente. Mientras que Moscatto *et al.* (2006) reporta un contenido de 4.13 g, Lobo *et al.* (2007) y Habib *et al.* (2011) indican valores mucho más elevados, alcanzando 13.51 g y 26 g respectivamente.

En el caso de la glucosa, los valores también muestran variaciones entre los estudios. Moscatto *et al.* (2006) informa de 1.96 g, mientras que Lobo *et al.* (2007) y Choque Delgado *et al.* (2010) registran contenidos de 8.97 g y 10.01 g respectivamente.

Por otro lado, la sacarosa también está presente en cantidades apreciables, con valores que oscilan entre 3.25 g y 13.42 g según los diferentes estudios.

Los fructooligosacáridos (FOS) y fructanos también son componentes significativos del yacón. Habib *et al.* (2011) y Choque Delgado *et al.* (2010) reportan contenidos de 52% y 34.31% respectivamente.

En cuanto a los oligosacáridos específicos como la 1-kestosa (GF2), nystosa (GF3) y fructofuranosil-nystosa (GF4), se observan variaciones notables. Por ejemplo, Moscatto *et al.* (2006) indica que la 1-kestosa (GF2) tiene un contenido de 8.19 g, mientras que Choque Delgado *et al.* (2010) reporta valores de 13.99 g. En el caso de la nystosa (GF3) y fructofuranosil-nystosa (GF4), Moscatto *et al.* (2006) proporciona valores específicos, mientras que los demás estudios no registran estos componentes.

La Tabla 18 presenta las propiedades fisicoquímicas del yacón según dos estudios. El pH del yacón varía ligeramente entre los estudios de Rojas (2015) y Chirinos (1999), registrando valores de 6.1 y 6.54 respectivamente.

Tabla 17: Composición de carbohidratos del yacón

Carbohidrato	Moscatto <i>et al.</i> (2006)	Lobo <i>et al.</i> (2007)	Habib <i>et al.</i> (2011)	Choque Delgado <i>et al.</i> (2010)
Fructosa	4.13	13.51	26.00	14.10
Glucosa	1.96	8.97	10.01	7.30
Sacarosa	3.25	13.42	10.00	10.50
FOS/fructanos	-	55.33	52.00	34.31
1-kestosa (GF2)	8.19	-	-	13.99
Nystosa (GF3)	5.36	-	-	13.72
Fructofuranosil- nistosa (GF4)	4.03	-	-	6.59

En términos de acidez, se observa que el porcentaje de ácido cítrico en el yacón es un poco más alto según el estudio de Rojas (2015) con un valor de 0.35%, mientras que Chirinos (1999) reporta un valor ligeramente menor de 0.29%.

En cuanto a los sólidos solubles medidos en °Brix, Rojas (2015) obtiene un valor de 13.5, mientras que Chirinos (1999) registra un valor un poco más bajo de 10.3.

Tabla 18: Propiedades fisicoquímicas del yacón

Propiedades	Rojas (2015)	Chirinos (1999)
pH	6.10	6.54
Acidez (% de ácido cítrico)	0.35	0.29
Sólidos solubles (°Brix)	13.50	10.30

2.3. INTELIGENCIA ARTIFICIAL

La inteligencia artificial es una disciplina que se enfoca en la creación de máquinas pensantes utilizando modelos matemáticos inspirados en biología y las neurociencias cognitivas. Su objetivo es desarrollar sistemas capaces de realizar tareas similares a las humanas. La inteligencia artificial es un campo de investigación exploratoria que utiliza diversas metodologías de búsqueda para construir un mapa del espacio de problemas, incluso sin haber tenido contacto directo con ellos (Universidad Complutense de Madrid, 2022). La Figura 6 muestra los diferentes subcampos de la inteligencia artificial.

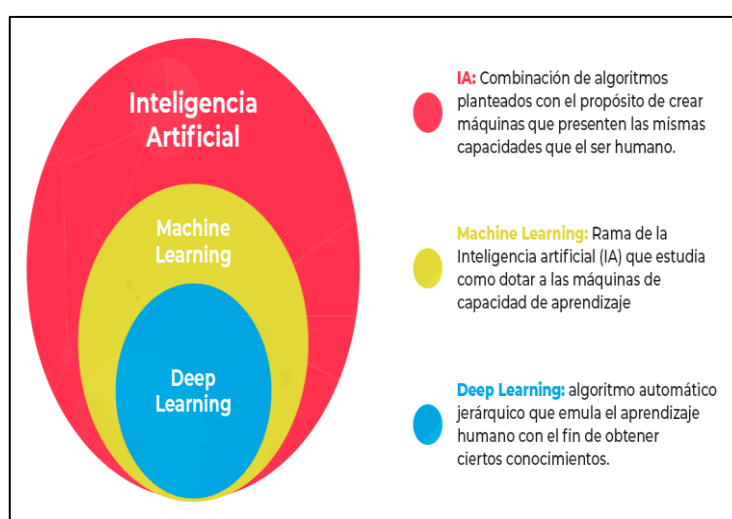


Figura 6: Terminología en el campo de la inteligencia artificial

FUENTE: Universidad Complutense de Madrid (2022)

2.3.1. APRENDIZAJE CONTINUO O *MACHINE LEARNING*

Torres (2018), menciona que el aprendizaje continuo o *machine learning* es una parte específica de la inteligencia artificial que se enfoca en enseñar a las computadoras a aprender y mejorar a partir de los datos, en lugar de ser programadas explícitamente para hacerlo. Los algoritmos son entrenados para identificar patrones y correlaciones en conjuntos de datos extensos y utilizar ese análisis para tomar decisiones y hacer predicciones precisas. A medida que tienen acceso a más datos, las aplicaciones del aprendizaje automática se perfeccionan y se vuelven más precisas con el tiempo.

2.3.2. APRENDIZAJE PROFUNDO O *DEEP LEARNING*

El aprendizaje profundo es un campo del *machine learning* que se engloba a su vez dentro de la inteligencia artificial, a diferencia del aprendizaje continuo, las técnicas de aprendizaje profundo tienen la capacidad de extraer automáticamente las características más relevantes de los datos originales para resolver un problema, además de aprender las transformaciones necesarias en esas características para producir una salida deseada. El perceptrón multicapa, con solo dos capas, se considera el modelo más básico que se puede aproximar funciones de manera universal (Torres, 2018).

Según Torres (2018), las estructuras algorítmicas permiten la creación de modelos compuestos por múltiples capas de procesamiento, que aprenden representaciones de datos con diferentes niveles de abstracción al realizar transformaciones lineales y no lineales a partir de los datos de entrada para generar una salida cercana a la deseada. En la siguiente figura se muestra una representación gráfica simplificada de una red neuronal de aprendizaje profundo.




Figura 7: Red neuronal con 3 capas

FUENTE: Torres (2018)

2.3.3. REDES NEURONALES

Las redes neuronales artificiales (RNA) son modelos matemáticos que buscan imitar el aprendizaje y procesamiento automáticos inspirados en el sistema nervioso. Este sistema de

interconexión de neuronas colabora para generar una respuesta de salida. En inteligencia artificial, se les conoce como redes neuronales, y como cualquier modelo, simplifican el sistema real que intentan simular, tomando sus características principales para resolver tareas específicas (Torres, 2018).

La esencia de las RNA radica en la interconexión de neuronas artificiales organizadas en capas. Las conexiones entre ellas se establecen mediante pesos sinápticos, y la información fluye a través de la red de manera similar a las señales eléctricas en el sistema nervioso biológico. Las neuronas colaboran para procesar información y generar una salida, replicando el funcionamiento sinérgico observado en sistemas biológicos (Torres, 2018).

Como destaca Torres (2018), las RNA simplifican los sistemas que intentan emular, extrayendo las características esenciales relevantes para la tarea específica. Este enfoque simplificado facilita la eficiente aplicación de las RNA en diversas áreas de inteligencia artificial. Además, las RNA tienen la capacidad única de aprender automáticamente durante el entrenamiento, ajustando los pesos sinápticos para mejorar su rendimiento con el tiempo.

a. ELEMENTOS BÁSICOS QUE COMPONEN UNA RED NEURONAL

a.1. CAPAS

Según Acevedo *et al.* (2017) el contexto de las redes neuronales, una "capa" se conceptualiza como una estructura fundamental que organiza y dirige el flujo de información a través del sistema. Se trata de una agrupación de nodos o unidades de procesamiento que comparten conexiones ponderadas, lo que permite la realización de operaciones específicas.

- **Capa de Entrada:** En esta fase, la capa de entrada sirve como interfaz entre el entorno externo y la red neuronal. Cada nodo en esta capa representa una característica o variable de entrada, y la información fluye a través de estas conexiones hacia las capas subsiguientes.
- **Capas Ocultas:** Estas capas actúan como verdaderos motores de procesamiento. Cada nodo en las capas ocultas realiza operaciones matemáticas complejas, utilizando

pesos y funciones de activación para transformar la información recibida de la capa de entrada. La configuración precisa de estas conexiones y funciones define la capacidad de la red para aprender patrones y realizar tareas específicas.

- **Capa de Salida:** La capa de salida presenta los resultados finales de la inferencia o procesamiento realizado por la red. Cada nodo en esta capa representa una salida específica, como una clasificación o predicción. La información procesada se transmite hacia el exterior de la red o, en algunos casos, se conecta a sistemas externos.

a.2. PESOS SINÁPTICOS

Según Matich (2001) En el contexto de las neuronas artificiales en redes neuronales, los pesos sinápticos desempeñan un papel esencial en la capacidad de la red para aprender y adaptarse a patrones específicos. Cada conexión entre neuronas está caracterizada por un peso sináptico, que es un valor numérico asignado a la fuerza o influencia de esa conexión particular. Este concepto se puede analizar desde una perspectiva más técnica.

- **Asignación de Pesos Sinápticos:** En una neurona artificial, cada entrada proveniente de otras neuronas está asociada con un peso sináptico. Este peso se inicializa con valores arbitrarios y se ajusta durante el proceso de entrenamiento de la red. La habilidad de modificar estos pesos constituye la base del aprendizaje en la red neuronal (Matich, 2001).
- **Ajuste de Pesos durante el Entrenamiento:** Durante el entrenamiento, la red ajusta los pesos sinápticos para minimizar la diferencia entre las salidas predichas y las salidas deseadas. Este ajuste se realiza utilizando algoritmos de optimización que buscan encontrar los valores óptimos de los pesos para mejorar el rendimiento de la red en tareas específicas (Matich, 2001).
- **Almacenamiento de Información Relevante:** El peso sináptico no es simplemente un número; es un contenedor de información relevante. A medida que la red se expone a datos de entrada, los pesos sinápticos se ajustan para capturar patrones y características importantes en los datos. En este sentido, la red "aprende" mediante la modificación de estos pesos para representar de manera más precisa la relación entre las entradas y las salidas (Matich, 2001).

- **Multiplicación de Entradas por Pesos:** Durante la fase de propagación hacia adelante, los valores de entrada se multiplican por los pesos sinápticos correspondientes en la neurona. Esta multiplicación ajusta la influencia de cada entrada en la salida de la neurona. Un valor de entrada grande puede tener una contribución significativa si el peso asociado es grande, pero su influencia puede ser atenuada si el peso es pequeño (Matich, 2001).
- **Flexibilidad y Adaptabilidad:** La capacidad de ajustar los pesos sinápticos confiere flexibilidad y adaptabilidad a la red. La red puede aprender a reconocer patrones, adaptarse a cambios en los datos y generalizar a nuevas situaciones ajustando adecuadamente estos pesos (Matich, 2001).

a.3. FUNCIONES DE ACTIVACIÓN U OPTIMIZACIÓN

Según Gupta (2017), las funciones de activación son transformaciones no lineales de las entradas y los sesgos para determinar si una neurona específica se activará o no. Son mapeos funcionales complejos no lineales de entrada y salida que se suelen aplicar a la siguiente capa de neuronas. Existen diferentes tipos de funciones de activación, siendo los cuatro principales la función *ReLU*, *Softmax*, Sigmoidal y Tangente hiperbólica (*Tanh*), en la siguiente tabla se expone las características de cada una.

a.4. ÉPOCA

El término época se refiere a la cantidad de veces que se pasa cada ejemplo de entrenamiento a través de la red. Aunque es común creer que un alto número de épocas facilitaría el aprendizaje de la red, en la práctica, los pesos y sesgos de las neuronas tienden a converger a valores específicos después de un cierto número. Continuar entrenando con un número excesivamente alto de épocas más allá de este punto no solo es innecesario en términos de tiempo y energía, sino que también aumenta el riesgo de sobreajuste (*overfitting*), lo que puede perjudicar el rendimiento de la red (Casas, 2020).

Por otro lado, si se utiliza un número bajo de épocas, la red puede sufrir de *underfitting*, lo que significa que no adquirirá suficiente conocimiento y como resultado tendrá un rendimiento deficiente en su tarea, por lo tanto, es fundamental encontrar un equilibrio

adecuado en la cantidad de épocas utilizadas durante el entrenamiento para obtener un proceso óptimo y evitar los problemas mencionados (Casas, 2020).

Tabla 19: Funciones de activación

Función de activación	Características
Sigmoidal	Es una función de activación no lineal y continuamente diferenciable. Tiene forma de una curva en “S” y sus valores van de 0 a 1.
<i>Tanh</i>	Es una función de activación no lineal y continuamente diferenciable, es una función extendida de la función sigmoideal y sus valores van de -1 a 1 .
<i>ReLU</i>	Es una función de activación no lineal y muy popular en el aprendizaje profundo. Sus valores van de 0 al infinito. La principal ventaja de <i>ReLU</i> es que solo activa algunas neuronas a la vez. Las neuronas con valores negativos no se activan.
<i>Softmax</i>	La salida para cada clase se comprime entre 0 y 1. Esto representa la probabilidad de que una entrada pertenezca a una clase específica.

FUENTE: Gupta (2017)

a.5. OPTIMIZADOR ADAM

Bushaev (2018) menciona que el optimizador Adam representa un avance significativo en el campo de los algoritmos de optimización para el entrenamiento de redes neuronales. Su diseño se basa en la combinación de conceptos clave del descenso de gradiente estocástico con momento, proporcionando una aproximación eficiente y adaptativa para la optimización de los pesos de la red.

- Tasa de Aprendizaje Adaptativa: Adam se destaca por su capacidad para adaptar la tasa de aprendizaje de manera individualizada para cada parámetro de la red neuronal. Este ajuste dinámico se logra mediante la utilización de estimaciones de los primeros y segundos momentos del gradiente. Los cuadrados de los gradientes se utilizan para ajustar la tasa de aprendizaje, lo que permite un control más preciso de la magnitud de las actualizaciones de los pesos (Bushaev, 2018).
- Elementos del Descenso de Gradiente Estocástico con Momento: Incorpora elementos del descenso de gradiente estocástico con momento, lo que significa que no solo tiene en cuenta la dirección del gradiente actual, sino que también incorpora información sobre la tendencia previa de los gradientes. Esto contribuye a suavizar las fluctuaciones en la dirección del gradiente, mejorando la estabilidad y acelerando el proceso de convergencia de la red hacia un óptimo (Bushaev, 2018).
- Utilización de Momento: En el contexto de los algoritmos de optimización, el momento se refiere a la incorporación de un promedio ponderado de los gradientes anteriores al calcular la actualización de los pesos durante el entrenamiento de la red neuronal. Este enfoque ayuda a superar desafíos asociados con oscilaciones en la dirección del gradiente, proporcionando una inercia que favorece la convergencia hacia el óptimo de manera más eficiente (Bushaev, 2018).
- Estimación de Momentos del Gradiente: Adam utiliza promedios móviles de primer y segundo orden de los gradientes para estimar los momentos. Estos momentos proporcionan información sobre la dirección y la magnitud del gradiente, permitiendo que la tasa de aprendizaje se adapte de manera más precisa a la topología y la dinámica de la superficie de pérdida (Bushaev, 2018).

b. LIBRERÍAS

b.1. *TENSORFLOW*

TensorFlow es una biblioteca más compleja para el cálculo numérico distribuido, eso hace posible entrenar y ejecutar redes neuronales muy grandes de manera eficiente mediante la visualización tributando los cálculos a través de potencialmente cientos de servidores multi-GPU (Gerón, 2019).

Acervolima (2022) menciona que *TensorFlow* presenta las siguientes ventajas:

- *TensorFlow* tiene una mejor representación gráfica para un dato dado en lugar de cualquier otra plataforma superior.
- *TensorFlow* tiene la ventaja de que admite y utiliza muchos softwares de *backend* (parte de desarrollo web que se encarga que una página web funciones) como GUI (*Graphical user interface*) que utiliza elementos gráficos y ASIC (*Application Specific Integrated Circuit*) que es un tipo circuito integrado que está personalizado y adaptado para hacer una tarea muy específica en particular.
- *TensorFlow* ha mostrado un mejor rendimiento en comparación con otras plataformas.
- Fácil de ampliar, ya que ofrece libertad para añadir bloques personalizados para desarrollar nuevas ideas.

b.2. KERAS

Keras es una API (Interfaz de programación de aplicaciones) de aprendizaje profundo de alto nivel que hace que sea muy simple de entrenar y ejecutar redes neuronales. Puede ejecutarse sobre *TensorFlow*, *Theano* o *Microsoft Cognitive Toolkit*. *TensorFlow* viene con su implementación propia de esta API, llamada *tf. Keras*, que brinda soporte para algunas características avanzadas de *TensorFlow* (por ejemplo, para cargar datos de manera eficiente) (Gerón, 2019).

Acervolima (2022) menciona que *Keras* presenta las siguientes ventajas:

- *Keras* es la mejor plataforma que existe para trabajar en modelos de redes neuronales.
- Es fácil de usar y que un principiante puede entender fácilmente.
- *Keras* tiene la ventaja que puede elegir cualquier biblioteca que lo admita para su soporte de *backend*.
- *Keras* proporciona varios modelos previamente entrenados que ayudan al usuario a mejorar aún más los modelos que el usuario está diseñando.

b.3. NUMPY

Numpy es una librería de *Python* especializada en el cálculo numérico y el análisis de datos, especialmente para un gran volumen de datos. Incorpora una nueva clase de objetos llamados *arrays* que permite representar colecciones de datos de un mismo tipo en varias dimensiones, y funciones muy eficientes para su manipulación. La ventaja de *Numpy* es que el procesamiento de los *arrays* se realiza mucho más rápido (hasta 50 veces más) que las listas, lo cual la hace ideal para el procesamiento de vectores y matrices de grandes dimensiones (Alberca, 2022).

b.4. PANDAS

Pandas es una muy popular librería de código abierto dentro de los desarrolladores de *Python*, y sobre todo dentro del ámbito de *Data Science* y *Machine Learning*, ya que ofrece unas estructuras muy poderosas y flexibles que facilitan la manipulación y tratamiento de datos. *Pandas* surgió como necesidad de aunar en una única librería todo lo necesario para que un analista de datos pudiese tener en una misma herramienta todas las funcionalidades que necesitaba en su día a día, como son: cargar datos, modelar, analizar, manipular y prepararlos (Chacón, 2022).

2.4. APLICACIONES DE LA INTELIGENCIA EN LA INDUSTRIA ALIMENTARIA

En la Tabla 20 se detallan algunos trabajos realizados en la aplicación de las redes neuronales artificiales en la industria alimentaria.

Tabla 20: Uso de redes neuronales artificiales (ANN) en matrices alimentarias

Fuente	Trabajos	Variables de Entrada	Variables de Salida	Descripción
Guignon <i>et al.</i> (2008)	Temperatura inicial de congelación de alimentos a altas presiones.	Actividad de Agua a_w . Presión P (MPa).	Tf (°C)	. 2 variables de entrada en una capa oculta. . 6 neuronas. . 1 capa de salida. . Software ANN: Microsoft Quick-Basic (V. 4.5). . Tasa de aprendizaje (μ): 0.6. . Error de predicción medio: 0.3 °C. . Se entrenó con 515 puntos de a_w , P, Tf. . Pesos se asignan mediante un procedimiento de optimización (Retro propagación).
Hussain <i>et al.</i> (2002)	Predicción de formación de poros (porosidad) en alimentos durante el secado: modelos genéricos mediante el uso de redes neuronales híbridas.	Combinaciones: Modelo I: Temperatura (T) y Contenido de agua (X_w). Modelo II: Temperatura (T), Contenido de agua (X_w) y porosidad inicial (ϵ_o). Modelo III: Temperatura (T), Contenido de agua (X_w) y porosidad inicial (ϵ_o) y tipo de producto (F).	Porosidad (ϵ_t)	. Error de predicción de modelo I: 56.5 %. . Error de predicción de modelo II: 0.98 %. . Error de predicción de modelo III: 0.58 %. . Se usaron funciones de activación: <i>purelin</i> , <i>tansing</i> , <i>losing</i> . . Se usó 50 épocas. . Se usaron 286 datos para entrenar la red. . Pesos se asignan mediante un procedimiento de optimización (Retro propagación).
Cerit <i>et al.</i> (2017)	Estimación de actividad antioxidante de alimentos usando redes neuronales artificiales.	Variedad de alimento. Contenido de fenoles.	Actividad antioxidante	.2 variables de entrada en una capa oculta. .1 capa de salida. .80 neuronas.

<<Continuación >>

				<p>.150 datos se utilizaron para entrenar la red neuronal (58 de pimienta y 92 de semilla de uva).</p> <p>. Rango de error del 10 % o 90 % de éxito.</p>
Rahman <i>et al.</i> (2012)	<p>Predicción de la conductividad térmica de los alimentos mediante técnicas de modelado de Redes neuronales y Difuso (ANFIS).</p>	<p>Fracción de contenido de agua.</p> <p>Temperatura.</p> <p>Porosidad aparente.</p>	<p>Conductividad térmica efectiva</p>	<p>. El modelo neuro difuso adaptativo (ANFIS) pudo ayudar a proporcionar predicciones más cercanas a las experimentales obteniendo un error cuadrático medio más bajo a comparación de una red neuronal artificial convencional.</p> <p>. Se utilizaron 676 puntos de datos para entrenar la red.</p> <p>. El método ANFIS Y ANN se compararon con resultados experimentales a través de: Error relativo medio, Desviación estándar en errores relativos, Error absoluto medio y Desviación estándar en error absoluto.</p>
Mittal y Zhang (2000)	<p>Predicción del tiempo de congelación de productos alimenticios utilizando una red neuronal.</p>	<p>Grosor del producto (m).</p> <p>Ancho del producto (m).</p> <p>Longitud del producto (m).</p> <p>Coefficiente convectivo de transferencia de calor (h_c) [$W/(m^2 K)$].</p> <p>Conductividad térmica del producto congelado (k) [$W/(m.K)$].</p> <p>Densidad del producto (ρ) (kg/m^3).</p>	<p>t (min)</p>	<p>. 10 datos de entrada.</p> <p>. 40 nodos en 3 bloques de capas ocultas.</p> <p>. 1 capa de salida.</p> <p>. Software ANN: NeuroShell 2.</p> <p>. 26611 conjunto de datos para entrenar la red.</p> <p>. Pesos se asignan mediante un procedimiento de optimización (Retro propagación).</p> <p>. Tasa de aprendizaje (μ): 0.7.</p>

<<Continuación >>

Calor específico del producto descongelado (C_{pu}) [$\text{kJ}/(\text{kg K}^{-1})$].	. Error absoluto medio más bajo: 3.54 min y el Error absoluto máximo: 53.7 min.
Contenido de humedad del producto (m) [%].	. El 83 % de los datos estuvieron dentro del 5 % de error relativo.
Temperatura inicial del producto (T_i) [$^{\circ}\text{C}$].	. Validación: 150 datos experimentales se predijeron con un error relativo menor a 10 %.
Temperatura ambiente (T_{∞}) [$^{\circ}\text{C}$].	. Influencia de los datos de entrada para la predicción siendo el más relevante el grosor del producto y el menos relevante el coeficiente de calor específico del producto descongelado.

III. METODOLOGÍA

3.1. LUGAR DE ESTUDIO

Para el desarrollo de la investigación se utilizó el Laboratorio de Análisis Fisicoquímico de los Alimentos, el Laboratorio de Investigación e Instrumentación, y el Laboratorio de Ingeniería de Alimentos, pertenecientes a la Facultad de Industrias Alimentarias de la Universidad Nacional Agraria La Molina (UNALM).

3.2. MATERIAS PRIMAS

Se adquirieron raíces y tubérculos en el Gran Mercado Mayorista de Lima, seleccionando aquellos que cumplieran con condiciones óptimas de madurez comercial y de consumo, así como un buen estado de conservación.

- Mashua amarilla (*Tropaeolum tuberosum*).
- Maca amarilla (*Lepidium meyenii*).
- Yacón blanco (*Smallanthus sonchifolius*).
- Arracacha blanca (*Arracacia xanthorrhiza*).
- Olluco chucchan lisa (*Ullucus tuberosus*).

3.3. EQUIPOS Y MATERIALES

3.3.1. EQUIPOS

- Módulo de ultra congelación (Mod. SUR/EV, Elettronica Veneta, Italia).
- Sensores DataTrace MPRF (M4T17114, M4T17115, M4T17257) (MesaLab, USA).
- Balanza analítica (MB35, OHAUS, EE. UU.).
- Estufa de vacío (Vacucell 22, MMM, Alemania).

- Digestor Kjeldahl (Kjeldatherm KB20S, Gerhardt, Alemania).
- Mufla (F48000, Barnstead International, USA).
- Soxtherm (416, Gerhardt, Alemania).
- Computador con software DataTrace PRO (MesaLab, USA).
- Refractómetro (Pocket, Atago, Japón).
- Potenciómetro (Hanna, USA).
- Espectrofotómetro de absorción atómica (Agilent 240FS AA, USA).

3.3.2. MATERIALES Y REACTIVOS

- Materiales de laboratorio para condicionamiento de las muestras (Tablas, cuchillos y material de vidrio).
- Reactivos para análisis proximal y para el acondicionamiento de las muestras para determinación de minerales.
- Reactivos para el análisis de vitamina C:
 - a. 100 mg de ácido ascórbico
 - b. Ácido oxálico al 0.5 %.
 - c. Solución de 2.6 diclorofenolindofenol

3.3.3. HERRAMIENTAS Y BIBLIOTECAS INFORMÁTICAS

a. *Google Colaboratory*

Google Colab, también conocido como "*Colab*", se presenta como un producto de Google que permitió a los desarrolladores escribir y ejecutar código Python directamente a través de un navegador. Este entorno de desarrollo se destacó por su accesibilidad, eliminando la necesidad de configuración y ofreciendo una versión gratuita que proporcionaba acceso a los recursos informáticos de Google, incluidas las unidades de procesamiento gráfico (GPU). Durante su existencia, *Google Colab* se consolidó como una herramienta especialmente efectiva para tareas de aprendizaje profundo, al ofrecer un entorno de cuaderno de notas alojado que facilitó el desarrollo de proyectos sin las complicaciones asociadas a la configuración del entorno de desarrollo (Yalçın, 2021).

Este entorno incluyó bibliotecas esenciales de ciencia de datos como *Pandas*, *Numpy* y *Matplotlib*, y, de manera crucial, proporcionó compatibilidad directa con *TensorFlow*, una biblioteca de aprendizaje profundo líder. Además, *Google Colab* permitió a los usuarios compartir fácilmente sus cuadernos de notas con otros desarrolladores, fomentando la colaboración, y ofreció la conveniencia de almacenar los archivos directamente en *Google Drive* para una gestión eficiente de los proyectos y recursos. En su conjunto, *Google Colab* se posicionó como una solución integral que aprovechó las capacidades de la nube y facilitó la implementación de proyectos de aprendizaje profundo de manera eficiente y colaborativa (Yalçın, 2021).

b. *TensorFlow*

TensorFlow, es una biblioteca compleja para el cálculo numérico distribuido, ha desempeñado un papel crucial en la capacidad de entrenar y ejecutar redes neuronales de gran envergadura de manera eficiente. Esta herramienta posibilita la distribución de cálculos en potencialmente cientos de servidores con unidades de procesamiento gráfico (GPU), permitiendo un aprovechamiento óptimo de recursos para tareas de aprendizaje profundo. Originada en Google, *TensorFlow* se alinea perfectamente con muchas de las aplicaciones de aprendizaje automático a gran escala desarrolladas por la empresa (Géron, 2019).

c. *Keras*

Keras es una biblioteca de red neuronal de código abierto escrita en Python que actúa como interfaz de alto nivel para la construcción, entrenamiento y evaluación de modelos de redes neuronales. Su funcionalidad se centra en simplificar el proceso de desarrollo de modelos, permitiendo a los desarrolladores experimentar rápidamente con arquitecturas de redes neuronales. La principal característica de *Keras* es su capacidad para ejecutarse sobre distintos motores de *backend*, siendo *TensorFlow* uno de los más comunes (Yalçın, 2021).

La biblioteca *Keras* facilita la creación de redes neuronales mediante una interfaz amigable y modular, lo que permite a los desarrolladores enfocarse en la estructura y lógica del modelo sin tener que preocuparse por detalles de bajo nivel. Esta biblioteca se caracteriza por ser simple, flexible y potente, proporcionando herramientas para la construcción de modelos

desde simples hasta complejas arquitecturas. Su versatilidad y facilidad de uso la convierten en una opción popular para aquellos que buscan una interfaz intuitiva para el desarrollo eficiente de aplicaciones de inteligencia artificial basadas en redes neuronales (Yalçın, 2021).

d. *Numpy*

Numpy se presenta como una biblioteca especializada en Python que se centra en el cálculo numérico y el análisis de datos, especialmente diseñada para manejar grandes volúmenes de información. Introduce una nueva clase de objetos denominada "*arrays*", que posibilita la representación de colecciones de datos del mismo tipo en múltiples dimensiones. *Numpy* ofrece funciones altamente eficientes para la manipulación de estos arrays, lo que constituye su característica distintiva (ALF, 2022).

La ventaja clave de *Numpy* radica en la velocidad de procesamiento de los *arrays*, que puede ser hasta 50 veces más rápida que las listas estándar de Python. Esta eficiencia la convierte en una elección ideal para el manejo y procesamiento de vectores y matrices de grandes dimensiones, ofreciendo un rendimiento superior en comparación con otras estructuras de datos en escenarios que involucran operaciones numéricas intensivas (ALF, 2022).

e. *Pandas*

Pandas se destaca como una librería de código abierto ampliamente popular entre los desarrolladores de Python, especialmente en los campos de *Data Science* y *Machine Learning*. Su popularidad radica en la oferta de estructuras de datos poderosas y flexibles que simplifican significativamente la manipulación y el tratamiento de datos. *Pandas* surgió como una respuesta a la necesidad de consolidar en una única librería todas las herramientas esenciales para los analistas de datos, proporcionando funcionalidades integrales para tareas cotidianas como cargar datos, modelar, analizar, manipular y prepararlos (Profile, 2022).

Con un enfoque centrado en la usabilidad y la eficiencia, *Pandas* se ha convertido en un pilar esencial en el ecosistema de Python para el análisis de datos. Su capacidad para manejar grandes conjuntos de datos de manera eficaz, junto con funciones avanzadas de manipulación y limpieza de datos, ha contribuido significativamente a su adopción

generalizada en diversos sectores, desde la investigación académica hasta la industria (Profile, 2022).

3.4. MÉTODOS DE ANÁLISIS

3.4.1. CARACTERIZACIÓN PROXIMAL Y FÍSICOQUÍMICA DE LAS MATERIAS PRIMAS

a. ANÁLISIS PROXIMAL

Las materias primas fueron caracterizadas mediante su composición proximal utilizando los métodos oficiales de la AOAC (2019): se determinó el contenido de agua (925.10), el contenido de proteína (920.87), el contenido de grasa (922.06), el contenido de cenizas (923.03). Asimismo, se evaluó el contenido de fibra cruda (NTP 205.003) y se determinó el contenido de carbohidratos por diferencia (MS-INN Collazos 1993).

b. ACIDEZ TITULABLE

Para determinar la acidez titulable de las muestras, se utilizó el Método 942.15 (AOAC, 2005). Se homogeneizaron 10 g de la materia prima con 100 mL de agua destilada durante 10 minutos. Posteriormente, se centrifugó la mezcla para separar el sobrenadante. El extracto resultante se tituló utilizando una solución de Hidróxido de sodio 0.0094 N, hasta alcanzar un pH de 8.2. Los resultados de acidez se expresaron en porcentaje de ácido predominante (g ácido predominante/100 g de muestra seca).

c. DETERMINACIÓN DE SÓLIDOS SOLUBLES

La determinación de la cantidad de sólidos solubles expresados en °Brix se llevó a cabo por refractometría siguiendo el Método 932.12 (AOAC, 2005). Se estrujaron diez gramos de muestra para obtener un líquido, el cual se empleó en la medición.

d. DETERMINACIÓN DE MINERALES

Los principales minerales de cada muestra (Calcio, Magnesio, Fósforo y Potasio) se cuantificaron utilizando espectrofotometría de absorción atómica (Agilent 240FS AA), siguiendo el método descrito en la AOAC 985.35.

e. DETERMINACIÓN DE ÁCIDO ASCÓRBICO

El contenido de ácido ascórbico fue cuantificado mediante la valoración de 2,6-dicloroindofenol (AOAC, 967.21).

3.5. DETERMINACIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN DE RAÍCES Y TUBÉRCULOS

3.5.1. RECOPIACIÓN DE DATOS PUBLICADOS DE LA COMPOSICIÓN Y LA TEMPERATURA INICIAL DE CONGELACIÓN (TF) DE VEGETALES

Se recopiló la composición proximal detallada de diversos vegetales utilizando la base de datos de *United States Department of Agriculture* (USDA, 2023). La base de datos se encuentra disponible en la web con diversas funciones de búsqueda (<https://fdc.nal.usda.gov/fdc-app.html#>). Se recopilaron los siguientes elementos clave: Agua, proteínas, lípidos, monosacáridos, disacáridos, fibra, minerales (Na, K, Mg, Ca, P, Cl) y ácidos/bases (Ascórbico, Cítrico (iso), Málico, Oxálico, Nitratos), para posteriormente determinar la temperatura inicial de congelación con el método de Boonsupthip y Heldman (2007).

La recopilación de la temperatura inicial de congelación (Tf) de vegetales se llevó a cabo a partir de investigaciones científicas y libros especializados, como el de La Sociedad Estadounidense de Ingenieros de Calefacción, Refrigeración y Aire Acondicionado (ASHRAE, 2018) y otros (Rahman, Machado-Velasco, Sosa-Morales, y Velez-Ruiz, 2009). En casos donde se encontraron diferentes valores reportados de Tf para un mismo alimento, se consideró como criterio el contenido de agua proporcionado en la literatura y la composición del alimento.

Para analizar la efectividad del modelo propuesto por Boonsupthip y Heldman (2007), se emplearon el porcentaje de error y la desviación estándar absoluta. Estos criterios se utilizaron para contrastar la temperatura inicial de congelación obtenida a través de la literatura con aquellas determinadas por el modelo mencionado.

3.5.2. GENERACIÓN DE DATOS Y TEMPERATURAS INICIALES DE CONGELACIÓN

Se generaron 6000 conjuntos de datos utilizando el código de la Figura 8 en *Google Colab*, empleando los valores máximos y mínimos obtenidos experimentalmente para la composición de raíces y tubérculos en estudio, que incluía agua, proteínas, lípidos, monosacáridos, disacáridos, fibra, minerales y ácido ascórbico. Adicionalmente, se determinaron las temperaturas iniciales de congelación mediante el modelo de Boonsupthip y Heldman (2007) (Ec. 5), las cuales fueron consideradas como variables de salida. Esto con la finalidad de comprobar que a una mayor cantidad de datos de entrenamiento se pueda mejorar el rendimiento de la red neuronal.

3.5.3. VERIFICACIÓN DE LOS SENSORES DATATRACE CON UNA DISOLUCIÓN DE NaCl A DIFERENTES CONCENTRACIONES

La verificación se llevó a cabo para validar el proceso experimental destinado a determinar la temperatura inicial de congelación de las raíces y tubérculos bajo estudio. Esta verificación fue esencial para asegurar el adecuado funcionamiento de los sensores inalámbricos DataTrace (M4T17257, M4T17114, M4T17115) utilizados en la medición.

Se utilizó una disolución de NaCl en agua, con la cual se llevaron a cabo mediciones a diversas concentraciones (2, 4, 6 y 10 g/100g). Estas concentraciones se sometieron a una temperatura de -30 °C. Los sensores registraron la temperatura cada 10 segundos, permitiendo la obtención de una curva de congelación en función del tiempo (°C vs. min).

Para determinar la temperatura inicial de congelación, se aplicó el método propuesto por Rahman et al. (2002), que involucra el análisis de las gráficas de congelación (°C) y la curva de velocidad de enfriamiento (°C/min vs. min) de manera gráfica.


```

import pandas as pd
import numpy as np

# Establecer la semilla aleatoria para reproducibilidad
np.random.seed(42)

# Función para generar composiciones aleatorias dentro de los
rangos dados
def generar_composiciones(num_composiciones):
    composiciones = {
        'Agua': np.random.uniform(69.27, 91.17,
num_composiciones),
        'Proteína': np.random.uniform(0.17, 3.51,
num_composiciones),
        'Lípidos': np.random.uniform(0.11, 0.56,
num_composiciones),
        'Monosacáridos': np.random.uniform(0.53, 12.3,
num_composiciones),
        'Disacáridos': np.random.uniform(0.43, 1.54,
num_composiciones),
        'Fibra': np.random.uniform(0.11, 1.76,
num_composiciones),
        'Minerales': np.random.uniform(0.231, 0.857,
num_composiciones),
        'Ácidos': np.random.uniform(0.001, 0.069,
num_composiciones)

    return composiciones

# Generar 6000 composiciones aleatorias
num_composiciones = 6000
composiciones =
generar_composiciones(num_composiciones)

# Convertir el diccionario a un DataFrame
df = pd.DataFrame(composiciones)

# Exportar el DataFrame a un archivo Excel
nombre_archivo_excel = 'composiciones_alimentos.xlsx'
df.to_excel(nombre_archivo_excel, index=False)

print(f"Se generaron {num_composiciones} composiciones de
alimentos y se exportaron a {nombre_archivo_excel}.")

```

Figura 8: Generación de 6000 conjunto de datos

3. 5. 4. DETERMINACIÓN EXPERIMENTAL DE LA TEMPERATURA INICIAL DE CONGELACIÓN (TF)

Se utilizó el método propuesto por Rahman *et al.* (2002) para determinar la Tf analizando la curva de congelación del alimento. Para ello, se introdujeron las muestras trituradas sin cáscara en un tubo de plástico con medidas de: 14.50 mm de espesor, 16.53 mm de diámetro y 118.44 mm de altura.

Se registró la temperatura en el centro del tubo cada 10 segundos utilizando un sensor inalámbrico de temperatura DataTrace (MESA Labs, USA) cuando la muestra estuvo sometida a -30°C . La determinación de la Tf se realizó evaluando la curva de congelación ($^{\circ}\text{C}$ vs min) y el perfil de velocidad de enfriamiento de manera gráfica (Temperatura/tiempo versus tiempo $^{\circ}\text{C}/\text{min}$ vs min). Los datos experimentales se ajustaron a diferentes pendientes.

La pendiente inicial se empleó para determinar la velocidad de enfriamiento. Posteriormente, se observó una reducción de la pendiente hasta llegar a una meseta, lo cual indicó el punto inicial de congelación (Punto a, Figura 5). Además, en la Figura 9 se aprecia el diagrama representativo. Se llevaron a cabo 3 repeticiones como mínimo por cada materia prima.




Figura 9: Diagrama representativo del A) Módulo de ultracongelación; B) Sensores inalámbricos de temperatura; C) Tubo de plástico que contendrá a las muestras y D) Computadora donde se recibirán los datos de tiempo y temperatura de la curva de congelación de los alimentos

3.6. PROCEDIMIENTO EXPERIMENTAL

3.6.1. DESARROLLO DE UNA RED NEURONAL ARTIFICIAL PROFUNDA PARA LA PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (TF) DE VEGETALES

a. PREDICCIÓN DE LA TF DE VEGETALES UTILIZANDO DATOS DE COMPOSICIÓN

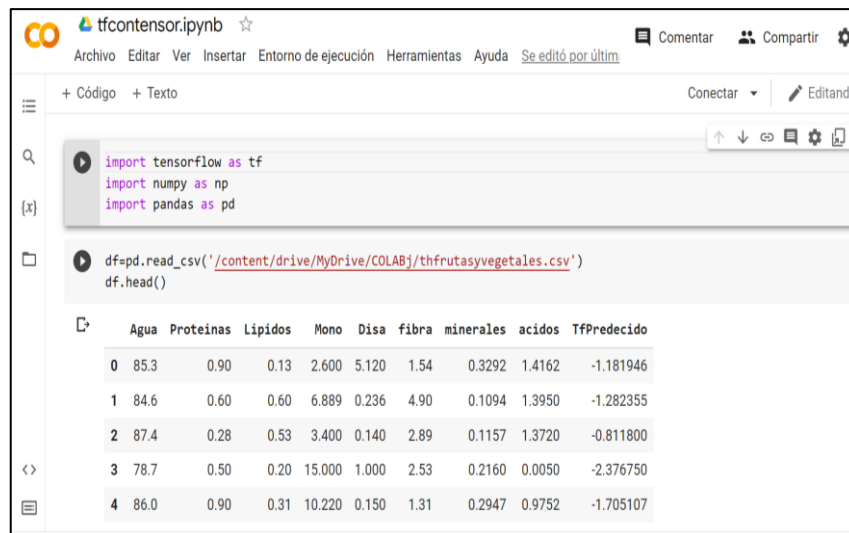
Se llevó a cabo la predicción de la temperatura inicial de congelación (Tf) de los vegetales mediante la aplicación del modelo propuesto por Boonsupthip y Heldman (2007); Waraporn Boonsupthip, Sajjaanantakul y Heldman (2009) (Ec. 5). En este análisis, se consideraron como componentes proximales del modelo: agua, proteínas, lípidos, monosacáridos, disacáridos, fibra; así como minerales: potasio, fósforo, calcio y magnesio, y ácido orgánico, representado por el ácido ascórbico.

Para determinar el contenido de agua no congelable o ligada en vegetales, se empleó el coeficiente experimental recomendado por Boonsupthip y Heldman (2007), que fue establecido en 0.18. Este coeficiente se aplicó a la suma de fracciones másicas, como se detalló en la Ec.6.

b. DESARROLLO Y ENTRENAMIENTO DE LA RED NEURONAL PROFUNDA PARA PREDECIR EL VALOR DE TF UTILIZANDO LA COMPOSICIÓN DE LOS VEGETALES

Se programó una red neuronal profunda en Google Colab utilizando el lenguaje de programación Python. En primer lugar, se importaron las librerías de *TensorFlow*, *Numpy* y *Pandas*. Por defecto, la hoja de *Google Colab* tenía las librerías de *Keras* cargadas.

La importación de los datos utilizados para entrenar la red neuronal se realizó directamente desde *Google Drive*, mediante un archivo con extensión ".csv". Un ejemplo de la organización de los datos importados se presenta en la Figura 10.



The screenshot shows a Jupyter Notebook titled 'tfcontensor.ipynb'. The code cell contains the following Python code:

```
import tensorflow as tf
import numpy as np
import pandas as pd

df=pd.read_csv('/content/drive/MyDrive/COLABj/thfrutasyvegetales.csv')
df.head()
```

The output of the code is a pandas DataFrame with 5 rows and 10 columns. The columns are: Agua, Proteinas, Lípidos, Mono, Disa, fibra, minerales, acidos, and TfPredecido. The data is as follows:

	Agua	Proteinas	Lípidos	Mono	Disa	fibra	minerales	acidos	TfPredecido
0	85.3	0.90	0.13	2.600	5.120	1.54	0.3292	1.4162	-1.181946
1	84.6	0.60	0.60	6.889	0.236	4.90	0.1094	1.3950	-1.282355
2	87.4	0.28	0.53	3.400	0.140	2.89	0.1157	1.3720	-0.811800
3	78.7	0.50	0.20	15.000	1.000	2.53	0.2160	0.0050	-2.376750
4	86.0	0.90	0.31	10.220	0.150	1.31	0.2947	0.9752	-1.705107

Figura 10: Ejemplo de importaciones de librerías y datos de entrenamiento a utilizar para programar una red neuronal profunda capaz de predecir la Tf

Se configuró la primera red neuronal con 8 valores de entrada (agua, proteínas, lípidos, monosacáridos, disacáridos, fibra, minerales y ácidos), así como un solo valor de salida que representa la temperatura inicial de congelación (Tf). La red neuronal artificial contó con 3 capas ocultas, cada una compuesta por 5 neuronas (ver Figura 11). Para desarrollar las capas ocultas, se empleó la librería de *Keras* a través de la siguiente instrucción:

```
Ocultal = tf.keras.layers.Dense(units=5,
input_shape=[8,])
Ocultal2 = tf.keras.layers.Dense(units=5, )
. Salida = tf.keras.layers.Dense(units=1)
```

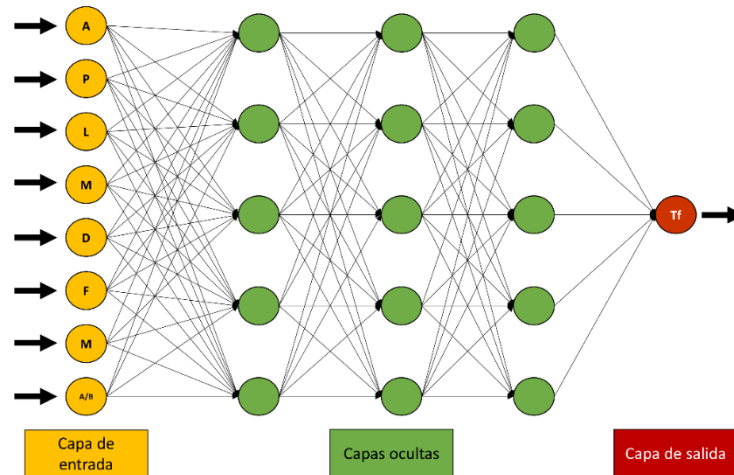


Figura 11: Esquema de la red neuronal artificial profunda con 8 valores de entrada, 1 valor de salida y 3 capas ocultas con 5 neuronas por capa. Donde A es el contenido de agua, P es el contenido de proteínas, L es el contenido de lípidos, M es el contenido de Monosacáridos, D es el contenido de Disacáridos, F es el contenido de Fibra, M es el contenido de minerales y A/B contenidos ácidos/bases

Se utilizó también el modelo "*sequential*". Este modelo de *Keras* resulta apropiado para el análisis y la comparación de modelos sencillos enfocados en redes neuronales, que comprenden capas y sus datos asociados a través de un flujo de arriba hacia abajo.

El modelo secuencial hace uso de un único conjunto de entrada y un único conjunto de salida siguiendo este flujo. Es la elección más adecuada cuando se trata de una secuencia simple de capas con un tensor de entrada y un tensor de salida. La utilización de la *API* secuencial de *Keras* representa el método más fundamental para crear redes neuronales (Long y Zeng, 2022).

```
modelo = tf.keras.Sequential([Oculto1, Oculta2...salida])
```

Las distancias entre los valores reales y los valores pronosticados se registraron como términos de error. Estos términos de error se consolidaron en un único valor mediante funciones de pérdida. Además de este proceso, las funciones de optimización llevaron a cabo ajustes pequeños en los pesos y sesgos, y evaluaron los efectos de estos cambios mediante funciones de pérdida.

Este procedimiento contribuyó a determinar los valores óptimos de peso y sesgo para minimizar los errores y maximizar la precisión del modelo (Yalçın, 2021).

En el caso de esta red neuronal, se optó por el optimizador "Adam". Para evaluar el rendimiento del modelo, es decir, la discrepancia entre el valor real y la predicción, se empleó el estadístico del Error Cuadrático Medio (Yalçın, 2021).

```
modelo.compile(optimizer=tf.keras.optimizers.Adam(0.1),  
loss='mean_squared_error')
```

c. EVALUACIÓN DE LA INFLUENCIA DEL NÚMERO DE CAPAS Y NEURONAS PARA AUMENTAR LA CAPACIDAD DE PREDICCIÓN DE LA RED NEURONAL ARTIFICIAL

Con el objetivo de mejorar la capacidad predictiva de la red neuronal artificial, se aumentó el número de capas ocultas (3, 5 y 9) y de neuronas (5, 10, 20) por cada capa (Figura 12).

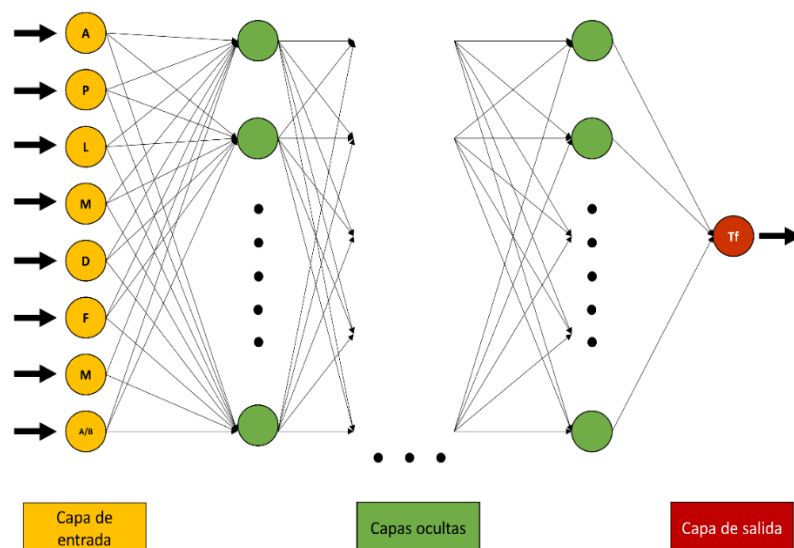


Figura 12: Esquema de la red neuronal artificial profunda con 8 valores de entrada, 1 valor de salida y con capas ocultas y neuronas variables. Donde A es el contenido de agua, P es el contenido de proteínas, L es el contenido de lípidos, M es el contenido de minerales, D es el contenido de disacáridos, F es el contenido de fibra, M es el contenido de monosacáridos y A/B contenidos ácidos/bases

Los tratamientos experimentales están detallados en la Tabla 21. Para determinar la combinación más efectiva de capas y neuronas, se empleó el RMSE (raíz del error cuadrático medio). Esta información sirvió de guía para realizar las siguientes modificaciones en la red neuronal.

Se llevaron a cabo varias iteraciones, probando diferentes configuraciones de capas y neuronas, y evaluando el impacto en el rendimiento del modelo en función del RMSE. Este proceso proporcionó una guía valiosa para optimizar la arquitectura de la red neuronal.

Tabla 21: Tratamientos a evaluar para mejorar la predicción de la red neuronal artificial desarrollada

Tratamiento	Capas ocultas	Neuronas	RMSE
T1	3	5	-
T2	3	10	-
T3	3	20	-
T4	5	5	-
T5	5	10	-
T6	5	20	-
T7	9	5	-
T8	9	10	-
T9	9	20	-

d. REDUCCIÓN DE LOS VALORES DE ENTRADA EN LA PREDICCIÓN DE LA TF DE VEGETALES

Con la red neuronal que mostró la mejor combinación de capas ocultas y número de neuronas, se procedió a reducir el número de variables utilizadas por la red neuronal artificial. Para esto, se evaluó la capacidad predictiva de la red al eliminar secuencialmente componentes de peso molecular elevado como Proteínas, Lípidos y Fibra. También se eliminaron minerales y ácidos/bases con baja proporción en los vegetales estudiados, siguiendo las indicaciones de Boonsupthip y Heldman (2007) y Waraporn Boonsupthip *et al.* (2009).

3.6.2. DESARROLLO DE DIFERENTES CONFIGURACIONES DE REDES NEURONALES

En el contexto de esta investigación, se llevaron a cabo cuatro entrenamientos de redes neuronales con el fin de evaluar su rendimiento en diversas condiciones. Se realizaron un total de 36 configuraciones diferentes al variar el número de capas y neuronas en cada caso. Aquí se detalla cada uno de los cuatro entrenamientos:

1. Entrenamiento con 31 conjuntos de datos iniciales:
 - Variables de entrada: Agua, proteínas, lípidos, monosacáridos, disacáridos, fibra, minerales totales y ácido ascórbico (ocho en total).
 - Variable de salida: Tf. Calculado mediante el modelo propuesto de Boonsupthip y Heldman (2007).
 - Configuraciones probadas: 3, 5 y 9 capas ocultas con 5, 10 y 20 neuronas.
2. Entrenamiento con 31 conjuntos de datos iniciales (variables de entrada reducidas):
 - Variables de entrada: Agua, monosacáridos, disacáridos, minerales totales y ácido ascórbico (cinco en total).
 - Variable de salida: Tf. Calculado mediante el modelo propuesto de Boonsupthip y Heldman (2007).
 - Configuraciones probadas: 3, 5 y 9 capas ocultas con 5, 10 y 20 neuronas.
3. Entrenamiento con 6000 conjuntos de datos generados:
 - Variables de entrada: Agua, proteínas, lípidos, monosacáridos, disacáridos, fibra, minerales totales y ácido ascórbico (ocho en total).
 - Variable de salida: Tf. Calculado mediante el modelo propuesto de Boonsupthip y Heldman (2007).
 - Configuraciones probadas: 3, 5 y 9 capas ocultas con 5, 10 y 20 neuronas.
4. Entrenamiento con 6000 conjuntos de datos generados (variables de entrada reducidas):
 - Variables de entrada: Agua, monosacáridos, disacáridos, minerales totales y ácido ascórbico (cinco en total).
 - Variable de salida: Tf. Calculado mediante el modelo propuesto de Boonsupthip y Heldman (2007).
 - Configuraciones probadas: 3, 5 y 9 capas ocultas con 5, 10 y 20 neuronas.

En cada una de estas configuraciones, se exploraron diferentes arquitecturas de red neuronal para evaluar su desempeño en el análisis de datos.

Estos distintos escenarios de entrenamiento posibilitaron una evaluación exhaustiva sobre cómo la cantidad de datos y la dimensión de las variables de entrada influyen en las capacidades predictivas y el rendimiento general de las redes neuronales resultantes (Rahman *et al.*, 2012).

En consecuencia, esta exploración contribuye a una comprensión más profunda de la aplicabilidad y eficacia de las redes neuronales en diversos contextos.

3.6.3. PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (Tf) DE RAÍCES Y TUBÉRCULOS ANDINOS Y VALIDACIÓN DE LA RED NEURONAL ARTIFICIAL PROFUNDA

a. VALIDACIÓN DE LA RED NEURONAL ARTIFICIAL PROFUNDA DESARROLLADA

Se llevó a cabo la predicción de la temperatura inicial de congelación (Tf) para la mashua, maca, yacón, arracacha y olluco. Para ello, se utilizaron los componentes proximales significativos, los cuales previamente habían sido determinados experimentalmente siguiendo la metodología detallada en la sección 3.4 (Métodos de Análisis).

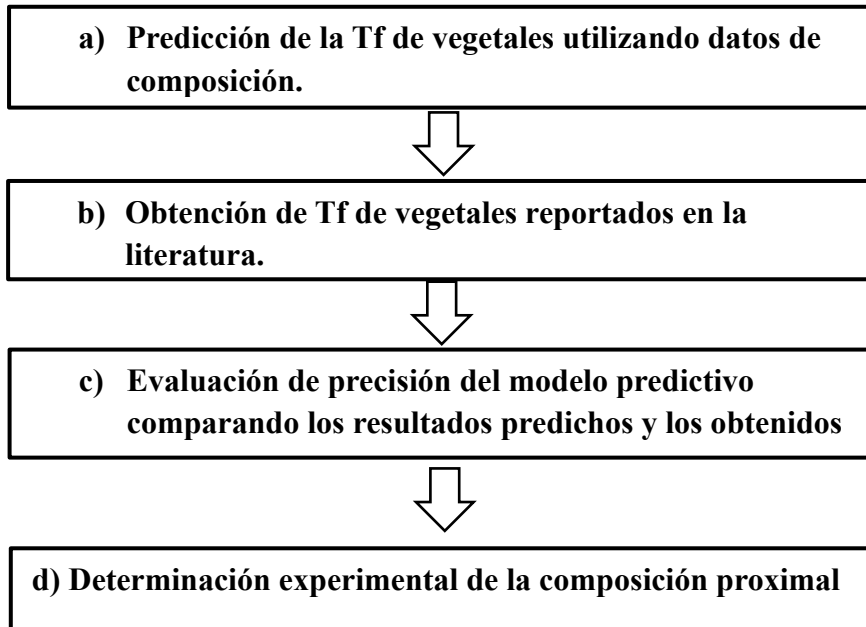
Los valores experimentales de la Tf se compararon con los valores predichos con el fin de validar la red neuronal artificial desarrollada.

Para evaluar la capacidad de predicción de la red neuronal, se utilizó el porcentaje de error y la desviación estándar absoluta.

El esquema experimental, que resume las diferentes etapas implementadas para desarrollar la red neuronal profunda capaz de predecir la temperatura inicial de congelación de raíces y tubérculos andinos, se presentó en la Figura 13.

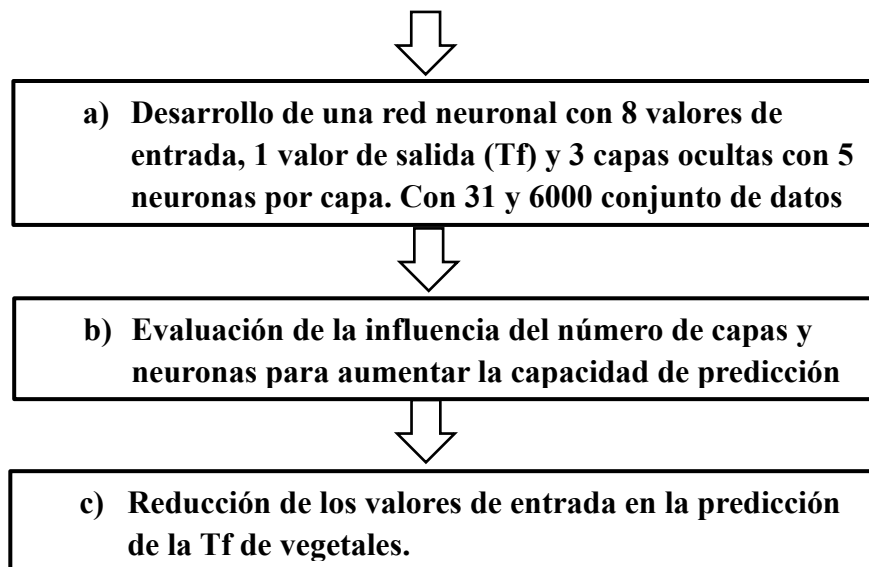
ETAPA 1

Obtención de valores de Tf de vegetales para entrenar la red neuronal y determinación experimental de la composición proximal



ETAPA 2

Desarrollo y entrenamiento de la red neuronal profunda capaz de predecir la Tf de vegetales



ETAPA 3

Determinación de la temperatura inicial de congelación de raíces y tubérculos y predicción de la temperatura inicial de congelación (Tf) de raíces y tubérculos andinos y validación de la red neuronal artificial profunda

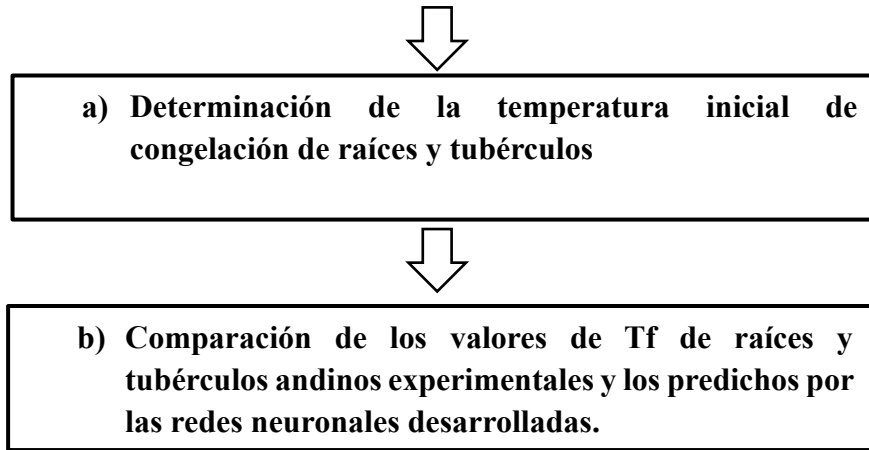


Figura 13: Esquema experimental para la predicción de la temperatura inicial de congelación de tubérculos y raíces andinos utilizando una red neuronal artificial profunda

3.7. ANÁLISIS ESTADÍSTICO

Las comparaciones de valores de Tf se analizaron estadísticamente en términos de la raíz del error cuadrático medio (RMSE) mediante la ecuación 7.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Tf_{experimental} - Tf_{predicho})^2} \quad \text{Ec (7)}$$

Donde n es el número de datos. En algunos casos, los resultados se expresaron en términos de diferencia absoluta (AD) y porcentaje de error (% E) (Ec. 8 y 9).

$$AD = |Valor_{experimental} - Valor_{predicho}| \quad \text{Ec (8)}$$

$$\%E = \frac{|Valor\ experimental - Valor\ predicho|}{Valor\ experimental} \times 100 \quad Ec\ (9)$$

Se llevó a cabo un análisis de varianza (ANVA) para los valores experimentales de la composición proximal, °Brix, pH, ácido ascórbico, minerales y Tf de las materias primas. Posteriormente, se aplicó una prueba de comparación (Tukey) con un nivel de significancia del 0.05.

IV. RESULTADOS Y DISCUSIÓN

4.1. ETAPA I: OBTENCIÓN DE VALORES DE TEMPERATURA INICIAL DE CONGELACIÓN (TF) DE VEGETALES PARA ENTRENAR LA RED NEURONAL

4.1.1. COMPOSICIÓN PROXIMAL DE VEGETALES

En la Tabla 22, se presentan los resultados recopilados de la composición proximal de 31 vegetales. Estos datos se obtuvieron de la base de datos de la USDA (2023). Se observa que los vegetales poseen un contenido significativo de agua (73.2 g a 95.6 g). Según Cheung y Mehta (2015), el contenido de agua en vegetales varía entre el 75 y el 95%, mientras que Gil (2010) menciona que el contenido de agua en vegetales generalmente se encuentra en un rango de 80 a 90%. Es importante destacar que la mayoría de estos vegetales son prácticamente libres de grasa y tienden a tener proporciones bajas de proteínas e hidratos de carbonos.

La materia seca de los vegetales está compuesta por biomoléculas como lípidos, proteínas y carbohidratos, además de minerales y vitaminas (Cheung y Mehta, 2015). Al analizar la Tabla 22, se destaca la variabilidad en el contenido de proteínas, que abarca desde 0.6 hasta 5.42 g/100 g. Estos valores se encuentran dentro del rango reportado por Gil (2010), quien menciona que los compuestos nitrogenados en los vegetales oscilan entre 1 y 5%. Por otro lado, los valores presentados en la Tabla 22 para el contenido de lípidos muestran una escasa presencia de esta biomolécula, fluctuando entre 0.05 a 1.18 g/100g. En línea con esto, Gil (2010) indica que el contenido de lípidos en los vegetales se encuentra en el rango de 0.1 a 0.9 %.

Shanmugavelan et al. (2013) explican que las plantas generan carbohidratos mediante la fotosíntesis, que luego se utilizan como fuentes de energía para su crecimiento y

desarrollo vegetativo o como precursores en la biosíntesis de diversas moléculas, incluyendo lípidos, proteínas y polisacáridos. Por su parte, Cheung y Mehta (2015) resaltan la variabilidad del contenido de carbohidratos en los vegetales y que estos se representan en formas como almidón, pectina, celulosa, monosacáridos y disacáridos. La sacarosa suele ser abundante en vegetales no maduros, pero su cantidad disminuye con la maduración, siendo reemplazada por glucosa y fructosa. En la Tabla 22 se exhiben los contenidos de monosacáridos y disacáridos, variando entre 0.26 y 4.08 g/100g para los primeros y de 0.01 a 4.41 g/100 para los segundos.

Muir *et al.* (2009) determinó el contenido de monosacáridos (glucosa y fructosa), disacáridos (sacarosa, maltosa y lactosa), polioles (sorbitol y manitol), GOS (rafinosa y estaquiosa) y FOS (nistosa y kestosa) en cuarenta y cinco vegetales.

El contenido de fructosa osciló entre 0.15 y 3.23 g/100 g, y el de glucosa varió de 0.21 a 4.66 g/100g. La presencia de sacarosa y maltosa no fueron reportadas y se menciona que la lactosa no es relevante en vegetales debido a su ausencia natural, lo cual concuerda con Shanmugavelan *et al.* (2013), quienes informaron contenidos de azúcares en doce vegetales, obteniendo valores de sacarosa entre 2.03 a 20.09 g/100 g, fructosa entre 2.16 a 27.74 g/100 g y glucosa de 1.94 a 31.18 g/100 g. Asimismo, Gil (2010) señala que el contenido de carbohidratos constituye del 3 a 20% de la composición total de los vegetales.

En la Tabla 22 se presenta la variabilidad en el contenido de ácido ascórbico, que abarca desde 0.002 hasta 0.1 g/100 g. Andarwulan *et al.* (2012) investigaron el contenido de ácido ascórbico de vegetales asiáticos, registrando valores que oscilaron entre 0.01203 y 0.4943 g/100 g. En comparación, los vegetales occidentales típicos como la espinaca (0.028 g/100g), la lechuga de hoja verde (0.0092 g/100 g) y la lechuga iceberg (0.0028 g/100 g) mostraron contenidos menores de ácido ascórbico.

El ácido ascórbico es un compuesto orgánico característico del metabolismo celular; junto a otros ácidos orgánicos, desempeña un papel crucial en los procesos biológicos al estar involucrado en diversas vías esenciales para el metabolismo y catabolismo de plantas. Actúa como producto intermedio o final en estas vías, desempeñando un papel fundamental en el ciclo del ácido cítrico, también conocido como ciclo de Krebs (Priecina y Karklina, 2015).

Cheung y Mehta (2015) explican que la presencia de ácido ascórbico en las plantas está influenciada por su desarrollo y maduración, y desde una perspectiva química, es afectada por la actividad de la enzima ascorbato (metaloenzima que contiene cobre).

Esta enzima oxida el ácido ascórbico, convirtiéndolo en ácido dehidroascórbico y disminuyendo su actividad vitamínica. Eso lleva una relación inversamente proporcional, donde los vegetales con presencia de ascorbato oxidasa, como pepinos, calabacines y zanahorias presentan menor contenido de ácido ascórbico. Por otro lado, Gil (2010) informa que los pimientos (0.14 g/100 g), las coles de bruselas (0.087 g/100 g) y la coliflor (0.069 g/100 g) son ejemplos de vegetales con un alto contenido de este ácido orgánico, lo cual también se refleja en la Tabla 22. La fibra dietética total se clasifica en soluble e insoluble de acuerdo a su capacidad de disolución en el sistema digestivo humano. La fibra dietaria insoluble está mayormente compuesta por celulosa, mientras que las pectinas son las principales representantes de la fibra dietética soluble en frutas y verduras (Dunsin *et al.*, 2016).

En la Tabla 22 se observa una variación en el contenido de fibra que oscila entre 0.5 a 14.9 g/ 100g. Sinha (2011) destaca que los vegetales, especialmente las de hojas verdes, son fuentes ricas de fibra dietaria, como el caso de la alcachofa, el camote y el nabo con contenidos de 6.5, 4.1, 4.8 g/100 g respectivamente. En la Tabla 24 se realiza una comparación entre los contenidos de agua de 31 vegetales obtenidos de la base de datos de la USDA (2023) y los obtenidos de diversas fuentes literaturas. Es evidente que el contenido de agua reportado en la base de datos de la USDA (2023) presenta una variación que abarca desde 73.2 hasta 95.6%, mientras que los valores extraídos de diferentes literaturas varían de 72.8 a 96.0%.

Estos resultados se mantienen dentro del rango de humedad mencionado por Boonsupthip y Heldman (2007), quienes indicaron que más del 70% de humedad es considerado un alto contenido de agua para doscientos productos alimenticios. En relación a la diferencia absoluta ($DA \pm$) en los contenidos de agua, esta varió de 0 a 6.6 g/100g.

La Figura 14 presenta el contenido de minerales en 31 vegetales, extraídos de la base datos de la USDA (2023). Los valores de Na, Mg, Ca, P y K se encuentran en un rango de 1 a 80,

7 a 79, 2 a 120, 17 a 108 y 141 a 558 mg/ 100 g, respectivamente. Resulta evidente que el potasio es el mineral predominante en comparación con los otros minerales. Gil (2010) sostiene que los vegetales tienden a ser ricos en potasio, seguidos de calcio y magnesio, mientras que su contenido de sodio es bajo. Dunsin *et al.* (2016) en el estudio de siete vegetales reportaron la concentración de los macroelementos Na, Mg, Ca y K estos variando de 31 a 138, 43 a 147, 53 a 320 y 135 a 444 mg/100g respectivamente.




Figura 14: Contenido de minerales en alimentos vegetales

FUENTE: USDA (2023)

Tabla 22: Composición proximal de vegetales obtenida de la base de datos del Departamento de Agricultura de Estados Unidos

Vegetal	Agua (g)	Proteínas (g)	Lípidos (g)	Monosacáridos (g)	Disacáridos (g)	Fibra (g)	Na (g)	K (g)	Mg (g)	Ca (g)	P (g)	Ácidos orgánicos (g)
Aguacate crudo	73.200	2.000	0.147	0.490	0.160	6.700	0.007	0.485	0.029	0.012	0.052	0.010
Apio crudo	95.400	0.690	0.170	0.770	0.488	1.600	0.080	0.260	0.011	0.040	0.024	0.003
Berenjena cruda	92.300	0.980	0.180	3.120	0.260	3.000	0.002	0.229	0.014	0.014	0.024	0.002
Berro crudo	95.100	2.300	0.100	0.000	0.000	0.500	0.041	0.330	0.021	0.120	0.060	0.043
Brócoli crudo	90.000	2.570	0.340	1.400	0.010	2.400	0.036	0.303	0.021	0.046	0.067	0.091
Calabacín crudo con cáscara	94.800	1.210	0.320	2.450	0.050	1.000	0.008	0.261	0.018	0.016	0.038	0.043
Camote sin cáscara crudo	79.500	1.580	0.380	1.910	4.410	4.440	0.003	0.486	0.019	0.022	0.037	0.015
Camote sin cáscara crudo	77.300	1.570	0.050	1.660	2.520	3.000	0.055	0.337	0.025	0.030	0.047	0.002
Cebolla roja cruda	88.600	0.940	0.100	4.080	1.880	2.200	0.001	0.197	0.011	0.017	0.041	0.008
Cebolla roja cruda	88.600	0.940	0.100	4.080	1.880	2.200	0.001	0.197	0.011	0.017	0.041	0.008
Coles de Bruselas crudas	86.000	3.380	0.300	1.740	0.460	3.800	0.025	0.389	0.023	0.042	0.069	0.085
Espárrago crudo	93.200	2.200	0.120	0.750	0.230	2.100	0.002	0.202	0.014	0.024	0.052	0.006
Espárrago crudo	93.200	2.200	0.120	0.750	0.230	2.100	0.002	0.202	0.014	0.024	0.052	0.006
Espárrago crudo	93.200	2.200	0.120	0.750	0.230	2.100	0.002	0.229	0.014	0.014	0.024	0.006
Espinaca cruda	91.400	2.860	0.390	0.260	0.170	2.200	0.079	0.558	0.079	0.099	0.049	0.028
Espinaca cruda	91.400	2.860	0.390	0.260	0.170	2.200	0.079	0.558	0.079	0.099	0.049	0.028
Guisante verde crudo	78.800	5.420	0.400	0.510	0.670	5.700	0.005	0.244	0.033	0.025	0.108	0.040

<<Continuación >>

Lechuga iceberg cruda	95.600	0.900	0.140	1.910	0.050	1.200	0.010	0.141	0.007	0.019	0.020	0.003
Maíz amarillo crudo	76.000	3.220	1.180	0.000	0.000	2.700	0.015	0.270	0.037	0.002	0.089	0.043
Papa dorada sin cáscara cruda	81.100	1.810	0.260	0.520	0.630	13.800	0.002	0.446	0.022	0.006	0.057	0.023
Papa roja sin cáscara cruda	80.500	2.060	0.250	0.400	0.660	13.800	0.000	0.472	0.024	0.005	0.056	0.021
Papa rojiza sin cáscara	78.600	2.270	0.360	0.450	0.570	14.900	0.003	0.450	0.026	0.008	0.055	0.011
Pepino crudo con cáscara	95.200	0.650	0.110	1.630	0.040	0.500	0.002	0.147	0.013	0.016	0.024	0.003
Pimiento verde crudo	94.100	0.720	0.110	0.000	3.880	0.900	0.002	0.163	0.009	0.007	0.017	0.100
Puerro crudo	83.000	1.500	0.300	0.000	0.000	1.800	0.020	0.180	0.028	0.059	0.035	0.012
Rábano oriental crudo	94.600	0.600	0.100	1.760	0.100	1.600	0.021	0.227	0.016	0.027	0.023	0.022
Repollo crudo	92.200	1.280	0.100	3.120	0.090	2.500	0.018	0.170	0.012	0.040	0.026	0.037
Repollo crudo	92.200	1.280	0.100	3.120	0.090	2.500	0.018	0.170	0.012	0.040	0.026	0.037
Tomate maduro crudo	92.500	0.830	0.630	2.620	0.000	2.100	0.005	0.260	0.012	0.011	0.028	0.027
Tomate maduro crudo	92.500	0.830	0.630	2.620	0.000	2.100	0.005	0.260	0.012	0.011	0.028	0.027
Zanahoria bebé cruda	89.300	0.800	0.140	1.890	2.310	2.700	0.063	0.237	0.011	0.042	0.030	0.002

FUENTE: USDA (2023)

4.1. 2. PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (Tf)

Se empleó el modelo de predicción propuesto por Boonsupthip y Heldman (2007) para determinar la temperatura inicial de congelación (Tf).

A diferencia de otros modelos que se basan en la dependencia de propiedades termo-físicas para estimar un peso molecular promedio, este enfoque utiliza pesos moleculares para cada componente.

Gulati y Datta (2012), en su investigación sobre propiedades de alimentos, destacan que el modelo de Boonsupthip y Heldman (2007) ha demostrado ser exitoso y preciso en la determinación de la temperatura inicial de congelación.

En su modelo propuesto, Boonsupthip y Heldman (2007) introdujeron variaciones en la ley de Raoult modificada para soluciones binarias (Ec. 1), considerando la presencia de agua no congelable (Ec. 2). Este enfoque incorporó los pesos moleculares de cada componente (agua, proteína, lípidos, monosacáridos, disacáridos, fibra, Na, K, Mg, P y ácido ascórbico) en el modelo de predicción.

En la Tabla 23 se presenta los pesos moleculares de cada componente que se utilizaron para la predicción de la temperatura inicial de congelación de los 31 vegetales de la base de datos de la USDA (2023).

En la Figura 14, se destaca de manera evidente la marcada predominancia del potasio en la composición mineral de los vegetales, emergiendo como el mineral más predominante. Por otro lado, los otros minerales presentan una presencia más reducida. Boonsupthip *et al.* (2009) propone una aproximación interesante al sugerir el uso del peso molecular del potasio (39.10 g/mol) como un valor que representativo para todos los minerales, especialmente en situaciones en las que no se disponga de información detallada sobre ciertos minerales en la composición de los vegetales.

Tabla 23: Pesos moleculares de los componentes de los vegetales

Componente	Cantidad
Agua	18.02 g/ mol
Proteínas	50.00 kDa
Lípidos	50.00 kDa
Monosacáridos	180.07 g/ mol
Disacáridos	342.11 g/mol
Fibra	50.00 kDa
Na	22.90 g/mol
K	39.10 g/mol
Mg	24.31 g/mol
P	30.97 g/ mol
Ácido ascórbico	176.10 g/ mol

FUENTE: Boonsupthip y Heldman (2007)

Boonsupthip *et al.* (2009) señala que, en la categoría de frutas, los ácidos orgánicos más predominantes son el málico e iso-cítrico/cítrico. En esta categoría, sugiere que el peso molecular promedio del ácido isocítrico/cítrico (191.10 g/mol) y el ácido málico (134.1 g/mol) podrían representar de manera más adecuada el peso molecular de los ácidos orgánicos (163.10 g/mol). No obstante, en el caso de la composición de los 31 vegetales analizados a partir de la base de datos de la USDA (2023), el ácido ascórbico se destaca como el ácido orgánico de importancia nutricional en los vegetales. Por esta razón, en el presente trabajo se consideró el contenido y peso molecular del ácido ascórbico para realizar la predicción de la Tf.

En la Tabla 24 se puede apreciar que las temperaturas iniciales de congelación predichas utilizando el modelo de Boonsupthip y Heldman (2007), basado en los componentes listados en la Tabla 22, las Tfs variaron en un rango de -0.361 a -1.077 °C. Asimismo, las temperaturas iniciales de congelación obtenidas a partir de la literatura se ubicaron dentro del intervalo de -0.10 a -1.44 °C. Obteniendo un porcentaje de error promedio de 33.78 % y una diferencia absoluta promedio de 0.20 °C al comparar las temperaturas iniciales de congelación determinadas y recopiladas.

El análisis reveló un porcentaje de error promedio del 33.78%, una cifra que, aunque relativamente alta, se justifica por la amplia recopilación de datos de composición procedentes de 31 conjuntos diversos de vegetales. En ciertos casos, se repitieron entre una y tres veces determinados tipos de vegetales, generando así variabilidad en los conjuntos de datos y contribuyendo a las desviaciones observadas.

Es crucial enfatizar que la obtención de una cantidad más sustancial de información, particularmente al expandir los conjuntos de datos relacionados con la composición de un mismo vegetal, habría desempeñado un papel fundamental en la reducción de desviaciones y, por consiguiente, en la disminución del error en el análisis. La inclusión de datos adicionales habría permitido obtener una visión más robusta y precisa de la composición, mejorando de manera significativa la confiabilidad de los resultados.

Según Rahman (2009) las temperaturas iniciales de congelación de los alimentos tienden a ser más bajas que la del agua (0 °C) debido a la presencia de diversos componentes disueltos y su elevado contenido de humedad. Esta característica ocasiona que la temperatura inicial de congelación de los alimentos fluctúe entre 0 a -4 °C.

En la Figura 15 se representa una matriz de calor (Anexo 1) que establece la correlación entre la composición de los 31 vegetales extraídos de la base de datos de la USDA (2023) y las temperaturas iniciales de congelación Tf (°C) predichas. Los valores cercanos a -1 y 1 reflejan una correlación más fuerte, mientras que los valores próximos a 0 indican una correlación más débil.

Tabla 24: Comparación entre el contenido de agua y la temperatura inicial de congelación de vegetales, predichas por el modelo propuesto por Boonsupthip y Heldman (2007) y datos obtenidos de la literatura

Vegetal	Agua (g)		DA (\pm)	Tf ($^{\circ}$ C)		DA (\pm)	E (%)	Fuente
	USDA	Obtenido de la literatura		Obtenido de la literatura	Predicho			
Aguacate crudo	73.200	74.270	1.070	-0.300	-0.651	0.351	53.92	ASHRAE (2018)
Apio crudo	95.400	94.640	0.760	-0.500	-0.505	0.005	0.99	ASHRAE (2018)
Berenjena cruda	92.300	92.030	0.270	-0.800	-0.676	0.124	18.34	ASHRAE (2018)
Berro crudo	95.100	95.110	0.010	-0.300	-0.471	0.171	36.31	ASHRAE (2018)
Brócoli crudo	90.000	90.690	0.690	-0.600	-0.608	0.008	1.32	ASHRAE (2018)
Calabacín crudo con cáscara	94.800	94.200	0.600	-0.500	-0.613	0.113	18.43	ASHRAE (2018)
Camote sin cáscara crudo	79.500	72.840	6.660	-1.300	-1.077	0.223	20.71	ASHRAE (2018)
Camote sin preparar	77.300	72.840	4.460	-1.300	-0.907	0.393	43.33	ASHRAE (2018)
Cebolla roja cruda	88.600	89.680	1.080	-0.900	-0.906	0.006	0.66	Heldman y Lund (2007)
Cebolla roja cruda	88.600	85.500	3.100	-1.440	-0.906	0.534	58.94	ASHRAE (2018)
Coles de Bruselas crudas	86.000	86.000	0.000	-0.800	-0.742	0.058	7.82	ASHRAE (2018)
Espárrago crudo	93.200	92.400	0.800	-0.600	-0.413	0.187	45.28	ASHRAE (2018)
Espárrago crudo	93.200	92.600	0.600	-0.670	-0.413	0.257	62.23	Hsieh <i>et al.</i> (1977)
Espárrago crudo	93.200	92.600	0.600	-0.670	-0.413	0.257	62.23	Heldman y Lund (2007)
Espinaca cruda	91.400	91.580	0.180	-0.300	-0.709	0.409	57.69	Heldman y Lund (2007)
Espinaca cruda	91.400	90.200	1.200	-0.560	-0.709	0.149	21.02	ASHRAE (2018)
Guisante verde crudo	78.800	78.800	0.000	-0.600	-0.566	0.034	6.01	ASHRAE (2018)
Lechuga iceberg cruda	95.600	95.890	0.290	-0.200	-0.468	0.268	57.26	ASHRAE (2018)
Maíz amarillo crudo	76.000	75.960	0.040	-0.600	-0.458	0.142	31.00	ASHRAE (2018)
Papa dorada sin cáscara cruda	81.100	78.000	3.100	-0.700	-0.615	0.085	13.82	ASHRAE (2018)

<<Continuación >>

Papa roja sin cáscara cruda	80.500	77.000	3.500	-0.700	-0.619	0.081	13.09	ASHRAE (2018)
Papa rojiza sin cáscara	78.600	78.000	0.600	-0.700	-0.624	0.076	12.18	ASHRAE (2018)
Pepino crudo con cáscara	95.200	96.010	0.810	-0.500	-0.439	0.061	13.90	ASHRAE (2018)
Pimiento verde crudo	94.100	91.700	2.400	-0.100	-0.500	0.400	80.00	Rahman (2009)
Puerro crudo	83.000	83.000	0.000	-0.700	-0.361	0.339	93.91	ASHRAE (2018)
Rábano oriental crudo	94.600	94.840	0.240	-0.700	-0.526	0.174	33.08	ASHRAE (2018)
Repollo crudo	92.200	92.150	0.050	-0.900	-0.666	0.234	35.14	Rahman (2009)
Repollo crudo	92.200	92.400	0.200	-0.560	-0.666	0.106	15.92	ASHRAE (2018)
Tomate maduro crudo	92.500	93.000	0.500	-0.600	-0.623	0.023	3.69	Zhou (2016)
Tomate maduro crudo	92.500	94.520	2.020	-0.890	-0.623	0.267	42.86	ASHRAE (2018)
Zanahoria bebé cruda	89.300	87.790	1.510	-1.400	-0.752	0.648	86.17	Hsieh <i>et al.</i> (1977)

Se observa que ciertos componentes están más estrechamente correlacionados que otros. Específicamente, los disacáridos ($r = -0.6$), los monosacáridos ($r = -0.54$), el agua ($r = 0.32$) y los minerales ($r = 0.31$) muestran correlaciones más notables con las Tfs. En contraste, los componentes de mayor peso molecular como la fibra ($r = -0.14$), la proteína ($r = 0.086$) y los lípidos ($r = 0.064$) exhiben correlaciones más bajas con las Tfs. Curiosamente, los ácidos orgánicos, con el ácido ascórbico como representante, presentan la correlación más baja ($r = 0.055$). Este análisis bajo el modelo de Boonsupthip y Heldman (2007) resalta que los componentes de bajo peso molecular desempeñan un papel determinante a las temperaturas iniciales de congelación, mientras que los componentes de mayor peso molecular no ejercen un efecto significativo. Una posible explicación, de la baja correlación del contenido de ácido ascórbico con el Tf, se deba a que se ha considerado como ácido predominante en la ecuación propuesta por Boonsupthip y Heldman (2007) y no se consideró la suma de todos los ácidos orgánicos presentes en el alimento, debido a la falta de información en la base de datos utilizada.




Figura 15: Matriz de calor de la correlación existente entre variables de composición y la temperatura inicial de congelación

4. 1. 3. CARACTERIZACIÓN FÍSICO QUÍMICA Y PROXIMAL DE RAÍCES Y TUBÉRCULOS EN ESTUDIO

En la Tabla 25 se presenta la composición proximal obtenida de las raíces y tubérculos en estudio.

Tabla 25: Composición proximal obtenida de las raíces y tubérculos en estudio

Componentes	Arracacha	Maca	Olluco	Yacón	Mashua
Agua (g)	71.21 ± 0.02 ^b	69.27 ± 0.08 ^a	91.18 ± 0.09 ^e	85.35 ± 0.05 ^c	88.91 ± 0.03 ^d
Proteína (g)	0.83 ± 0.05 ^b	3.51 ± 0.04 ^d	1.13 ± 0.01 ^c	0.17 ± 0.00 ^a	1.13 ± 0.01 ^c
Lípidos (g)	0.27 ± 0.00 ^d	0.13 ± 0.01 ^b	0.19 ± 0.01 ^c	0.11 ± 0.01 ^a	0.19 ± 0.00 ^c
Monosacáridos (g)	0.53 ¹	0.68 ²	1.73 ³	3.85 ⁴	7.74 ⁵
Disacáridos (g)	0.99 ¹	12.30 ²	0.43 ³	1.54 ⁴	1.50 ⁵
Fibra (g)	0.66 ± 0.03 ^d	1.77 ± 0.01 ^c	0.11 ± 0.00 ^a	0.52 ± 0.03 ^c	0.43 ± 0.02 ^b
Calcio (mg)	118.00 ± 0.00 ^d	272.00 ± 0.00 ^e	35.02 ± 0.02 ^a	114.00 ± 0.02 ^c	77.00 ± 0.01 ^b
Fósforo (mg)	77.45 ± 0.05 ^d	151.50 ± 0.10 ^e	59.40 ± 0.14 ^b	49.90 ± 0.00 ^a	71.10 ± 0.28 ^c
Magnesio (mg)	13.55 ± 0.25 ^c	25.65 ± 0.55 ^e	9.80 ± 0.42 ^b	6.80 ± 0.00 ^a	17.45 ± 0.03 ^d
Potasio (mg)	427.80 ± 1.10 ^e	407.45 ± 1.74 ^d	126.95 ± 1.34 ^b	112.95 ± 0.21 ^a	171.55 ± 1.15 ^c
Vitamina C (mg)	18.87 ± 1.09 ^c	0.85 ± 0.06 ^a	16.33 ± 1.52 ^c	12.67 ± 0.67 ^b	68.66 ± 2.30 ^d

El contenido de monosacáridos y disacáridos fueron obtenidos de la literatura; los demás valores fueron determinados experimentalmente.

1. Mazon (1993)
2. Valentová *et al.* (2006)
3. Chuquilín *et al.* (2021)
4. El promedio de Choque *et al.* (2012) y Habib *et al.* (2011)
5. Pacheco *et al.* (2020)

a. AGUA

El contenido de agua en el olluco es el mayor entre las raíces y tubérculos en el estudio, registrando 91.18 ± 0.09 g/100g, ligeramente mayor que lo reportado por Márquez (2019) y Valcárcel-Yamani *et al.* (2013) con valores alrededor del 85%. Seguido de esto, el yacón

presenta un contenido de agua de 85.35 ± 0.05 g/100g, dentro de los rangos mencionados por Lachman (2003), Grau y Rea (1997), Manrique *et al.* (2004) y Reyes *et al.* (2017), que oscilan entre 70 y 93 g/100g. En cuanto a la arracacha, su contenido de agua se registró en 71.21 ± 0.02 g/100g, en concordancia con los informes de Palacios (2011) e ICBF (1992) para diversas variedades, que oscilan entre 71.34 y 74.5 g/100g. Rodas (1992) respalda estos hallazgos al reportar valores similares en diferentes regiones del mundo, situándose entre 71 y 75.1 g/100g. Posteriormente, la mashua exhibe un contenido de agua de 88.91 ± 0.03 g/100g, en consonancia con los valores reportados por Espín *et al.* (2001), Reyes *et al.* (2009), Valcárcel-Yamani *et al.* (2013), Salazar (2014), Cuya (2009) y Grau *et al.* (2003), que se encuentran entre 86 y 93.8 g/100g. Por último, en el caso de la maca, se registró un contenido de agua de 69.27 ± 0.08 g/100g, menor que lo informado por Reyes *et al.* (2017) con 79.8 g/100g. Este descenso podría estar relacionado con el proceso de deshidratación al que se somete la raíz fresca antes de su comercialización, llegando a superar el 80% según Wang y Zhu (2019).

Mohammad (2014) menciona que la estructura del agua, tanto en su estado líquido como sólido, se basa en interacciones de largo alcance, especialmente en enlaces de hidrógeno, y repulsiones de corto alcance. En el agua líquida, las moléculas forman una estructura tridimensional mediante enlaces de hidrógeno, dejando espacios vacíos entre ellas. Las interacciones de enlace puente de hidrógeno son cruciales para la formación de estructuras cristalinas en el hielo. Las raíces y tubérculos comprenden componentes, como proteínas, carbohidratos y lípidos, estos exhiben propiedades tanto hidrofílicas como hidrofóbicas. Por ejemplo, el agua estabiliza las estructuras proteicas al interactuar con sus grupos laterales. Las interacciones polar-hidrofóbico en soluciones acuosas afectan significativamente la cohesión y la interacción entre las moléculas, influyendo en propiedades claves (temperatura inicial de congelación). La formación de hielo depende de la naturaleza y concentración molar de las sustancias disueltas presentes, este proceso se desencadena después de cierto grado de sobre enfriamiento, y a medida que los productos se enfrían más allá de su punto de congelación inicial, más agua se convierte en hielo, haciendo que la solución se vuelva más concentrada.

b. PROTEÍNAS

El mayor porcentaje de proteína entre las raíces y tubérculos analizados fue encontrado en la maca (3.51 g/100g), este valor concuerda con lo reportado por Reyes *et al.* (2017); menores valores se han reportado en macas de diferentes colores (amarillas, blancas y moradas) (0.55 – 1.1 g/100g) de origen chino (Wang y Zhu, 2019). El menor contenido de proteína fue encontrado en las muestras de yacón (0.17 g/100g), este resultado fue mucho a lo reportado en anteriores estudios, donde se reporta valores mínimos de proteína de 0.3 y máximos de 4.9 g/ 100g (Manrique *et al.*, 2004; Reyes *et al.*, 2017). Esto podría deberse a diferencias en los métodos de análisis, la genética de las muestras utilizadas o las condiciones de cultivo, lo que puede influir en la variabilidad de los resultados obtenidos (Hermann *et al.*, 1999). Para el caso de la arracacha, se encontró un contenido proteico de 0.83 g/100g, dentro del rango informado previamente para esta raíz (Hermann, 1997; Palacios, 2011). Así como, el olluco y la mashua, los cuales presentaron un contenido de proteína de 1.13 g/100g, este valor fue comparable con investigaciones previas realizadas (Márquez, 2019; Valcárcel-Yamani *et al.*, 2013; Salazar, 2014).

c. LÍPIDOS

En el estudio, se encontró que la arracacha tiene un contenido de lípidos de 0.27 ± 0.00 g/100g, ubicándose en un rango similar a los valores reportados por Palacios (2011) e ICBF (1992) para diversas variedades, que oscilan entre 0.1 y 0.28 g/100g. Por otro lado, se observó una notable reducción en lípidos en las raíces de maca, con un contenido de 0.13 ± 0.01 g/100g, el cual es inferior al rango reportado para esta raíz (0.59 a 2.2%) (Wang y Zhu, 2019; Reyes *et al.*, 2017). El olluco mostró un contenido de lípidos de 0.19 ± 0.01 g/100 g, ligeramente mayor que lo informado por García (2021) (0.072 g/100g) y dentro del rango de los valores mencionados por Márquez (2019), que varían entre 0.12 y 0.15 g/100g. En el caso del yacón, se obtuvo un contenido de lípidos de 0.11 ± 0.01 g/100g, siendo menor en comparación con el rango presentado por diferentes autores (0.1 a 0.464 g/100 g) (Grau y Rea, 1997; Hermann *et al.*, 1999; Lachman *et al.*, 2003; Reyes *et al.*, 2017). Por último, para la mashua, se determinó un contenido de lípidos de 0.19 ± 0.00 g/100g, el cual es menor que los valores reportados por los autores debido a la variabilidad en composición entre diferentes variedades de mashua, que varían entre 0.084 y 0.9 g/100g (Espín *et al.*, 2001;

Reyes *et al.*, 2009; Valcárcel-Yamani *et al.*, 2013; Salazar, 2014; Cuya, 2009; Grau *et al.*, 2003).

d. MONOSACÁRIDOS Y DISACÁRIDOS

Se determinó experimentalmente el contenido de carbohidratos totales y en base a los porcentajes reportados en la literatura se determinaron los contenidos de monosacáridos y disacáridos en las raíces y tubérculos estudiados. En el caso de la maca, se estimó una presencia de aproximadamente 0.68 g/100g de monosacáridos (principalmente glucosa) y 12.3 g/100g de disacáridos (principalmente sacarosa) al utilizar los porcentajes proporcionados por Valentová *et al.* (2006). El contenido total de carbohidratos determinado fue de 25.9 g/100g (valor base para estimar el contenido de monosacáridos y disacáridos), notablemente superior al valor informado por Reyes *et al.* (2017) de 13.2 g/100g. Para la mashua, se obtuvo una estimación de 7.74 g/100g de monosacáridos (glucosa y fructosa) y 1.46 g/100g de disacáridos (sacarosa) utilizando los porcentajes reportados por Pacheco *et al.* (2020). El contenido total de carbohidratos determinado fue de 9.2 g/100g, en concordancia con los valores mencionados anteriormente que oscilan entre 6.32 y 13.1 g/100g. En el yacón, se estimaron 3.85 g/100g de monosacáridos (glucosa y fructosa) y 1.54 g/100g de disacáridos (sacarosa) utilizando los porcentajes proporcionados por Hermann *et al.* (1999), Lachman *et al.* (2003) y Reyes *et al.* (2017). El contenido total de carbohidratos determinado fue de 14 g/100g, en línea con los valores previamente informados que varían entre 9 y 13 g/100g. Para el olluco, se calculó una presencia de 1.73 g/100g de monosacáridos (glucosa y fructosa) y 0.43 g/100g de disacáridos (sacarosa) utilizando los porcentajes reportados por Chuquilín *et al.* (2021). El contenido total de carbohidratos determinado fue de 7.1 g/100g, menor que los valores reportados por Márquez (2019) y García (2021), que oscilan entre 11.87 y 17.24 g/100g. Finalmente, en el caso de la arracacha, se estimó una presencia de 0.53 g/100g de monosacáridos (principalmente glucosa) y 0.99 g/100g de disacáridos (principalmente sacarosa) utilizando los porcentajes proporcionados por Mazon (1993). El contenido total de carbohidratos determinado fue de 26.4 g/100g, situándose dentro del rango de valores reportados por Palacios (2011), ICBF (1992) y Rodas (1992), que varían entre 22.3 y 26.95 g/100g.

Al analizar el efecto de la congelación en monosacáridos y disacáridos, es esencial resaltar las operaciones previas que impactan la temperatura inicial de congelación. El blanqueado, diseñado para inactivar las enzimas vinculadas al pardeamiento enzimático, representa una de estas operaciones. Según Scher *et al.* (2009), durante este proceso, los alimentos son expuestos a temperaturas, por ejemplo, de 70 °C. En el caso particular del yacón, que contiene fructooligosacáridos (FOS), el blanqueado induce la hidrólisis de estos compuestos, resultando en un aumento de los azúcares reductores. Simultáneamente, se produce una pérdida de carbohidratos de bajo peso molecular (monosacáridos y disacáridos) en el agua de procesamiento.

Se determina que esta operación previa ejerce una influencia significativa en la temperatura inicial de congelación. La hidrólisis de los FOS impulsa un aumento en la concentración de azúcares, lo que puede disminuir la temperatura inicial de congelación al incrementar la presencia de solutos en el agua celular o elevar dicha temperatura debido a la lixiviación de carbohidratos hacia el agua del proceso.

e. FIBRA

Para la maca, el contenido de fibra de 1.77 ± 0.01 g/100g está notablemente por debajo de los valores reportados por Blanco *et al.* (2003) y Sifuentes *et al.* (2015) para la maca seca, que varían entre 3.35 y 9.08 g/100g. En cuanto al yacón, el contenido de fibra de 0.52 ± 0.03 g/100g se sitúa dentro del rango proporcionado por Grau y Rea (1997) de 0.3 a 1.7 g/100g y es inferior al valor indicado por Lachman *et al.* (2003) de 0.9 g/100g. En el caso de la mashua, el contenido de fibra de 0.43 ± 0.02 g/100g es ligeramente menor que los valores informados por varios autores, como Espín *et al.* (2001), Reyes *et al.* (2009) y Salazar (2014), que oscilan entre 0.67 y 0.9 g/100g. Para la arracacha, se registró un valor de 0.66 ± 0.03 g/100g, el cual se encuentra en el extremo inferior del rango reportado por Palacios (2011) e ICBF (1992) para las variedades amarilla, blanca y moradas, que oscila entre 0.7 y 1 g/100g. Por último, el olluco mostró un contenido de fibra de 0.11 ± 0.00 g/100g, una cantidad significativamente menor que los valores reportados por Márquez (2019), García (2021) y USDA (2023), que varían entre 0.47 y 0.9 g/100g.

f. MINERALES

Los resultados del análisis de minerales en las diferentes raíces y tubérculos muestran variaciones significativas en comparación con los rangos reportados por varios autores. En el caso de la arracacha, se encontraron niveles de calcio (118 ± 0.00 mg/100g), fósforo (77.45 ± 0.05 mg/100g), magnesio (13.55 ± 0.25 mg/100g) y potasio (427.80 ± 1.10 mg/100g) que superan los valores mencionados por Ventura (2007), especialmente en el caso del potasio, que es considerablemente mayor que el rango de 240.2 a 427.80 mg/100g mencionado por el autor.

Para la maca, se detectaron concentraciones de potasio (407.45 ± 1.74 mg/100g), calcio (272.0 ± 0.00 mg/100g), fósforo (151.50 ± 0.10 mg/100g) y magnesio (25.65 ± 0.55 mg/100g) en la raíz fresca, que difieren de manera significativa de los informados por Wang y Zhu (2019), especialmente en el caso del potasio, que supera ampliamente el rango de 549.4 a 806.4 mg/100g mencionado por los autores.

En cuanto al olluco, se observó un predominio de potasio (126.95 ± 1.34 mg/100g), seguido de fósforo (59.40 ± 0.14 mg/100g), calcio (35.02 ± 0.02 mg/100g) y magnesio (9.80 ± 0.42 mg/100g), con valores discordantes respecto a los proporcionados por Leterme *et al.* (2006), especialmente en el caso del potasio, que supera ampliamente el rango de 35 a 59.4 mg/100g mencionado por el autor. Por otro lado, en el yacón, se registraron mayores cantidades de calcio (114.00 ± 0.02 mg/100g), potasio (112.95 ± 0.21 mg/100g), fósforo (49.90 ± 0.00 mg/100g) y magnesio (6.80 ± 0.00 mg/100g), dentro de los rangos mencionados por Hermann *et al.* (1999), especialmente en el caso del calcio, que se encuentra en el límite superior del rango de 56 a 131 mg/100g mencionado por el autor.

Finalmente, en la mashua, se obtuvieron niveles elevados de potasio (171.55 ± 1.15 mg/100g), calcio (77.00 ± 0.01 mg/100g), fósforo (71.10 ± 0.28 mg/100g) y magnesio (17.45 ± 0.03 mg/100g), que difieren notablemente de los valores informados por Reyes *et al.* (2009) y Salazar (2014), especialmente en el caso del potasio, que supera ampliamente el rango de 77 a 170.95 mg/100g mencionado por los autores.

g. ÁCIDO ASCÓRBICO

En el presente estudio, se determinó el contenido de ácido ascórbico en diversas raíces y tubérculos. Comenzando por la mashua, se registró el valor más elevado con 68.66 ± 2.30 mg/100g. Aunque este resultado es ligeramente inferior a los informes de Espín *et al.* (2001), Reyes *et al.* (2009), Salazar (2014) y Grau *et al.* (2003), que oscilan entre 67 mg/100g y 77.50 mg/100g, demuestra la notable presencia de vitamina C en este tubérculo. En el caso del olluco, se obtuvo un valor de 16.33 ± 1.52 mg/100g, similar al reportado por García (2021) de 15.62 mg/100g, pero por debajo del valor proporcionado por Lescano (1994) de 26.03 mg/100g.

Para el yacón, se encontró una concentración de 12.67 ± 0.67 mg/100g, cercana al resultado obtenido por Grau y Rea (1997) de 13 mg/100g. En cuanto a la arracacha, se registró el contenido más bajo de ácido ascórbico con 18.87 ± 1.09 mg/100g, siendo ligeramente inferior a los valores reportados por Palacios (2011) para las variedades amarilla, blanca y morada, que oscilan entre 19.8 mg/100g y 26.46 mg/100g. Reyes *et al.* (2017) reporta 2.10 mg/100 g para el contenido de vitamina C en maca, siendo este resultado mayor al obtenido de 0.85 ± 0.06 , esta diferencia se puede deber a la variedad, estado de madurez de la raíz y condiciones en la medición de los autores.

Se evidenció una amplia variabilidad en la composición proximal de las raíces y tubérculos analizados. Los valores mínimos registrados fueron de 69.27 g de agua, 0.17 g de proteínas, 0.11 g de lípidos, 0.53 g de monosacáridos, 0.43 g de disacáridos, 0.11 g de fibra, 204.67 mg de minerales totales y 0.85 mg de ácidos orgánicos. En contraposición, se observaron valores máximos de 91.18 g de agua, 3.51 g de proteínas, 0.27 g de lípidos, 12.3 g de monosacáridos, 1.54 g de disacáridos, 1.7 g de fibra, 876.95 mg de minerales totales y 68.66 mg de ácidos orgánicos.

Estos resultados subrayan la considerable diversidad nutricional presente en estos alimentos. En los Anexos 2 al 5 se muestran los análisis estadísticos de la composición proximal, en los Anexos 6 al 9 de contenido de minerales y en el Anexo 10 del contenido de vitamina C.

En la Tabla 26 se presenta las propiedades fisicoquímicas de las raíces y tubérculos en estudio.

Tabla 26: Propiedades fisicoquímicas de raíces y tubérculos en estudio

Composición	Arracacha	Maca	Olluco	Yacón	Mashua
pH	6.25 ± 0.03^c	5.58 ± 0.04^b	6.68 ± 0.04^e	5.06 ± 0.01^a	6.39 ± 0.01^d
Acidez (% Ácido predominante)	$0.17 \pm 0.01(M)^a$	$0.60 \pm 0.01(S)^c$	$0.15 \pm 0.02(S)^b$	$0.12 \pm 0.03(C)^b$	$0.16 \pm 0.03(C)^b$
Sólidos solubles (°Brix)	6.30 ± 0.10^c	16.50 ± 0.1^e	5.03 ± 0.06^a	8.30 ± 0.17^d	5.80 ± 0.20^b

(M) Ácido málico.

(S) Ácido sulfúrico.

(C) Ácido cítrico.

h. PH

Rincón *et al.* (2021) investigaron la variación del pH en siete variedades de arracacha postcosecha, encontrando un rango de 5.2 a 6.9. Observaron un aumento inicial seguido de una disminución en los primeros ocho días. Vargas *et al.* (2017) respaldaron estos hallazgos, indicando que un pH más alto sugiere una maduración más rápida y una vida útil más corta. Otros estudios también reportaron valores similares, como García y Pacheco (2008) con pH de 6.6 y 6.5 para variedades amarilla y blanca, y Carmo y Leonel (2012) con 6.57 para variedad amarilla. Estos datos se asemejan a los obtenidos por Pacheco *et al.* (2020), quienes registraron un pH de 6.8. Todos estos resultados están cercanos al pH determinado para la arracacha, que fue de 6.25 ± 0.03 . Se determinó el pH de la maca, obteniendo un valor de 5.58 ± 0.04 , este resultado se encuentra en proximidad con los valores reportados por otros estudios, que oscilan entre 5.33 y 5.53 (Flores y León, 2006; BendeZú, 1992; Ponce, 1999). Pacheco (2014), Calderón y Peceros (2023) han reportado valores de pH próximos para el olluco fresco de 6.18 y deshidratado de 5.74 respectivamente. Aunque estas cifras resultan

superiores a las obtenidas por Yavar (2016) y García y Pacheco (2008) que fueron de 4.07 y 3.95 respectivamente. Es crucial resaltar que Aredo *et al.* (2012) han argumentado que esta variación se debe a diversos factores, como la variedad, condiciones edafológicas del suelo y el estadio de madurez. Se determinó el contenido de pH de 6.68 ± 0.04 , lo que muestra semejanza con los valores ya mencionados previamente. Se determinó el contenido de pH del yacón y se obtuvo como resultado 5.06 ± 0.01 , siendo estos valores menores a los obtenidos por Rojas (2015) y Chirinos (1999), donde obtuvieron valores de 6.1 y 6.54. El pH determinado para la mashua, 6.39 ± 0.01 , se encuentra en proximidad con los valores reportados por otros estudios: Samaniego (2010) con 5.56, Fernández y Martínez (2015) con 6.22 y Ortiz (2015) con 5.5.

i. ACIDEZ TITULABLE

La arracacha, según Rincón *et al.* (2021), presenta una acidez titulable de 0.13%, expresada en ácido málico, siendo este ácido el predominante. En contraste, Ruiz y Marcelo (2011) reportaron una acidez de 0.74%, sugiriendo la presencia de otros ácidos. En el caso de la maca, se determinó una acidez titulable de $0.6 \pm 0.01\%$ expresada en ácido sulfúrico. Sin embargo, este valor difiere considerablemente de los informados por Flores y León (2006), Bendezú (1992) y Ponce (1999), que fueron de 0.26, lo que sugiere variaciones en la composición ácida de la maca. Para el olluco deshidratado, Calderón y Peceros (2023) registraron una acidez de 0.27% expresada en ácido sulfúrico, también predominando este ácido, en contraposición al valor obtenido de $0.15 \pm 0.02\%$, que podría ser atribuido a diferencias en la naturaleza de la muestra. Rojas (2015) y Chirinos (1999) reportaron 0.35 % y 0.29 % en acidez titulable expresado en ácido cítrico para el yacón. Estos valores son ligeramente mayores al obtenido que fue de $0.12 \pm 0.03\%$. En el caso de la mashua, se obtuvo una acidez titulable de $0.16 \pm 0.03\%$ expresada en ácido cítrico, indicando que este ácido es el predominante en esta raíz, contrastando ligeramente con el valor reportado por Ortiz (2022) de 0.09% en ácido cítrico para la mashua.

j. °BRIX

Rincón *et al.* (2021) registraron un valor de 6.5 °Brix para la arracacha, cercano al obtenido que fue de 6.3 ± 0.1 °Brix. Pacheco *et al.* (2020) detallaron el contenido inicial de sólidos

solubles en la arracacha, señalando un 11% de sacarosa, 3.5 % de fructosa y un 3.7 % de glucosa, justificando su elevado contenido de sólidos solubles. También sugieren que la posible disminución futura en los valores de °Brix podría ser atribuible a degradaciones oxidativas posteriores de los azúcares y al consumo de sustratos durante el proceso de respiración. Flores y León (2006) obtuvieron 13 °Brix para la maca amarilla, similar al valor obtenido que fue de 16.5 ± 0.1 °Brix. En el caso del olluco, se registró 5.03 ± 0.06 °Brix, cercano al valor reportado por Pacheco (2014) que fue de 4.3 °Brix.

Para el yacón, se obtuvo 8.3 ± 0.17 °Brix, inferior a los valores reportados por Rojas (2015) y Chirinos (1999). Esto se explica por el contenido considerable de agua en el yacón, lo que tiende a reducir la cantidad de sólidos solubles. Samaniego (2010), Fernández y Martínez (2015) y Ortiz (2022) informaron valores de 6.61, 10.10 y 8 °Brix respectivamente para la mashua, mientras que el resultado obtenido de 5.8 ± 0.2 °Brix es relativamente menor en comparación con los valores previamente reportados.

Los análisis estadísticos para la determinación de las propiedades fisicoquímicas se encuentran en los Anexos del 11 al 13.

4.2. ETAPA II: ENTRENAMIENTO DE REDES NEURONALES CON VARIACIONES EN CAPAS, NEURONAS Y CONJUNTOS DE DATOS DE ENTRADA PARA PREDECIR LA TEMPERATURA INICIAL DE CONGELACIÓN.

4.2.1. ESCENARIO 1

a. DESARROLLO, ENTRENAMIENTO Y EVALUACIÓN DE UNA RED NEURONAL CON DIVERSAS CONFIGURACIONES DE CAPAS Y NEURONAS: 31 CONJUNTOS DE DATOS, 8 VALORES DE ENTRADA Y 1 VALOR DE SALIDA.

En la Tabla 27 se presentan las temperaturas iniciales de congelación (T_f) determinadas mediante el modelo de Boonsupthip y Heldman (2007), utilizando la composición extraída de 31 vegetales de la base de datos de la USDA (2023). También se muestran las temperaturas iniciales de congelación predichas por una red neuronal con diferentes números de capas y neuronas. En el Anexo 14 se observa los códigos utilizados.

Las capas utilizadas son 3, 5 y 9, mientras que las neuronas son 5, 10 y 20. Se utilizaron 8 variables de entrada (agua, proteínas, lípidos, monosacáridos, disacáridos, fibra, minerales totales y ácidos ascórbico) y como variable de salida la temperatura inicial de congelación. En total se muestran 9 configuraciones de redes neuronales.

En la Figura 16, se visualiza cómo el número de capas y neuronas influye en la capacidad de predicción de distintas configuraciones. Se evaluaron la raíz del error cuadrático medio (RMSE) y el coeficiente de determinación (R^2) para examinar la relación entre los valores predichos y los valores de entrenamiento. Se destaca que la configuración con 3 capas ocultas y 5 neuronas exhibió una raíz del error cuadrático medio de 0.02 °C, junto con un coeficiente de determinación de 0.99, acercándose notablemente a 1. Además, se observa que la configuración de 5 capas ocultas y 5 neuronas también demostró resultados favorables, generando valores de 0.05 °C y 0.93 para la raíz del error cuadrático medio y el coeficiente de determinación, respectivamente.




Figura 16: Evaluación del número de capas y neuronas con la red neuronal entrenada con 31 datos

Tabla 27: Predicción de Tf (°C) mediante redes neuronales profundas con diferentes números de capas y neuronas utilizando los 31 datos

Ítem	Tf predicho (°C)	Tf (°C) Red Neuronal (3x5)	Tf (°C) Red Neuronal (3x10)	Tf (°C) Red Neuronal (3x20)	Tf (°C) Red Neuronal (5x5)	Tf (°C) Red Neuronal (5x10)	Tf (°C) Red Neuronal (5x20)	Tf (°C) Red Neuronal (9x5)	Tf (°C) Red Neuronal (9x10)	Tf (°C) Red Neuronal (9x20)
1	-0.651	-0.625	-0.512	-0.517	-0.576	-0.598	-0.566	-0.459	-0.751	-88.956
2	-0.505	-0.483	-0.448	-0.446	-0.466	-0.474	-0.785	-0.544	-0.381	2381.107
3	-0.676	-0.686	-0.694	-0.694	-0.690	-0.673	-0.502	-0.708	-0.557	-2662.893
4	-0.471	-0.458	-0.414	-0.418	-0.423	-0.428	-0.421	-0.444	-0.626	3781.107
5	-0.608	-0.595	-0.602	-0.602	-0.599	-0.603	-0.291	-0.571	-0.703	-65.284
6	-0.613	-0.613	-0.616	-0.615	-0.621	-0.614	-0.451	-0.637	-0.509	-1245.237
7	-1.077	-1.059	-1.008	-1.005	-1.038	-1.035	-1.731	-0.983	-0.842	-1102.534
8	-0.907	-0.858	-0.773	-0.773	-0.812	-0.824	-1.153	-0.695	-0.841	-457.940
9	-0.906	-0.919	-0.922	-0.919	-0.916	-0.896	-0.882	-0.882	-0.727	-4118.018
10	-0.906	-0.919	-0.922	-0.919	-0.916	-0.896	-0.882	-0.882	-0.727	-4118.018
11	-0.742	-0.734	-0.737	-0.742	-0.730	-0.718	-0.278	-0.654	-0.924	-1185.862
12	-0.413	-0.431	-0.490	-0.492	-0.446	-0.445	-0.347	-0.471	-0.591	2347.123
13	-0.413	-0.431	-0.490	-0.492	-0.446	-0.445	-0.347	-0.471	-0.591	2347.123
14	-0.413	-0.431	-0.490	-0.492	-0.446	-0.445	-0.347	-0.471	-0.591	2347.123
15	-0.709	-0.676	-0.547	-0.562	-0.614	-0.589	-0.526	-0.588	-0.772	1824.169
16	-0.709	-0.676	-0.547	-0.562	-0.614	-0.589	-0.526	-0.588	-0.772	1824.169

<<Continuación >>

17	-0.566	-0.604	-0.729	-0.744	-0.650	-0.630	0.066	-0.500	-1.139	473.341
18	-0.468	-0.472	-0.514	-0.511	-0.489	-0.490	-0.455	-0.539	-0.419	427.638
19	-0.458	-0.478	-0.512	-0.522	-0.542	-0.555	-0.260	-0.367	-0.584	67.740
20	-0.615	-0.616	-0.621	-0.618	-0.620	-0.627	-0.787	-0.723	-0.595	-527.112
21	-0.619	-0.622	-0.625	-0.624	-0.623	-0.628	-0.760	-0.715	-0.640	-343.018
22	-0.624	-0.627	-0.646	-0.647	-0.641	-0.641	-0.702	-0.721	-0.650	-966.487
23	-0.439	-0.439	-0.462	-0.457	-0.448	-0.458	-0.510	-0.494	-0.377	1094.982
24	-0.500	-0.537	-0.639	-0.611	-0.572	-0.632	-1.617	-0.700	-0.413	5256.982
25	-0.361	-0.373	-0.357	-0.356	-0.376	-0.410	-0.485	-0.313	-0.466	2533.326
26	-0.526	-0.517	-0.503	-0.498	-0.509	-0.518	-0.595	-0.564	-0.415	475.091
27	-0.666	-0.667	-0.687	-0.685	-0.672	-0.664	-0.374	-0.675	-0.613	-2512.393
28	-0.666	-0.667	-0.687	-0.685	-0.672	-0.664	-0.374	-0.675	-0.613	-2512.393
29	-0.623	-0.625	-0.631	-0.631	-0.654	-0.645	-0.531	-0.668	-0.388	-2474.440
30	-0.623	-0.625	-0.631	-0.631	-0.654	-0.645	-0.531	-0.668	-0.388	-2474.440
31	-0.752	-0.756	-0.736	-0.731	-0.742	-0.744	-1.196	-0.770	-0.583	113.654

Rahman *et al.* (2012) trabajaron con diferentes modelos para determinar la conductividad térmica de los alimentos, donde utilizaron 676 conjunto de datos recopilados de 12 artículos científicos sobre 10 alimentos diferentes. Por otro lado, Sablani y Shayya (2002) abordaron la predicción del factor de fricción mediante redes neuronales y para su estudio generaron un conjunto de datos para el entrenamiento mediante procedimientos numéricos, basándose en 7240 datos. Mencionando las premisas de estas investigaciones anteriores, se encontró una analogía en la forma de trabajo con respecto a esta investigación. Así, mediante la recopilación de información sobre la composición de vegetales a partir de una base de datos, se logró determinar la temperatura inicial de congelación siguiendo el modelo propuesto por de Boonsupthip y Heldman (2007), lo que implica la generación de datos propios. Estos valores obtenidos fueron sometidos a validación comparativa con resultados de diferentes autores, que ya ha sido previamente reportada.

Mittal y Zhang (2000a) generaron diferentes configuraciones de redes neuronales para el estudio de la predicción de la temperatura y contenido de humedad en productos cárnicos durante su procesamiento. Generaron un conjunto 13500 datos, de los cuales eligieron aleatoriamente 1543 conjunto de prueba, 1416 conjuntos de producción y los 10541 conjunto de datos restantes fueron utilizados para el entrenamiento. Mittal y Zhang (2000b) para la predicción de la temperatura, humedad y grasa de alimentos con recubrimiento comestibles, donde dividieron sus datos en 20% para las pruebas, 20% para la validación y el 60% para el entrenamiento. Por su parte, Rahman *et al.* (2012) seccionaron los 676 conjuntos de datos recopilados en 338 conjuntos de datos para el entrenamiento, 169 conjuntos de datos para la prueba y el tercer conjunto de 169 de datos para la validación o producción.

En la presente investigación para las configuraciones de redes neuronales de ocho (nueve configuraciones) y cinco variables (nueve configuraciones) se entrenó la red con 31 conjunto de datos (en total dieciocho configuraciones), siguiente a este paso se realizó una validación con el coeficiente de determinación y la raíz del error cuadrático medio, para posteriormente determinar la temperatura inicial de congelación de raíces y tubérculos a través de su composición.

Durante la fase de selección de la configuración óptima en la construcción de una red neuronal destinada a predecir el factor de fricción, Sablani y Shayya (2002) llevaron a cabo

un análisis exhaustivo de diversas métricas. Su objetivo principal era identificar la configuración que minimizara diferentes tipos de errores, como el Error Relativo Medio (MRE) y el Error Absoluto Medio (MAE). Además, buscaron maximizar la precisión del modelo a través del coeficiente de determinación R^2 y prestaron atención a las desviaciones estándar de los errores.

En el presente trabajo, una configuración efectiva de la red neuronal se caracterizaría por reducir al mínimo los errores, en este caso representados por la Raíz del Error Cuadrático Medio (RMSE), y al mismo tiempo aumentar la precisión mediante el valor de R^2 . También se consideró fundamental que los errores fueran consistentes y no mostraran una variación significativa en magnitud, lo que se refiere a una "baja dispersión en los errores". Cabe destacar que la elección final de la configuración adecuada dependió de otros factores, como la búsqueda de una red neuronal que fuera simple y factible para el estudio en cuestión.

Es evidente que se sigue un patrón en la distribución de los conjuntos de datos. Según lo señalado por Sablani y Shayya (2002), este enfoque busca prevenir el fenómeno del sobreentrenamiento. Dicho fenómeno ocurre cuando un modelo se ajusta excesivamente a los datos de entrenamiento, llegando incluso a capturar el ruido presente en dichos datos, lo que conlleva a una pérdida de su habilidad para generar nuevos datos. Como contramedida, una estrategia ampliamente utilizada implica dividir el conjunto de datos en las secciones ya mencionadas, permitiendo así evitar esta problemática.

Otra medida para contrarrestar el sobreentrenamiento implica restringir el número de épocas utilizadas en el entrenamiento. En este sentido, para el proceso de entrenamiento se empleó 1000 épocas, en contraposición con los trabajos de Sablani y Shayya (2002), así como los de Mittal y Zhang (2000), quienes utilizaron un rango amplio de 500 a 150000 épocas en sus respectivos estudios. Al observar la Figura 17, se destaca que el modelo más óptimo de las nueve configuraciones iniciales logró su convergencia en menos de 100 capas. Como resultado, para evitar el sobreentrenamiento se implementó una tasa de aprendizaje. Es importante resaltar que, aunque no sea el caso, en escenarios donde las redes neuronales no presentan tendencias lineales, se torna esencial la utilización de funciones de activación adecuadas.

En sus investigaciones, Mittal y Zhang (2000a,b) exploraron el efecto de diferentes configuraciones de tasa de aprendizaje de 0.7 junto con un valor de momento o valor de ímpetu de 0.7, mientras que en otra instancia emplearon una tasa de aprendizaje de 0.7 junto con un valor de momento de 0.5.

Sablani y Shayya (2000, 2002) y Mittal y Zhang (2000a,b) han discutido que una tasa de aprendizaje alta resulta en un aprendizaje rápido, aunque puede causar fluctuaciones en los pesos, mientras que una tasa baja implica un aprendizaje más lento. Además, se ha señalado anteriormente que la introducción del valor de momento en la retro propagación tiene el propósito de evitar quedar atrapado en mínimos locales durante el proceso de entrenamiento, disminuyendo notablemente la cantidad de iteraciones requeridas para lograr la convergencia.

En el contexto de este estudio, no fue necesario experimentar con distintos valores de momento, ya que se empleó el optimizador Adam con un valor constante de 0.1. Cabe destacar que el optimizador Adam incluye la adaptación del momento o ímpetu como parte integral de su algoritmo, eliminando la necesidad de un ajuste adicional. Este optimizador de gradiente descendente estocástico ajusta automáticamente las tasas de aprendizaje para cada parámetro y, además, incorpora el concepto de momento en su funcionamiento (Rojano *et al.*, 2021).

En uno de sus objetivos, Guignon *et al.* (2008) realizaron un estudio que abordó la optimización de una red neuronal con el fin de predecir la temperatura inicial de congelación de alimentos en condiciones de alta presión. En su investigación, evaluaron un rango de 1 a 100 neuronas y determinaron que el mejor desempeño se lograba con 80 neuronas distribuidas en 6 capas ocultas. Esta estrategia se basó en dos variables de entrada y una salida constante. Donde obtuvieron coeficientes de determinación de 0.9518 para el conjunto de entrenamiento y 0.9428 para el conjunto de prueba. Siendo el coeficiente de determinación de la mejor configuración en el presente trabajo mayor a la obtenida por Guignon *et al.* (2008), con una menor cantidad de capas y neuronas.




Figura 17: Entrenamiento de la red neuronal con 1000 épocas (31 conjuntos de datos, 8 variables de entrada, 3 capas ocultas, 5 neuronas y 1 variable de salida)

Sablani y Shayya (2002) lograron mejoras notables en su desempeño al aplicar transformaciones logarítmicas a sus variables de entrada, lo que condujo a mejoras significativas en sus resultados. En sus hallazgos, señalan que la configuración más efectiva consiste en 12 neuronas y 2 capas ocultas, logrando una desviación estándar de 0.27%, un error del 0.19% y un coeficiente de determinación de 0.99.

Curiosamente, a pesar de estas cifras impresionantes, Sablani y Shayya (2002) optaron por la configuración más sencilla con solo una capa oculta y 6 neuronas, la cual arrojó un error del 0.91%, una desviación estándar del 0.92% y un coeficiente de determinación de 0.99. Esta elección se basó en su simplicidad de implementación y su rendimiento predictivo sólido. En consecuencia, se puede inferir que no es necesario emplear una red neuronal con un gran número de capas y neuronas, ya que en el presente trabajo la configuración con 3 capas y 5 neuronas demuestra ser la más eficiente en términos de predicción.

Resulta claro que a medida que se aumenta el número de capas y neuronas, la capacidad predictiva de la red neuronal tiende a alejarse de los valores de entrenamiento. Vale la pena destacar que en la Figura 16 no se muestra la configuración 9x20, dado que esta presentaba predicciones notoriamente divergentes, llegando incluso a valores extremadamente incoherentes.

4. 2. 2. ESCENARIO 2

a. REDUCCIÓN DE LOS VALORES DE ENTRADA EN LA PREDICCIÓN DE LA TF DE VEGETALES CON 31 CONJUNTO DE DATOS

En la Tabla 28 se presentan las temperaturas iniciales de congelación (Tf) determinadas mediante el modelo de Boonsupthip y Heldman (2007), utilizando la composición extraída de 31 vegetales de la base de datos de la USDA (2023). También se muestran las temperaturas iniciales de congelación pronosticadas por una red neuronal con diferentes números de capas y neuronas. Las capas utilizadas son 3, 5 y 9, mientras que las neuronas son 5, 10 y 20. Se redujeron los valores de entrada que inicialmente eran ocho a cinco siendo estas: el contenido de agua, monosacáridos, disacáridos, minerales totales y ácidos ascórbico y como variable de salida la temperatura inicial de congelación. La mejora en la precisión de la predicción se logra al reducir el rango de las variables de entrada, según la sugerencia de Mittal y Zhang (2000).

Hussain *et al.* (2001) llevaron a cabo un estudio sobre la formación de porosidad en diversos alimentos como lentejas, zanahorias, peras, batatas, ajo, calamares, apio y cebolla. Su enfoque consistió en desarrollar un modelo predictivo para esta propiedad, empleando distintas combinaciones de cuatro variables de entrada. Inicialmente, comenzaron con dos variables de entrada, luego incorporaron una tercera en otra configuración y finalmente llegaron a utilizar cuatro variables de entrada en total.

Durante el análisis, observaron que, al utilizar dos variables de entrada, el error fue del 56.5%. Sin embargo, al emplear tres variables, el error se redujo significativamente a un 0.98%, y con la inclusión de las cuatro variables, el error disminuyó aún más, llegando a un valor de 0.58%. A partir de estos resultados, llegaron a la conclusión de que la interacción entre estas variables mejoraba la capacidad predictiva del modelo. No obstante, también destacaron que no necesariamente una mayor cantidad de variables se traducían en una predicción más precisa. Esto se debía a que las variables mostraban una buena correlación entre sí, y concluyeron que añadir más variables carecería de utilidad si estas no presentaban una correlación sólida.

Tabla 28: Predicción de Tf (°C) mediante redes neuronales profundas con diferente número de capas y neuronas utilizando los 31 datos reduciendo las variables de entrada (sin proteínas, lípidos y fibra)

Ítem	Tf predicho (°C)	Tf (°C) Red Neuronal (3x5)	Tf (°C) Red Neuronal (3x10)	Tf (°C) Red Neuronal (3x20)	Tf (°C) Red Neuronal (5x5)	Tf (°C) Red Neuronal (5x10)	Tf (°C) Red Neuronal (5x20)	Tf (°C) Red Neuronal (9x5)	Tf (°C) Red Neuronal (9x10)	Tf (°C) Red Neuronal (9x20)
1	-0.65	-0.625	-0.588	-0.520	-0.654	-0.526	-0.702	-0.670	-0.671	-56.005
2	-0.50	-0.508	-0.505	-0.528	-0.480	-0.531	-0.463	-0.478	-0.462	60.660
3	-0.68	-0.685	-0.695	-0.701	-0.685	-0.635	-0.590	-0.680	-0.657	-195.254
4	-0.47	-0.483	-0.448	-0.488	-0.443	-0.443	-0.600	-0.456	-0.382	52.023
5	-0.61	-0.596	-0.586	-0.605	-0.600	-0.535	-0.761	-0.607	-0.566	-88.971
6	-0.61	-0.622	-0.628	-0.653	-0.616	-0.575	-0.629	-0.614	-0.576	-154.938
7	-1.08	-1.063	-1.022	-1.028	-1.052	-1.170	-1.142	-1.063	-1.062	412.280
8	-0.91	-0.860	-0.838	-0.804	-0.874	-0.895	-0.874	-0.881	-0.906	177.528
9	-0.91	-0.913	-0.923	-0.929	-0.921	-0.916	-0.828	-0.916	-0.910	-78.571
10	-0.91	-0.913	-0.923	-0.929	-0.921	-0.916	-0.828	-0.916	-0.910	-78.571
11	-0.74	-0.725	-0.691	-0.706	-0.728	-0.630	-0.930	-0.743	-0.674	-83.055
12	-0.41	-0.420	-0.454	-0.447	-0.420	-0.484	-0.304	-0.407	-0.464	32.027
13	-0.41	-0.420	-0.454	-0.447	-0.420	-0.484	-0.304	-0.407	-0.464	32.027
14	-0.41	-0.420	-0.454	-0.447	-0.420	-0.484	-0.304	-0.407	-0.464	32.027
15	-0.71	-0.713	-0.591	-0.653	-0.638	-0.522	-0.991	-0.682	-0.456	5.578
16	-0.71	-0.713	-0.591	-0.653	-0.638	-0.522	-0.991	-0.682	-0.456	5.578

<<Continuación >>

17	-0.57	-0.544	-0.559	-0.504	-0.583	-0.570	-0.565	-0.580	-0.661	50.837
18	-0.47	-0.471	-0.517	-0.517	-0.476	-0.516	-0.306	-0.457	-0.509	-85.836
19	-0.46	-0.445	-0.467	-0.389	-0.500	-0.454	-0.466	-0.495	-0.599	-1.336
20	-0.62	-0.606	-0.583	-0.553	-0.616	-0.574	-0.672	-0.625	-0.626	39.981
21	-0.62	-0.611	-0.583	-0.552	-0.619	-0.574	-0.686	-0.630	-0.626	51.005
22	-0.62	-0.607	-0.581	-0.537	-0.622	-0.565	-0.655	-0.632	-0.640	28.212
23	-0.44	-0.443	-0.491	-0.487	-0.449	-0.499	-0.277	-0.430	-0.491	-62.118
24	-0.50	-0.542	-0.633	-0.655	-0.558	-0.924	-0.513	-0.524	-0.733	618.875
25	-0.36	-0.368	-0.408	-0.347	-0.404	-0.427	-0.274	-0.391	-0.507	32.997
26	-0.53	-0.532	-0.550	-0.563	-0.527	-0.532	-0.473	-0.520	-0.521	-79.881
27	-0.67	-0.662	-0.683	-0.690	-0.675	-0.616	-0.621	-0.668	-0.657	-216.100
28	-0.67	-0.662	-0.683	-0.690	-0.675	-0.616	-0.621	-0.668	-0.657	-216.100
29	-0.62	-0.629	-0.639	-0.648	-0.632	-0.577	-0.595	-0.628	-0.605	-184.440
30	-0.62	-0.629	-0.639	-0.648	-0.632	-0.577	-0.595	-0.628	-0.605	-184.440
31	-0.75	-0.766	-0.767	-0.777	-0.754	-0.849	-0.710	-0.751	-0.768	182.164

Al reducir las variables de entrada (proteína, lípidos y fibra), se pudo observar que ciertas configuraciones aún eran capaces de predecir con precisión. De esto se puede inferir que estas variables no mantienen una correlación significativa con la temperatura inicial de congelación. Boonsupthip y Heldman (2007) explican que esto se debe a la metodología utilizada en su modelo para determinar la temperatura de congelación inicial (T_f , en °C), la cual se basa en los pesos moleculares. Resulta que todas estas biomoléculas tienen un peso superior de 50 kDa, un valor considerablemente mayor en comparación con las otras variables. Previamente se generó una matriz de calor donde también se apreció de que estas variables no guardaban una buena correlación entre sí y la variable de salida (T_f). Por lo tanto, se puede concluir que en futuras investigaciones enfocadas en determinar o predecir la temperatura inicial de congelación de los alimentos, es posible prescindir de la fase de recolección o evaluación de estas biomoléculas específicas (proteínas, lípidos y fibra) en el caso de vegetales.

b. EVALUACIÓN DE LA INFLUENCIA DEL NÚMERO DE CAPAS Y NEURONAS PARA AUMENTAR LA CAPACIDAD DE PREDICCIÓN DE LA RED NEURONAL ARTIFICIAL REDUCIENDO LAS VARIABLES DE ENTRADA (SIN PROTEÍNAS, LÍPIDOS Y FIBRA) CON 31 CONJUNTO DE DATOS.

En la Figura 18, se presentan las diversas configuraciones utilizadas para las redes neuronales. Se realizó una comparación entre los valores predichos y los valores de entrenamiento, evaluando su nivel de concordancia. Se destaca que las configuraciones con 3 capas y 5 neuronas, así como 9 capas y 5 neuronas, lograron una raíz del error cuadrático medio de 0.02 °C y un coeficiente de determinación de 0.99.

Además, se observaron resultados favorables en la configuración de 5 capas con 5 neuronas y 3 capas con 10 neuronas, con valores de raíz del error cuadrático medio de 0.03 °C y 0.06 °C respectivamente. Los coeficientes de determinación correspondientes fueron de 0.98 y 0.91 respectivamente, reforzando así la calidad de las predicciones obtenidas en estos casos. Cabe destacar que en la Figura 18 se omite la configuración 9x20 debido a que las predicciones generadas por esta configuración se alejaban considerablemente de los valores deseados. Esta omisión coincide con la sugerencia de Mittal y Zhang (2000), quienes señalan que, al restringir el rango de las variables de entrada, se logra un incremento en la precisión

de las predicciones. En este caso, obtuvieron que los errores promedio se redujeron de un rango de 0-1 a un rango de 0.05-0.95. Sablani y Shayya (2002) también concluyeron que la configuración más simple puede considerarse un buen predictor y es fácil de implementar para los usuarios.

En el mismo sentido, Sablani y Shayya (2002) indican que, aunque los modelos de redes neuronales no requieren un conocimiento previo profundo de las relaciones de entrada y salida, contar con cierta comprensión puede contribuir a ajustar el rendimiento. Tal como se ha mencionado previamente, la composición de los alimentos incorpora componentes que influyen directamente en la determinación o predicción de la temperatura inicial de congelación. En este contexto, poseer un conocimiento previo de estos aspectos podría conducir a un mejor rendimiento y a una optimización de los tiempos de predicción.




Figura 18: Evaluación del número de capas y neuronas con la red neuronal entrenada con 31 datos reduciendo las variables de entrada (sin proteínas, lípidos y fibra)

En las figuras 19a y 19b, se observa que ambas configuraciones comparten el mismo número de capas y neuronas (3x5), diferenciándose únicamente en la cantidad de variables de entrada: la figura 19a tiene ocho variables, mientras que la figura 19b tiene cinco. En ambas, se aprecia un sólido coeficiente de determinación que relaciona las temperaturas iniciales predichas con las temperaturas iniciales de entrenamiento. Este coeficiente ha sido una

herramienta crucial para evaluar el desempeño de la red, revelando que ambas configuraciones muestran un rendimiento destacado.

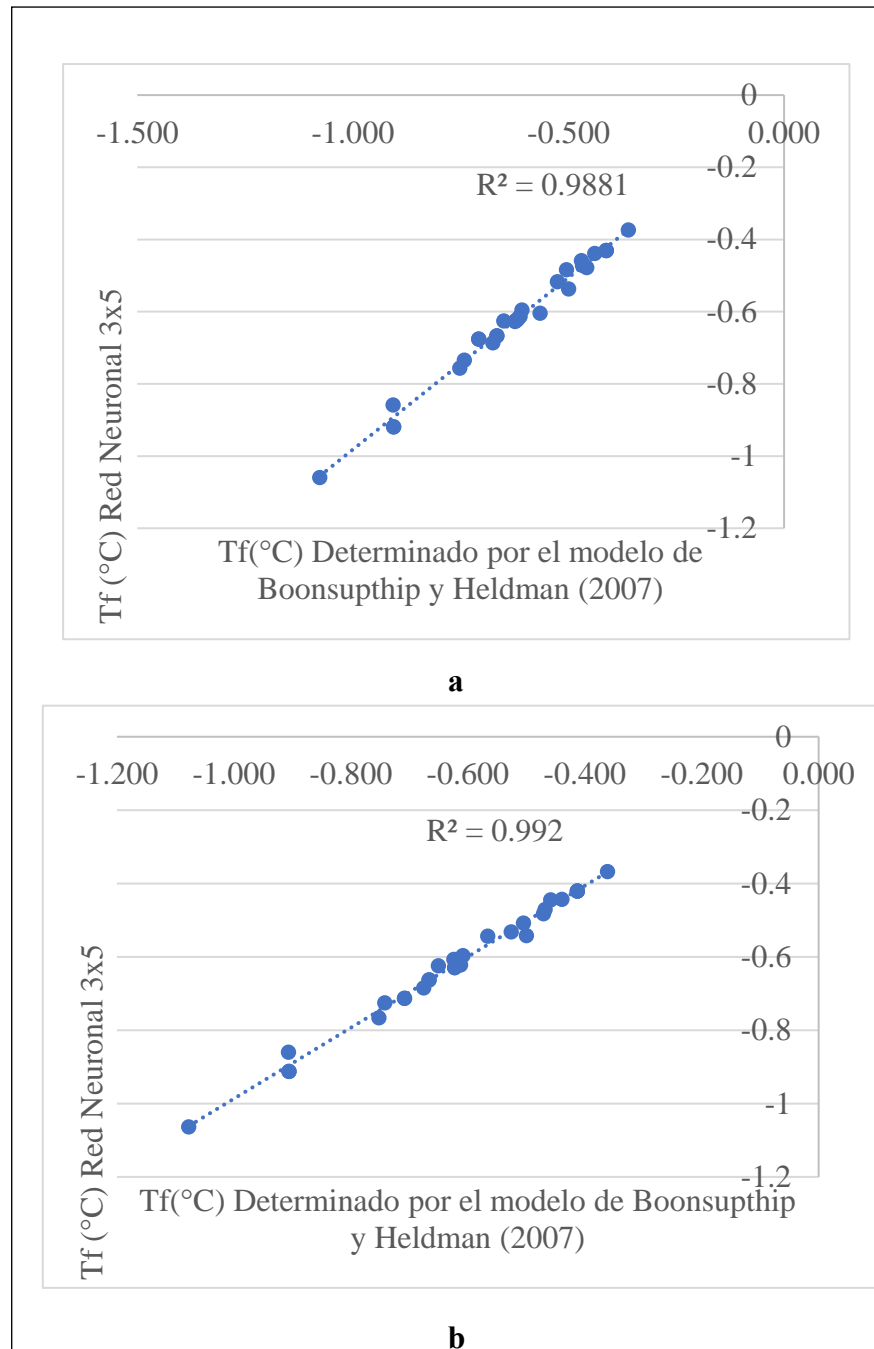


Figura 19: a) Correlación entre temperaturas iniciales de congelación con red neuronal (8 variables de entrada, 3 capas ocultas, 5 neuronas) entrenada con 31 datos vs. modelo de Boonsupthip y Heldman (2007). b) Correlación entre temperaturas iniciales de congelación con red neuronal (5 variables de entrada, 3 capas ocultas, 5 neuronas) entrenada con 31 datos vs. modelo de Boonsupthip y Heldman (2007)

4. 2. 3. ESCENARIO 3 Y 4

a. DESARROLLO Y EVALUACIÓN DE LA RED NEURONAL PARA PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN CON DIFERENTES CONFIGURACIONES DE CAPAS Y NEURONAS UTILIZANDO 6000 CONJUNTOS DE DATOS INICIALMENTE CON OCHO VARIABLES DE ENTRADA Y POSTERIOR REDUCCIÓN A CINCO.

Cuando los datos de entrada en un conjunto de producción alcanzan los límites, tienden a resultar en predicciones inexactas. Una estrategia efectiva para abordar el error, es aumentar los ejemplos en el conjunto de entrenamiento que se encuentran en los límites. Posteriormente, se procede a un nuevo ciclo de entrenamiento de la red neuronal para mejorar la precisión global de las predicciones (Mittal y Zhang, 2000).

Siguiendo lo expuesto, se generaron 6000 conjuntos de datos adicionales con el propósito de entrenar la red neuronal. Estos conjuntos de datos se conformaron utilizando los límites inferiores y superiores de la composición proximal determinados para las raíces y tubérculos. La ejecución de esta tarea se logró mediante el desarrollo de un código (Figura 8) específico para esta finalidad.

Esta estrategia abordó la discrepancia observada al comparar el uso de límites de composición basados en 31 vegetales, extraídos de la base de datos del USDA (2023). Dentro de la mencionada base de datos, a pesar de haber logrado resultados satisfactorios en la predicción de la temperatura inicial de congelación, se buscó explorar el impacto de la cantidad de variables de entrada en el rendimiento predictivo. Los conjuntos de datos adicionales se generaron considerando los valores mínimos y máximos de los componentes obtenidos de los análisis proximales. Esto se realizó debido a que estos rangos de valores resultaron ser más amplios en comparación con los valores extraídos de la base de datos del USDA (2023). Mittal y Zhang (2000) mencionan que esta es la mejor manera de evitar errores importantes ya que sin esos rangos la red no encontrará un patrón. También mencionan además de aumentar la presencia de datos, es bueno reducir las variables de entrada para que existan mejoras en la precisión.

Un ejemplo claro de esta diferencia se encuentra en el contenido de monosacáridos y disacáridos presentes en los tubérculos y raíces. En estas muestras, dichos contenidos variaron en un rango considerable, desde 0.53 hasta 7.74 g/100g y de 0.99 hasta 12.3 g/100g, respectivamente. En contraste, en el caso de los vegetales, los contenidos de monosacáridos oscilaron entre 0 y 4.080 g/100g, y los de disacáridos, entre 0 y 4.41 g/100g.

Con este enfoque, se generaron datos utilizando inicialmente ocho variables de entrada (agua, proteína, lípidos, monosacáridos, disacáridos, fibra, minerales totales y ácido ascórbico), así como con una versión reducida que contenía únicamente cinco variables (sin proteína, lípidos y fibra). A pesar de que en las Tablas 27 y 28 se proporcionan los valores pronosticados, no resultó factible presentar una tabla para exponer los 6000 conjuntos de datos anticipados debido a su amplia extensión. No obstante, en la Figura 8 previamente mencionada se encontrará el código utilizado para esta tarea. A través de la generación de estos 6000 conjuntos de datos (representando los valores de entrada), se determinaron las correspondientes temperaturas iniciales de congelación (valores de salida) utilizando el modelo desarrollado por Boonsupthip y Heldman (2007). Estas temperaturas se emplearon posteriormente para llevar a cabo una comparación detallada con las temperaturas iniciales predichas.

En la Figura 20 se expone la evaluación del número de capas y neuronas con la red neuronal entrenada con 6000 datos, tanto con ocho variables de entrada (Figura 20a) y con cinco variables de entrada (Figura 20b).

En la figura 20b, se llevó a cabo una evaluación exhaustiva de la influencia del número de capas y neuronas en un conjunto de 6000 conjuntos de datos. Estos datos se componían de cinco variables de entrada y una variable de salida, y el objetivo principal era determinar el nivel de predicción de diversas configuraciones.

Al analizar la figura, se destacan dos configuraciones específicas: la primera es la de 3 capas ocultas con 5 neuronas, y la segunda es la de 5 capas ocultas con 5 neuronas. Para ambas configuraciones, se lograron obtener valores de la raíz del error cuadrático medio de 0.06 °C y 0.15 °C respectivamente. Estos valores son notoriamente menores en comparación con la mejor configuración previamente obtenida, que involucraba ocho variables (0.33). Además,

ambas configuraciones exhibieron un coeficiente de determinación de 0.99, lo que refleja un alto grado de precisión en las predicciones realizadas.

Es importante destacar que estos resultados respaldan la noción de que una selección cuidadosa de las variables de entrada y la arquitectura de la red neuronal puede conducir a un mejor rendimiento predictivo. Este hallazgo se alinea con un estudio realizado por Batista *et al.* (2021), donde desarrollaron tres modelos de redes neuronales para predecir las características texturales y reológicas de los yogures. En su trabajo, lograron coeficientes de determinación que superaban 0.95, 0.99 y 0.99 para los tres modelos respectivamente, enfatizando así la importancia de identificar las variables de entrada más relevantes y su influencia en las respuestas obtenidas. Se adjunta en el Anexo 15, 16, 17 y 18 que muestra las arquitecturas de las redes neuronales de las mejores configuraciones.

Este análisis resalta la relevancia de una selección estratégica de variables y la configuración de la red en la construcción de modelos de redes neuronales altamente precisos, lo que puede tener implicaciones significativas en la optimización de la predicción de resultados en diversas aplicaciones.

Se puede apreciar en la Figura 20 a la influencia que tienen los números de capas ocultas y neuronas con el rendimiento de predicción de las diferentes configuraciones de redes neuronales. Donde se comparó la temperatura inicial de congelación entrenada con 6000 conjuntos de datos, ocho variables de entrada y una variable de salida, donde se obtuvo que la mejor configuración (3 capas ocultas y 5 neuronas) tuviera una raíz del error cuadrático medio de 0.33 °C y un coeficiente de determinación de 0.99. Se puede apreciar que se obtuvo buenos resultados con 3 capas ocultas, donde la configuración 3x20 y 3x10 obtuvieron raíces de los errores cuadráticos medios de 0.4 °C y 0.33 °C respectivamente y coeficientes de determinación de 0.95 y 0.71. Se puede apreciar que para las configuraciones con 5 capas ocultas y 9 capas ocultas (ya no se presentaron) las predicciones ya no guardan linealidad con respecto a los valores de entrenamiento, las gráficas que representen la linealidad de las configuraciones óptimas se pueden observar en la Figura 21.

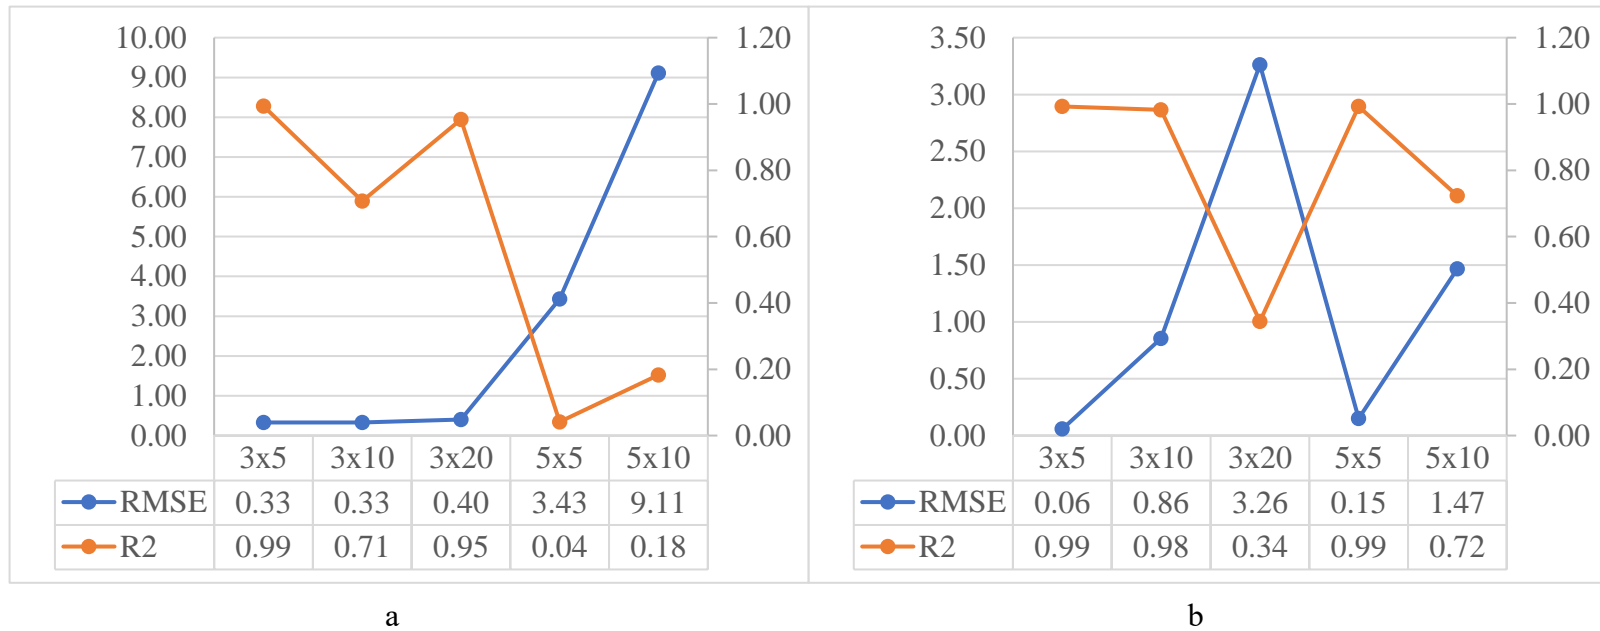


Figura 20: a) Evaluación del número de capas y neuronas con la red neuronal entrenada con 6000 datos. b) Evaluación del número de capas y neuronas con la red neuronal entrenada con 6000 datos reduciendo las variables de entrada (sin proteínas, lípidos y fibra)

En el estudio de Ohtman *et al.* (2023) sobre la detección de adulteraciones y defectos en alimentos mediante redes neuronales, se resalta la importancia del número de capas y neuronas en estas redes. Exploraron diversas arquitecturas con parámetros de entrada con notables disparidades, algunas hasta 18 veces mayores o menores que otros.

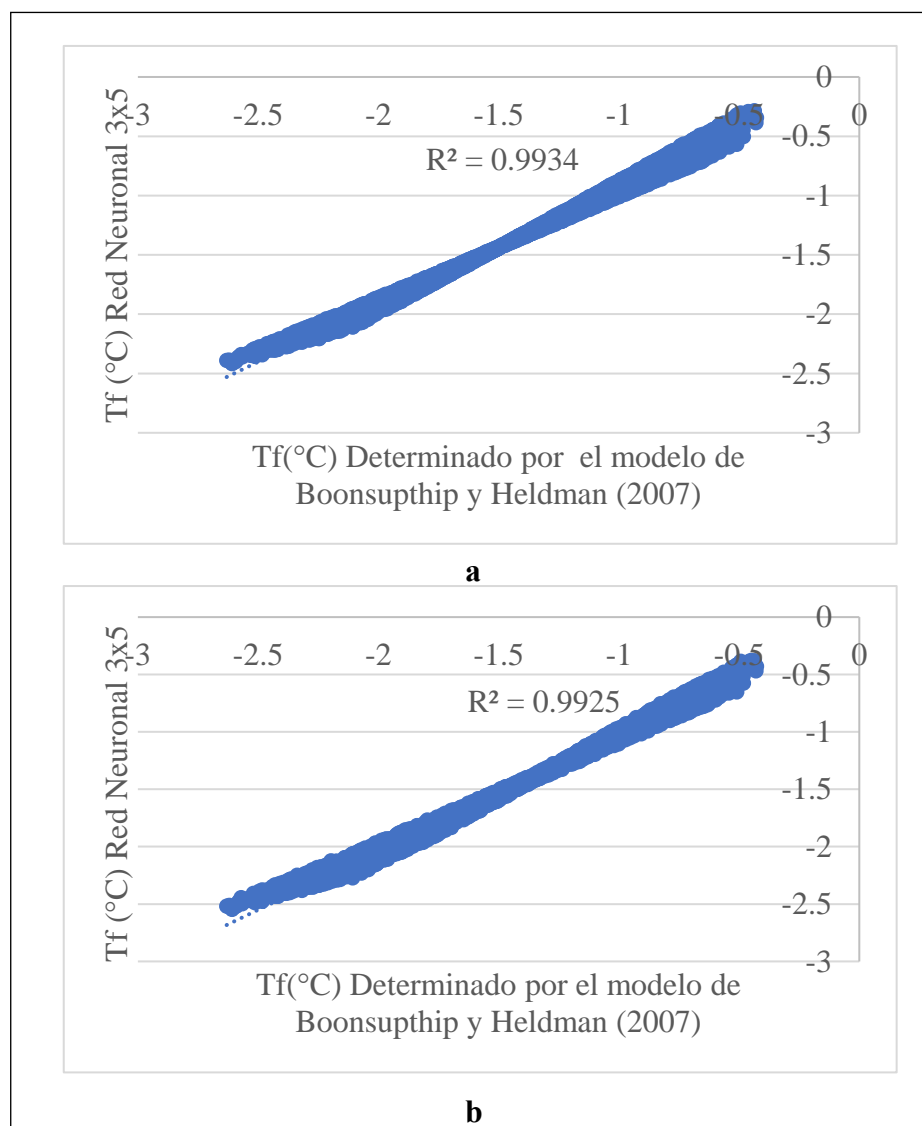


Figura 21: a) Correlación entre temperaturas iniciales de congelación con red neuronal (8 variables de entrada, 3 capas ocultas, 5 neuronas) entrenada con 6000 datos vs. modelo de Boonsupthip y Heldman (2007). b) Correlación entre temperaturas iniciales de congelación con red neuronal (5 variables de entrada, 3 capas ocultas, 5 neuronas) entrenada con 6000 datos vs. modelo de Boonsupthip y Heldman (2007)

A pesar de la preferencia general por parámetros básicos (medidas directas o simples) en lugar de derivados (calculados o generados), ya que los últimos a veces no mejoran significativamente el rendimiento, este estudio reveló hallazgos interesantes. Primero que la inclusión de un conjunto de 45 parámetros, que abarcaba tanto parámetros derivados como básicos, mejoró efectivamente la capacidad de la red.

Esto respalda la confiabilidad de los datos derivados en el entrenamiento de redes y valida la determinación de la temperatura inicial de congelación según el método de Boonsupthip y Heldman (2007), ya sea utilizando la base de datos de la USDA (2023) o generando 6000 datos adicionales. Es esencial resaltar que la elección de la cantidad de capas y neuronas es un proceso altamente dependiente de la naturaleza del análisis, la materia objeto de estudio y las propiedades físicas específicas que se están investigando. No se requiere una estructura de red neuronal con un gran número de capas y neuronas para alcanzar resultados precisos. Esto indica que la configuración óptima de una red neuronal puede variar ampliamente según la tarea y los datos particulares que se estén abordando, destacando la importancia de adaptar la arquitectura de la red a las necesidades específicas de cada aplicación.

4.3. ETAPA III: PREDICCIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN (TF) DE RAÍCES Y TUBÉRCULOS ANDINOS Y VALIDACIÓN DE LA RED NEURONAL ARTIFICIAL PROFUNDA

4.3.1. DETERMINACIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN DE DISOLUCIONES DE NaCl A DIFERENTES CONCENTRACIONES

La Tabla 29 presenta las temperaturas iniciales de congelación obtenidas mediante el método gráfico propuesto por Rahman *et al.* (2002). Se compararon con las determinaciones realizadas por Rahman (2009). Para concentraciones de 2, 4, 6 y 10 g/100g, se obtuvieron temperaturas iniciales de congelación de -1.23 ± 0.09 a -6.97 ± 0.03 °C. Rahman (2009) determinó la temperatura inicial de congelación para las mismas concentraciones de NaCl (2, 4, 6 y 10 g /100g), obteniendo valores cercanos a los de esta investigación, donde reportaron valores de -1.21 a -6.61 °C,

respectivamente. Es evidente que los valores obtenidos se asemejan a los reportados por Rahman (2009), con una diferencia absoluta promedio de 0.22 ± 0.15 °C y un porcentaje de error promedio de 5.33 %. Estos resultados respaldan la confiabilidad de las mediciones obtenidas y validan el funcionamiento de los sensores utilizados en este estudio.

Tabla 29: Temperatura inicial de congelación de NaCl a diferentes concentraciones

Concentración (g/100g)	Tf (°C)	Tf (°C) Rahman (2009)	DA (±)	E (%)
2	-1.23 ± 0.09	-1.21	0.02	1.63
4	-2.65 ± 0.05	-2.47	0.17	6.79
6	-4.02 ± 0.07	-3.71	0.31	7.71
10	-6.97 ± 0.03	-6.61	0.36	5.17

En la Figura 22, se destaca una tendencia evidente en la curva de calibración del NaCl, que se presenta en este estudio y la curva reportada por Rahman (2009).

Se puede apreciar claramente que, a medida que aumenta la concentración de NaCl, la temperatura inicial de congelación disminuye de manera progresiva.

Este fenómeno concuerda con las conclusiones obtenidas por Rahman (2009) en su estudio sobre la temperatura de congelación inicial en soluciones que contienen sacarosa y almidón.

Rahman (2009) señala que la concentración de solutos ejerce una influencia significativa en la temperatura de congelación inicial en estas soluciones.

Por ejemplo, Rahman (2009) observó que a medida que se incrementa la concentración de soluto, la temperatura inicial de congelación experimenta una disminución notable.

Para explicar el punto mencionado, cuando la concentración alcanza los 0.40 kg de sacarosa por kg de muestra, la temperatura inicial de congelación se sitúa en $-4.88\text{ }^{\circ}\text{C}$.

Estos resultados indican claramente que, a concentraciones más elevadas, se requieren temperaturas más bajas para lograr la congelación. Además, Rahman (2009) destaca que estos hallazgos concuerdan con los valores de referencia obtenidos en la literatura mediante otras técnicas, como el análisis de calorimetría diferencial de barrido (DSC).




Figura 22: Temperatura inicial de congelación del NaCl a diferentes concentraciones

4.3.2. COMPARACIÓN ENTRE LAS TEMPERATURAS INICIALES DE CONGELACIÓN DE RAÍCES Y TUBÉRCULOS PREDICHAS MEDIANTE LAS CONFIGURACIONES ÓPTIMAS DE LAS REDES NEURONALES Y AQUELLAS OBTENIDAS EXPERIMENTALMENTE

En la Figura 23 y 24 se aprecian las curvas de congelación y velocidad de congelación, que se utilizaron para determinar la temperatura inicial de congelación de las raíces y tubérculos en estudio. Donde la arracacha, maca, olluco, yacón y mashua, arrojaron resultados de -1.11 ± 0.03 , -2.03 ± 0.14 , -0.7 ± 0.05 , -1.37 ± 0.16 y -0.86 ± 0.02 °C, respectivamente. Los análisis estadísticos correspondientes a la determinación experimental de la temperatura inicial de congelación de las raíces y tubérculos se encuentran en el Anexo 19.

4.3.3. DETERMINACIÓN DE LA TEMPERATURA INICIAL DE CONGELACIÓN POR EL MODELO DE BOONSHUPTHIP Y HELDMAN (2007) Y PREDICHOS POR REDES NEURONALES

En la Tabla 30, se muestran las temperaturas iniciales de congelación obtenidas mediante el método gráfico propuesto por Rahman *et al.* (2012) para diferentes muestras, además se presentaron las predicciones generadas por las mejores configuraciones de la red neuronal utilizando ocho variables de entrada (agua, proteína, lípidos, monosacáridos, disacáridos, fibra, minerales totales y ácido ascórbico) y cinco variables de entrada tras la reducción de las biomoléculas de alto peso molecular. También se presentó la diferencia absoluta y porcentaje error entre la temperatura inicial de congelación experimental y con el determinado con el modelo de Boonsupthip y Heldman (2007).

En la Tabla 30, se observa que las temperaturas iniciales de congelación, según el modelo de Boonsupthip y Heldman (2007), presentan una diferencia absoluta de 0.43 ± 0.12 °C y 0.44 ± 0.17 °C al compararlas con los valores experimentales correspondientes a ocho y cinco variables de entrada, respectivamente. Aunque el porcentaje de error varía ligeramente, se evidencia que la diferencia absoluta aumenta ligeramente al reducirse el número de variables.

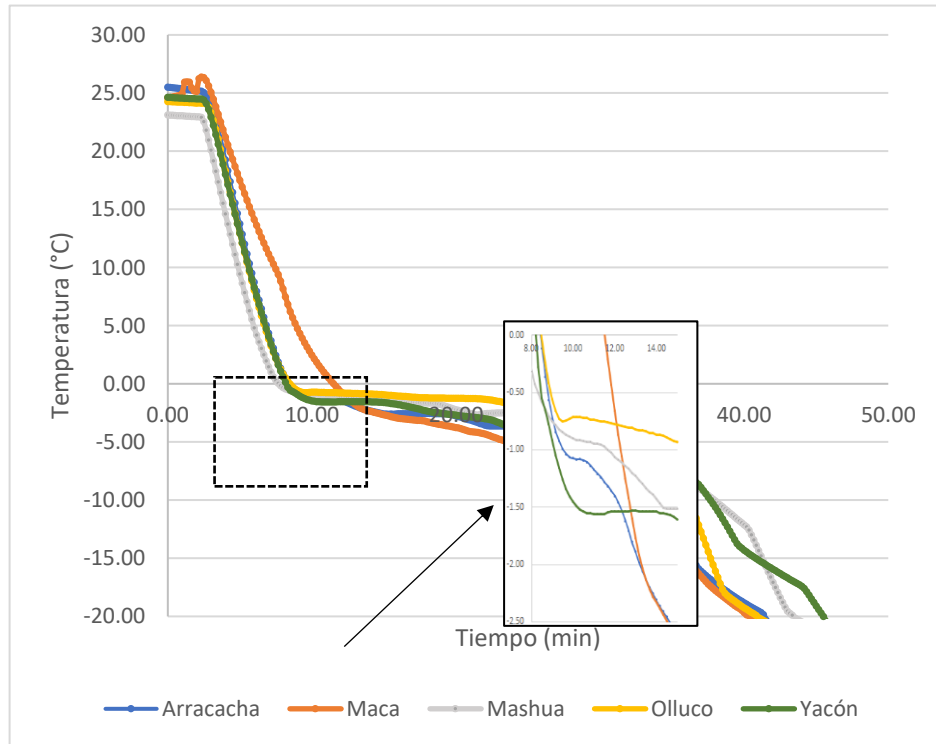


Figura 23: Curva de congelación de las raíces y tubérculos

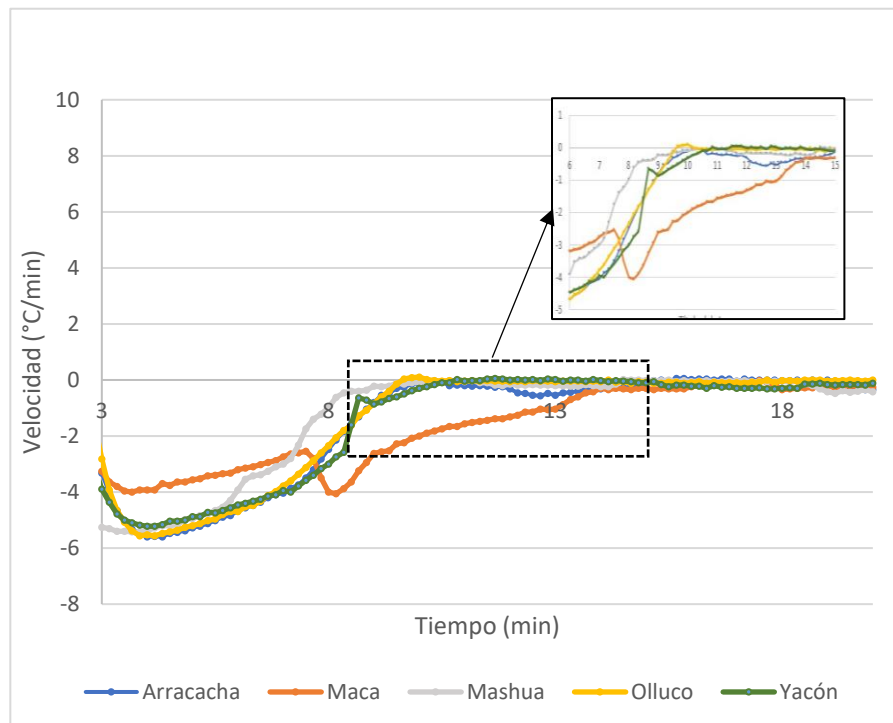


Figura 24: Velocidad de congelación de raíces y tubérculos

Esto sugiere que el modelo en cuestión requiere una mayor cantidad de datos para realizar de terminaciones más precisas.

Sin embargo, se destaca que el empleo de redes neuronales muestra una disminución tanto en el porcentaje de error como en la diferencia absoluta al reducir las variables de entrada.

Para la configuración que emplea ocho variables de entrada, tres capas ocultas y cinco neuronas, las predicciones de temperatura inicial de congelación variaron de -2.17 a -0.52 °C, respectivamente. En la validación de estos resultados, se obtuvo una diferencia absoluta promedio de 0.34 ± 0.17 °C y un porcentaje de error 32.23 %.

Para la configuración que emplea cinco variables de entrada, tres capas ocultas y cinco neuronas, las predicciones de temperatura inicial de congelación variaron de -2.17 a -0.51 °C. Donde al compararlas con las determinadas experimentalmente se obtuvo una diferencia absoluta promedio de 0.33 ± 0.16 °C y un porcentaje de error de 31.82 %.

El modelo semiempírico propuesto por Boonsupthip y Heldman (2007) evidencia limitaciones al abordar la composición de alimentos, manifestadas por un error del 31.82% en las predicciones. Este porcentaje indica variaciones sustanciales en la composición alimentaria, donde factores como la diversidad de productos y sus estados de madurez añaden complejidad al modelo.

Es esencial resaltar que la variabilidad en la composición de los alimentos incide directamente en la precisión del modelo propuesto. Para mejorar la exactitud de las predicciones, se sugiere explorar otros modelos que incorporen variables más controladas durante el entrenamiento de la red neuronal.

Guignon *et al.* (2008) respalda esta sugerencia al proponer un modelo con la inclusión de variables como la actividad del agua (aw) y la presión, brindando así mayor estabilidad y consistencia en los resultados. Aunque se haya observado una desviación estándar de 0.33 ± 0.16 °C, resulta imperativo evaluar su relevancia práctica en el ámbito industrial.

Tabla 30: Diferencia absoluta y porcentaje de error entre Tf (°C) experimental con Tf (°C) determinado por el modelo de Boonsupthip y Heldman (2007) y predichos por redes neuronales entrenada con 31 vegetales

Composición total								Reduciendo las variables (Sin proteína, lípidos y fibra)					
Raíces y Tubérculos	Tf (°C) Experimental	Tf (°C) Determinado por el modelo de Boonsupthip y Heldman (2007)	DA (°C)	E (%)	Tf (°C) Red Neuronal 3x5	DA (°C)	E (%)	Tf (°C) Determinado por el modelo de Boonsupthip y Heldman (2007)	DA (°C)	E (%)	Tf (°C) Red Neuronal 3x5	DA (°C)	E (%)
Arracacha	-1.11 ±0.03 ^c	-0.67	0.44	39.64	-0.70	0.41	36.94	-0.75	0.36	32.43	-0.73	0.38	34.23
Maca	-2.03 ±0.14 ^a	-2.50	0.47	23.15	-2.17	0.14	6.90	-2.70	0.67	33.00	-2.17	0.14	6.90
Olluco	-0.70 ±0.05 ^d	-0.48	0.22	31.43	-0.52	0.18	25.71	-0.50	0.2	28.57	-0.51	0.19	27.14
Yacón	-1.37 ±0.16 ^b	-0.82	0.55	40.15	-0.88	0.49	35.77	-0.88	0.49	35.77	-0.89	0.48	35.04
Mashua	-0.86 ±0.02 ^{cd}	-1.32	0.46	53.49	-1.34	0.48	55.81	-1.35	0.49	56.98	-1.34	0.48	55.81
Promedio	-	-	0.43 ± 0.12	37.60	-	0.34 ± 0.17	32.23	-	0.44 ± 0.17	37.35	-	0.33 ± 0.16	31.82

La temperatura de congelación (T_f) desempeña un papel crucial en la determinación del tiempo de congelación, y la variación mencionada se considera aceptable.

Desde una perspectiva industrial, esta variación no impactará de manera drástica en los tiempos de congelación. Por ende, se acepta que, a pesar del error mencionado, el uso del modelo semiempírico propuesto por Boonsupthip y Heldman (2007) sigue siendo válido para el entrenamiento de una red neuronal con el fin de determinar la temperatura inicial de congelación.

En el análisis experimental de sólidos solubles ($^{\circ}\text{Brix}$) realizado en las raíces y tubérculos de estudio, se destacó que la maca exhibió la mayor concentración, registrando un valor de $16.50 \pm 0.1^{\circ}\text{Brix}$, seguida por el yacón con $8.30 \pm 0.17^{\circ}\text{Brix}$. A continuación, se ubicaron la arracacha, mashua y olluco con niveles de 6.30 ± 0.10 , 5.80 ± 0.20 y 5.03 ± 0.06 , respectivamente.

Este hallazgo es de gran relevancia, ya que la maca exhibió la temperatura de congelación inicial más baja entre las muestras analizadas. Este fenómeno se atribuye a la influencia directa de la concentración de sólidos totales en la temperatura inicial de congelación de diversos alimentos.

Es decir, a medida que la concentración de sólidos totales en un alimento aumenta, su temperatura de inicial de congelación tiende a disminuir. Por lo tanto, al analizar el proceso de congelación de una solución o alimento, resulta esencial tener en cuenta el contenido de sólidos totales, como ha sido resaltado en investigaciones previas (Rahman, 2009).

Además, la concentración de solutos en el agua intracelular y extracelular de los alimentos también influye en la formación de cristales de hielo y la textura del alimento congelado. Un aumento en la concentración de solutos conduce a un punto de congelación más bajo, lo que a su vez puede afectar la calidad del producto. Por ejemplo, una mayor concentración de solutos puede causar cambios en el pH del alimento, lo que puede influir en su calidad (Evans, 2008).

En la Tabla 30, es evidente que las redes neuronales con una configuración de entrada de tres capas y cinco neuronas proporcionaron resultados de predicción satisfactorios. Además, se destaca que las diferencias absolutas entre ambas configuraciones son mínimas (con ocho y cinco variables de entrada).

Por lo tanto, si se busca realizar un análisis rápido de la temperatura de congelación inicial en raíces y tubérculos, es posible prescindir de la medición de proteínas, lípidos y fibra en los análisis proximales sin sacrificar significativamente la precisión de las predicciones.

En el estudio realizado por Ortiz (2022) estableció las temperaturas iniciales de congelación de varias raíces y tubérculos, datos esenciales para la evaluación de temperaturas iniciales determinadas experimentalmente. Esto permitió la comparación de los resultados, sirviendo como una forma de medir la capacidad predictiva de la red y validarlos mediante métodos comparativos.

Ortiz (2022) determinó experimentalmente la temperatura inicial de congelación del yacón, obteniendo un valor de -1.23 ± 0.15 °C. En contraste, en el presente trabajo se obtuvo experimentalmente un valor de -1.37 ± 0.16 °C para Tf, lo que resulta en una diferencia absoluta de 0.14 °C. Esta cercanía entre los datos validó la medición experimental realizada en este estudio.

En relación a la mashua, según el informe de Ortiz (2022), la temperatura inicial de congelación se registró en -0.7 ± 0.1 °C, mientras que en nuestro estudio experimental se obtuvo un valor de -0.86 ± 0.02 °C. Esta discrepancia arroja una diferencia absoluta de 0.17 °C. Es importante notar que esta diferencia es relativamente pequeña, lo que respalda la validez de nuestra medición.

En su investigación sobre la transferencia de calor durante el proceso de congelación, Salas *et al.* (2019) determinaron la temperatura inicial de congelación (Tf) del olluco, obteniendo un valor de -0.69 °C. Estos resultados revelan una notable similitud en el valor determinado experimentalmente que fue de -0.7 °C, lo que indica una consistencia y confiabilidad en los datos obtenidos ya que se obtuvo una diferencia absoluta de 0.01 °C.

En su investigación, López y Rodríguez (2013) determinó mediante experimentos una temperatura inicial de congelación para la arracacha de -0.4°C . Sin embargo, los resultados experimentales obtenidos indicaron una temperatura inicial de congelación de $-1.11 \pm 0.03^{\circ}\text{C}$. Esta discrepancia de 0.71°C podría atribuirse a factores como la variabilidad de la variedad y el grado de madurez, los cuales influyen en la composición de la arracacha.

Hasta el momento, la temperatura inicial de congelación de la maca ha sido poco explorada en investigaciones previas, lo que subraya la importancia de este estudio como punto de partida para futuras investigaciones en este campo.

En la Tabla 31, se presentan las temperaturas iniciales de congelación de las raíces y tubérculos en estudio, para las cuales se entrenaron dos configuraciones diferentes utilizando un conjunto de datos de 6000. Estas configuraciones destacan como las dos mejores entre las evaluadas. Una de ellas consta de ocho variables de entrada, que incluyen agua, proteínas, lípidos, monosacáridos, disacáridos, fibras, minerales totales y ácido ascórbico. La segunda configuración, en cambio, emplea solo cinco variables de entrada, reduciendo las dimensiones de proteínas, lípidos y fibra en comparación con la primera.

En la investigación realizada por Haiying *et al.* (2007) subrayaron la marcada influencia de la concentración de humedad en la temperatura inicial de congelación de los alimentos. Su estudio reveló que diferentes vegetales frescos exhiben variaciones en los niveles de humedad, lo que incide directamente en las temperaturas iniciales de congelación.

Los análisis de las raíces y tubérculos reflejaron valores de contenido de humedad que oscilaban entre el 69.27% y el 91.17%. Es notorio que la maca, siendo la raíz con el contenido de agua más bajo en el estudio, presentó la temperatura inicial de congelación más baja, mientras que el olluco, como el tubérculo con mayor humedad en el análisis, exhibió una temperatura inicial de congelación más cercana a 0°C .

Este hallazgo respalda la conclusión de que existe una relación inversamente proporcional entre el contenido de agua y la temperatura inicial de congelación en estos alimentos.

Tabla 31: Diferencia absoluta y porcentaje de error entre Tf (°C) experimental con Tf (°C) determinado por el modelo de y predichos por redes neuronales entrenada con 6000 datos

Composición total								Reduciendo las variables (Sin proteína, lípidos y fibra)					
Raíces y Tubérculos	Tf (°C) Experimental	Tf (°C) Determinado por el modelo de Boonsupthip y Heldman (2007)	DA (°C)	E (%)	Tf (°C) Red Neuronal 3x5	DA (°C)	E (%)	Tf (°C) Determinado por el modelo de Boonsupthip y Heldman (2007)	DA (°C)	E (%)	Tf (°C) Red Neuronal 3x5	DA (°C)	E (%)
Arracacha	-1.11 ±0.03 ^c	-0.67	0.44	39.64	-0.77	0.34	30.63	-0.75	0.36	32.43	-0.84	0.27	24.32
Maca	-2.03 ±0.14 ^a	-2.50	0.47	23.15	-2.46	0.43	21.18	-2.70	0.67	33.00	-2.6	0.57	28.08
Olluco	-0.70 ±0.05 ^d	-0.48	0.22	31.43	-0.31	0.39	55.71	-0.50	0.2	28.57	-0.42	0.28	40.00
Yacón	-1.37 ±0.16 ^b	-0.82	0.55	40.15	-0.79	0.58	42.34	-0.88	0.49	35.77	-0.91	0.46	33.58
Mashua	-0.86 ±0.02 ^{cd}	-1.32	0.46	53.49	-1.29	0.43	50.00	-1.35	0.49	56.98	-1.42	0.56	65.12
Promedio	-	-	0.43 ± 0.12	37.6	-	0.43 ± 0.08	39.97	-	0.44 ± 0.17	37.35	-	0.43 ± 0.15	38.22

Ambas configuraciones presentan tres capas de entrada con cinco neuronas cada una. Los resultados muestran que la configuración con ocho variables alcanza una diferencia absoluta promedio de 0.43 ± 0.08 , con un porcentaje de error de 37.35 %, mientras que la configuración con cinco variables obtiene una diferencia absoluta promedio de 0.43 ± 0.15 , con un porcentaje de error de 38.22 %. Esto indica que ambas configuraciones muestran un rendimiento de predicción similar.

Sun (2012) enfatiza la importancia de conocer los componentes específicos y sus pesos moleculares en la predicción de la temperatura inicial de congelación, así como en la relación entre la fracción de agua congelada y la temperatura. Este conocimiento se revela esencial para el diseño eficiente de procesos de congelación de alimentos, lo que puede impactar significativamente la calidad y eficiencia de la producción alimentaria.

En la observación de diferentes configuraciones de redes neuronales para predecir la temperatura inicial de congelación de raíces y tubérculos, se destaca que una configuración entrenada con tan solo 31 datos, utilizando cinco variables de entrada, tres capas ocultas y cinco neuronas (Anexo 20), presentó un rendimiento de predicción superior en comparación con otras configuraciones. Aunque las diferencias absolutas entre las cuatro mejores redes eran bastante cercanas entre sí, este hallazgo sugiere la posibilidad de desarrollar una red neuronal simple con un conjunto de datos de entrenamiento más reducido. Esto resulta ventajoso, dado que entrenar con 6000 conjuntos de datos requería un tiempo considerable en comparación con los 31 conjuntos de datos que se procesaban en tan solo 5 segundos. Al trabajar con las variables esenciales, se puede lograr un ahorro sustancial en tiempo y recursos en los análisis de composición de alimentos. En resumen, esta investigación subraya la viabilidad de utilizar enfoques más eficientes y económicos en la predicción de la temperatura inicial de congelación en el ámbito de la industria alimentaria.

V. CONCLUSIONES

1. Se desarrolló y entrenó una red neuronal profunda capaz de predecir la temperatura inicial de congelación de vegetales, utilizando datos de composición proximal y temperaturas de congelación previamente publicadas, la diferencia absoluta fue de 0.20 °C y el error porcentual promedio de 33.78 %.
2. Las redes entrenadas con 6000 conjunto de datos no mejoraron el rendimiento de las predicciones.
3. Se identificó que los disacáridos ($r = -0.6$), monosacáridos ($r = -0.54$), agua ($r = 0.32$) y minerales ($r = 0.31$), son los componentes significativos en la predicción de la temperatura inicial de congelación de los vegetales.
4. Se determinó la temperatura inicial de congelación de la arracacha (-1.11 °C), maca (-2.03 °C), olluco (-0.70 °C), yacón (-1.37 °C) y mashua (-0.86 °C). Se validó la red neuronal profunda compuesta por tres capas ocultas y cinco neuronas, entrenada con 31 conjuntos de datos y cinco variables de entrada. Se obtuvo una diferencia absoluta promedio de 0.33 ± 0.16 °C y un porcentaje de error del 31.82 %.

VI. RECOMENDACIONES

- Se sugiere complementar el análisis experimental de carbohidratos, que incluye la determinación de monosacáridos y disacáridos, con la utilización de técnicas adicionales como la Cromatografía Líquida de Alta Resolución (HPLC) u otras metodologías reconocidas. Esto permitirá una corroboración independiente de los porcentajes teóricos obtenidos a partir de la literatura, aumentando así la confianza en los valores obtenidos. Esta estrategia robustecerá la base de datos necesaria para la aplicación del modelo de Boonsupthip y Heldman (2007) en la determinación de la temperatura inicial de congelación.
- Se sugiere ampliar el estudio a otras variedades de tubérculos y raíces andinos para una comprensión más completa de sus propiedades termo físicas y contribuir así a la valorización y diversificación de estos cultivos.

VII. BIBLIOGRAFÍA

- Acervolima. (2022). Diferença entre TensorFlow e Keras – Acervo Lima. Recuperado de <https://acervolima.com/diferenca-entre-tensorflow-e-keras/>
- Acevedo, E., Serna A., A., & Serna M., E. (2017). Principios y características de las redes neuronales artificiales. En E. Serna M. (Ed.), Desarrollo e Innovación en Ingeniería: 2 Edición (pág. 173). ISBN 978-958-59127-5-5.
- Addanki, M., Patra, P., & Kandra, P. (2022). Recent advances and applications of artificial intelligence and related technologies in the food industry. *Applied Food Research*, 2(2), 100126. <https://doi.org/10.1016/j.afres.2022.100126>
- Agência Nacional de Vigilância Sanitária Alimentos. (ANVISA) (2005). Comissões e Grupos de Trabalho. Comissão Tecnocientífica de Assessoramento em Alimentos Funcionais e Novos Alimentos. Alimentos com Alegações de Propriedades Funcionais e ou de Saúde, Novos Alimentos/Ingredientes, Substâncias Bioativas e Probióticos. Brasil. Recuperado de <http://www.anvisa.gov.br/alimentos/comissoes/tecno.htm>
- Alberca, A. (2022). La librería NumPy. Aprende con Alf. Recuperado de <https://aprendeconalf.es/docencia/python/manual/numpy/>
- ALF (2022). Librería numpy. Recuperado de <https://aprendeconalf.es/docencia/python/manual/numpy/>
- Aliaga, R. (2004). "maca" (*Lepidium meyenii*). In: Seminario, J. (ed.) Raíces Andinas: Contribuciones al conocimiento y a la capacitación, 361-366.
- Andarwulan, N., Kurniasih, D., Apriady, R. A., Rahmat, H., Roto, A. V., & Bolling, B. W. (2012). Polyphenols, carotenoids, and ascorbic acid in underutilized medicinal vegetables. *Journal of Functional Foods*, 4(1), 339–347. <https://doi.org/10.1016/j.jff.2012.01.003>

- Aredo, V., Benites, C., Gerónimo, W., & Areteaga, A. (2012). Comparación entre el secado convectivo y osmoconvectivo en la pérdida de vitamina C de Aguaymanto (*Physalis peruviana*) con y sin pre-tratamiento de NaOH. *Agroind Science*, 1(1), 126-131. <https://doi.org/10.17268/agroind.science.2012.02.01>
- ASHRAE. (2018). 2018 ASHRAE Handbook - Refrigeration. Atlanta, GA, United States: American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc.
- Batista, L. F., Marques, C. S., Pires, A. C. dos S., Minim, L. A., Soares, N. de F. F., & Vidigal, M. C. T. R. (2021). Artificial neural networks modeling of non-fat yogurt texture properties: effect of process conditions and food composition. *Food and Bioprocess Processing*, 126, 164–174. <https://doi.org/10.1016/j.fbp.2021.01.002>
- Bendezú, Mayorga, Alicia. (1992). Elaboración de una Bebida a Partir de Maca (Tesis de pregrado, Universidad Nacional del Centro del Perú). Recuperado de <https://repositorio.uncp.edu.pe/bitstream/handle/20.500.12894/1867/FLORES%20C%C3%93RDOVA%20Jos%C3%A9%20Antonio%20Cleon%20machacuay.pdf?sequence=1&isAllowed=y>
- Boonsupthip, W., & Heldman, D. R. (2007). Prediction of frozen food properties during freezing using product composition. *Journal of Food Science*, 72(5), 254–263. <https://doi.org/10.1111/j.1750-3841.2007.00364.x>
- Boonsupthip, W., Sajjaanantakul, T., & Heldman, D. R. (2009). Use of Average Molecular Weights for Product Categories to Predict Freezing Characteristics of Foods. *Journal of Food Science*, 74(8), E417–E425. <https://doi.org/10.1111/j.1750-3841.2009.01309.x>
- Bridgman, P. W. (1912). Water, in the liquid form and five solid forms, under pressure. *Proc. Amer. Acad. Arts Sci.*, 47, 441–513.
- Bushaev, V. (2018). Stochastic gradient descent with momentum. *Towards Data Science*. Recuperado de <https://towardsdatascience.com/stochastic-gradient-descent-with-momentum-a84097641a5d>
- Calderón Huaman, C. A., & Peceros Sauñi, A. S. (2023). Valor nutricional, digestibilidad in vitro y características sensoriales de sopa deshidratada a base de champiñones y olluco

- (*Ollucus tuberosus*) (Tesis de pregrado, Universidad Nacional del Centro del Perú). Recuperado de <https://repositorio.uncp.edu.pe/handle/20.500.12894/8823>
- Canales, M., Aguilar, J., Prada, A., Marcelo, A., Huamán, C., & Carbajal, L. (2000). Evaluación nutricional de *Lepidium meyenii* (MACA) en ratones albinos y su descendencia. Archivos latinoamericanos de nutrición, 50(2), 126–133.
- Carmo, E. L. do, & Leonel, M. (2012). Composição físico-química e cor de clones de mandioquinha-salsa. Energia na Agricultura, 27(1), 62–81. <https://doi.org/10.17224/energagric.2012v27n1p62-81>
- Casas, J. (2020). Tuneando los hiperparámetros de una red neuronal LSTM para obtener un aprendizaje más eficiente. LinkedIn. Recuperado de <https://www.linkedin.com/pulse/tuneando-los-hiperpar%C3%A1metros-de-una-red-neuronal-lstm-casas-gonzalez/?originalSubdomain=es>
- Cerit, İ., Yildirim, A., Uçar, M. K., Demirkol, A., Coşansu Akdemir, S., & Demirkol, O. (2017). Estimation of antioxidant activity of foods using artificial neural networks. Journal of Food and Nutrition Research. <https://acikerisim.sakarya.edu.tr/handle/20.500.12619/64835>
- Chacón, J. (2022). Introducción a Pandas, la librería de Python para trabajar con datos. Profile Software Services. Recuperado de <https://profile.es/blog/pandas-python/>
- Chang, H. D., & Tao, L. C. (1981). Correlations of enthalpies of food systems. Journal of Food Science, 46(5), 1493–1497. <https://doi.org/10.1111/j.1365-2621.1981.tb04205.x>
- Chen, C. S., & Nagy, S. (1987). Prediction and correlation of freezing point depression of aqueous solutions. Transactions of the ASAE. American Society of Agricultural Engineers, 30(4), 1176–1180. <https://doi.org/10.13031/2013.30540>
- Chen, C. S., Nguyen, T. K., & Braddock, R. J. (1990). Relationship between freezing point depression and solute composition of fruit juice systems. Journal of Food Science, 55(2), 566–567. <https://doi.org/10.1111/j.1365-2621.1990.tb06815.x>
- Cheung, P. C. K., & Mehta, B. M. (Eds.). (2015). Handbook of Food Chemistry. Springer.

- Chirinos, R. (1999). Obtención y caracterización de los oligofructanos a partir de la raíz del yacón (*Smallanthus sonchifolius* Poepp. & Endl.) (Tesis de maestría, Universidad Nacional Agraria La Molina). Recuperado de <https://repositorio.lamolina.edu.pe/handle/>
- Choque Delgado, G. T., Thomé, R., Gabriel, D. L., Tamashiro, W. M. S. C., & Pastore, G. (2012). Yacon (*Smallanthus sonchifolius*)-derived fructooligosaccharides improves the immune parameters in the mouse. *Nutrition Research*, 32, 884–892.
- Chuquilín Goicochea, R. C., Martínez Laurente, M. C., & Rodrigo-Chumbes, J. T. (2020). Propiedades funcionales de productos tradicionales congelados y secados al sol de oca (*Oxalis tuberosa* Molina) y olluco (*Ullucus tuberosus* Caldas): Una revisión. *Puriq*, 2(3), 247–263. <https://doi.org/10.37073/puriq.2.3.100>
- Cronquist, A. (1981). An integrated system of classification of flowering plants. Columbia University Press, New York.
- Cuya, R. A. (2009). Efecto de secado en bandeja y atomización sobre la actividad antioxidante de la mashua (*Tropaeolum tuberosum* R&P) (Tesis de maestría, Universidad Nacional Agraria La Molina). Recuperado de <https://renati.sunedu.gob.pe/handle/sunedu/3014071>
- Dini, A., Migliuolo, G., Rastrelli, L., Saturnino, P., & Schettino, O. (1994). Chemical composition of *Lepidium meyenii*. *Food Chemistry*, 49(4), 347–349. [https://doi.org/10.1016/0308-8146\(94\)90003-5](https://doi.org/10.1016/0308-8146(94)90003-5)
- Dunsin, O., Aboyeji, C. M., Adekiya, A. O., Omolola, M., Agbaje, G., & Oluwaseun, A. (2016). Effect of Biochar and Npk Fertilizer on Growth, Biomass Yield and Nutritional Quality of Kale (*Brassica Oleracea*) in a Derived Agro-Ecological Zone of Nigeria. *PAT*, 12(2), 135-141. ISSN: 0794-5213.
- Esparza, E., Hadzich, A., Kofer, W., Mithöfer, A., & Cosio, E. G. (2015). Bioactive maca (*Lepidium meyenii*) alkalamides are a result of traditional Andean postharvest drying practices. *Phytochemistry*, 116, 138–148. <https://doi.org/10.1016/j.phytochem.2015.02.030>
- Espín, S. (2001). Composición química, valor nutricional y usos potenciales de siete especies de raíces y tubérculos andinos. *SENACYT-FUNDACYT*, 1, 63.

- Evans, J. A. (Ed.). (2008). Frozen food science and technology. Blackwell Publishing Ltd.
- Fernández, J., & Martínez A. (2015). Elaboración de papilla instantánea a base de oca (*Oxalis tuberosa*), mashua (*Tropaeolum tuberosum*) y leche descremada en polvo (Tesis de pregrado, Universidad Nacional “José Faustino Sánchez Carrión”). Recuperado de <https://repositorio.unjfsc.edu.pe/handle/20.500.14067/44>
- Flores Córdova, J. A., & León Machacuay, J. A. (2006). Determinación de parámetros óptimos en la elaboración de rodajas de maca (*Lepidium peruvianum Chacón*) en almíbar de mandarina (*Citrus reticulata*) utilizando envases de vidrio – Junín (Tesis de pregrado, Universidad Nacional del Centro del Perú). Recuperado de <https://repositorio.uncp.edu.pe/handle/20.500.12894/1867>
- García, A., & Pacheco Delahaye, E. (2008). Caracterización postcosecha del apio criollo cultivado en el municipio Tovar, estado Mérida - Venezuela. *Agronomía tropical*, 58(4), 409–416.
- García, E. (2021). Evaluación bromatológica del olluco silvestre (*Ullucus tuberosus* subsp. aborigineus) procedente del distrito de Ticrapo para su uso agroindustrial (Tesis de pregrado, Universidad Nacional de Huamanga). Recuperado de <https://repositorio.unh.edu.pe/items/5058828f-6f13-4987-9832-19e22de809ef>
- Gerón, A. (2019). Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. California.
- Gil, A. (2010). Tratado de nutrición. Editorial Médica Panamericana.
- Gonzales, G. F., Nieto, J., Rubio, J., & Gasco, M. (2006). Effect of Black maca (*Lepidium meyenii*) on one spermatogenic cycle in rats. *Andrologia*, 38(5), 166–172. <https://doi.org/10.1111/j.1439-0272.2006.00733.x>
- Goñi, S. M., Oddone, S., Segura, J. A., Mascheroni, R. H., & Salvadori, V. O. (2008). Prediction of foods freezing and thawing times: Artificial neural networks and genetic algorithm approach. *Journal of Food Engineering*, 84(1), 164–178. <https://doi.org/10.1016/j.jfoodeng.2007.05.006>
- Grau, A., & Rea, J. (1997). Yacon *Smallanthus sonchifolius* (Poepp. & Endl.) H. Robinson. In Ahipa, Arracacha, Maca and Yacon: Promoting the Conservation and Use of

- Underutilized Crops (pp. 199–256). Hermann, M., & Heller, J. (Eds.). IPK, Gatersleben/IPGRI, Rome, 174.
- Grau, A., Ortega Dueñas, R., Nieto Cabrera, C., & Hermann, M. (2003). Mashua (*Tropaeolum tuberosum* Ruiz & Pav.). Promoting the conservation and use of under-utilized and neglected crops. 25. International Potato Center, Lima, Peru/International Plant Genetic Resources Institute, Rome, Italy. 55 p.
- Guerra, A. (2014). Estudio de la utilización de la harina de mashua (*Tropaeolum tuberosum*) en la obtención del pan de molde (Tesis de pregrado, Universidad Tecnológica Equinoccial). Recuperado de https://repositorio.ute.edu.ec/bitstream/123456789/5061/1/55524_1.pdf
- Guignon, B., Torrecilla, J. S., Otero, L., Ramos, A. M., Molina-García, A. D., & Sanz, P. D. (2008). The initial freezing temperature of foods at high pressure. *Critical Reviews in Food Science and Nutrition*, 48(4), 328–340. <https://doi.org/10.1080/10408390701347736>
- Gulati T., Datta A.K. (2015). Mechanistic understanding of case-hardening and texture development during drying of food materials. *Journal of Food Engineering*, 166, 119–138. <https://doi.org/10.1016/j.jfoodeng.2015.05.031>
- Gupta, D. (2017). Fundamentals of deep learning-activation functions and when to use them? Analytics Vidhya. Recuperado de <https://www.analyticsvidhya.com/blog/2020/01/fundamentals-deep-learning-activation-functions-when-to-use-them/>
- Habib, N. C., Honoré, S. M., Genta, S. B., & Sánchez, S. S. (2011). Hypolipidemic effect of *Smallanthus sonchifolius* (yacon) roots on diabetic rats: biochemical approach. *Chem Biol Interact*, 194(Suppl 1), 31–39.
- Haiying, W., Shaozhi, Z., & Guangming, C. (2007). Experimental study on the freezing characteristics of four kinds of vegetables. *LWT-Food Science and Technology*, 40(6), 1112–1116.
- Heldman, D., & Lund, D. (Eds.). (2007). *Handbook of food engineering*. CRC Press.
- Hermann, M., & Heller, J. (Eds.). (1997). *Andean roots and tubers*. Leibniz Institute of Plant Genetics and Crop Plant Research, Germany; International Plant Genetic Resources

- Institute; Promoting the Conservation and Use of Underutilized and Neglected Crops n.21, 256 p. ISBN: 978-92-9043-351-4, ISBN: 92-9043-351-5
- Hermann, M., Freire, I., & Pazos, C. (1999). Compositional diversity of the yacon storage root. In Impact on a changing world: Program Report 1997–1998 (pp. 425–432). CIP, Lima, Peru.
- Hsieh, R.C., Lerew, L.E. and Heldman, D.R. 1977. Prediction of freezing times for foods as influenced by product properties. *Journal of Food Process Engineering*. 1, 183-197.
- Hussain, M. A., Shafiur Rahman, M., & Ng, C. W. (2002). Prediction of pores formation (porosity) in foods during drying: generic models by the use of hybrid neural network. *Journal of Food Engineering*, 51(3), 239–248. [https://doi.org/10.1016/s0260-8774\(01\)00063-2](https://doi.org/10.1016/s0260-8774(01)00063-2)
- Instituto Colombiano de Bienestar Familiar (ICBF). (1992). Tabla de composición de alimentos colombianos. Gov.co. Recuperado de https://www.icbf.gov.co/system/files/tcac_web.pdf
- Jamwal, A., Agrawal, R., & Sharma, M. (2022). Deep learning for manufacturing sustainability: Models, applications in Industry 4.0 and implications. *International Journal of Information Management Data Insights*, 2(2), 100107. <https://doi.org/10.1016/j.jjime.2022.100107>
- Jie, W., Lite, L., & Yang, D. (2003). The correlation between freezing point and soluble solids of fruits. *Journal of Food Engineering*, 60(4), 481–484. [https://doi.org/10.1016/s0260-8774\(03\)00081-5](https://doi.org/10.1016/s0260-8774(03)00081-5)
- Johns, T., Kitts, W. D., Newsome, F., & Towers, G. H. (1982). Anti-reproductive and other medicinal effects of *Tropaeolum tuberosum*. *Journal of Ethnopharmacology*, 5(2), 149–161. [https://doi.org/10.1016/0378-8741\(82\)90040-x](https://doi.org/10.1016/0378-8741(82)90040-x)
- KJÆR, A., ØGAARD MADSEN, J., & MAEDA, Y. (1978). Seed volatiles within the family Tropaeolaceae. *Phytochemistry*, 17, 1285-1287.
- Kechin, V. V. (2001). Melting curve equations at high pressure. *Physical review. B, Condensed matter*, 65(5). <https://doi.org/10.1103/physrevb.65.052102>

- King, S. R., & Gershoff, S. N. (1987). Nutritional evaluation of three underexploited Andean tubers: *Oxalis tuberosa* (Oxalidaceae), *Ullucus tuberosus* (Basellaceae), and *Tropaeolum tuberosum* (Tropaeolaceae). *Economic Botany*, 41(4), 503–511. <https://doi.org/10.1007/BF02908144>
- Lachman, J., Fernández, E.C. and Orsák, M. (2003) Yacon [*Smallanthus sonchifolia* (Poepp. et Endl.) H. Robinson] Chemical Composition and Use—A Review. *Plant Soil and Environment*, 49, 283-290.
- Lescano, J. (1994). Genética y mejoramiento de cultivos altoandinos. Programa interinstitucional de Waru. Proyecto Especial Binacional. Convenio INADE/PELT COTESU. La Paz.
- Leterme, P., Buldgen, A., Estrada, F., & Londoño, A. M. (2006). Mineral content of tropical fruits and unconventional foods of the Andes and the rain forest of Colombia. *Food Chemistry*, 95(4), 644–652. <https://doi.org/10.1016/j.foodchem.2005.02.003>
- Lobo AR, Colli C, Alvares EP, Filisetti TM (2007) Effects of fructans-containing yacon (*Smallanthus sonchifolius* Poepp & Endl.) flour on cecum mucosal morphometry, calcium and magnesium balance, and bone calcium retention in growing rats. *Br J Nutr* 97:776–785
- Long, L., & Zeng, X. (2022). *Beginning Deep Learning with TensorFlow*. <https://doi.org/10.1007/978-1-4842-7915-1>
- López Velasco, D. M., & Rodríguez Bautista, L. J. (2013). Evaluación del efecto de precocción sobre algunas propiedades de calidad en arracacha (*Arracacia xanthorrhiza*) almacenada en congelación (Tesis de pregrado, Universidad del Valle). Recuperado de <https://bibliotecadigital.univalle.edu.co/entities/publication/a0dfbb25-0625-4d34-a916-f7078352e5db>
- Manrique, I., Hermann, M. and Bernet, T. (2004). Yacon e fact Sheet. International Potato Center (CIP), Lima, Peru. Recuperado de www.cipotato.org/artc/cipcrops/factsheetyacon.pdf.
- Manrique, I., Parraga, A. and Hermann, M. (2005). Conservación y uso de la biodiversidad de raíces y tubérculos andinos: Una década de investigación para el desarrollo (1993–2003). *Yacon syrup: Principles and Processing*. Centro Internacional de La Papa, Lima.

- Matich, D. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. Documento de trabajo. Universidad Tecnológica Nacional. Recuperado de https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientador1/monografias/matich-redesneuronales.pdf
- Mazon Ortiz, N. (1993). Análisis de la variación morfológica e isoenzimática de la colección ecuatoriana de zanahoria blanca (*Arracacia xanthorrhiza Brancoft*) (Tesis de pregrado, Escuela Superior Politécnica de Chimborazo). Recuperado de <https://repositorio.iniap.gob.ec/handle/41000/538>
- Millán García, R. R. (2001). Obtención de una Confitura a Base de Arracacha (*Arracacia xanthorrhiza*) (Tesis de pregrado, Universidad Nacional Agraria La Molina). Recuperado de <https://repositorio.lamolina.edu.pe/handle/>
- Mittal, G. S., & Zhang, J. (2000a). Prediction of freezing time for food products using a neural network. Food Research International (Ottawa, Ont.), 33(7), 557–562. [https://doi.org/10.1016/s0963-9969\(00\)00091-0](https://doi.org/10.1016/s0963-9969(00)00091-0)
- Mittal, G. S., & Zhang, J. (2000b). Prediction of temperature and moisture content of frankfurters during thermal processing using neural network. Meat Science, 55(1), 13–24. [https://doi.org/10.1016/s0309-1740\(99\)00120-5](https://doi.org/10.1016/s0309-1740(99)00120-5)
- Mittal, G. S., & Zhang, J. (2000c). Use of artificial neural network to predict temperature, moisture, and fat in slab-shaped foods with edible coatings during deep-fat frying. Journal of Food Science, 65(6), 978–983. <https://doi.org/10.1111/j.1365-2621.2000.tb09403.x>
- Mohammad, R. (2014). Use of water properties in food technology: A global view. International Journal of Food Properties, 17:5, 1034-1054, DOI: <https://doi.org/10.1080/10942912.2011.650339>
- Moscatto JA, Borsato D, Bona E, de Oliveira AS, de Oliveira MCH (2006) The optimization of the formulation for a chocolate cake containing inulin and yacon meal. Int J Food Sci Tech 41:181–188
- Muir, J. G., Rose, R., Rosella, O., Liels, K., Barrett, J. S., Shepherd, S. J., & Gibson, P. R. (2009). Measurement of short-chain carbohydrates in common Australian vegetables and fruits

- by high-performance liquid chromatography (HPLC). *Journal of Agricultural and Food Chemistry*, 57(2), 554–565. <https://doi.org/10.1021/jf802700e>
- Márquez, H. (2019). Composición nutricional y de mucílago de tres variedades de olluco (*Ullucus tuberosus* loz.) para la obtención de chuño de olluco en el distrito de Santo Tomás –Cusco (Tesis de pregrado, Universidad Nacional San Antonio Abad del Cusco). Recuperado de <https://repositorio.unsaac.edu.pe/handle/20.500.12918/3694>
- National Research Council. (1989). *Lost crops of the Incas: Little-known plants of the Andes with promise for worldwide cultivation*. National Academies Press.
- Ortiz, L. (2022). Estimación experimental y teórica de la temperatura inicial de congelación del loche (*Cucurbita moschata* duch.), la mashua (*Tropaeolum tuberosum* r&p.), y el yacón (*Smallanthus sonchifolius* p&e.) con diferentes contenidos de agua. <https://doi.org/10.25127/riagrop.20223.847>
- Othman, S., Mavani, N. R., Hussain, M. A., Rahman, N. A., & Mohd Ali, J. (2023). Artificial intelligence-based techniques for adulteration and defect detections in food and agricultural industry: A review. *Journal of Agriculture and Food Research*, 12(100590), 100590. <https://doi.org/10.1016/j.jafr.2023.100590>
- Pacheco, A. (2014). Optimización de parámetros fisicoquímicos y organolépticos en el olluco (*Ullucus tuberosus* Caldas) mínimamente procesado (Tesis de Pregrado, Universidad Nacional San Cristóbal de Huamanga). Recuperado de <https://repositorio.unsch.edu.pe/handle/UNSCH/931?locale=es>
- Pacheco, M. T., Hernández-Hernández, O., Moreno, F. J., & Villamiel, M. (2020). Andean tubers grown in Ecuador: New sources of functional ingredients. *Food Bioscience*, 35(100601), 100601. <https://doi.org/10.1016/j.fbio.2020.100601>
- Palacios, R., Morales, M., & Arias, G. C. (2011). Evaluación químico-bromatológica de tres variedades de *Arracacia xanthorrhiza* “Arracacha”. *Ciencia e Investigación*, 14(2), 12–14. <https://doi.org/10.15381/ci.v14i2.3161>
- Ponce, R. C. (1999). Elaboración a Base de una Conserva de Maca (*Lepidium Meyenii* Wolf) Utilizando Envases de Vidrio (Tesis de pregrado, Universidad Nacional del Centro del Perú). Recuperado de

<https://repositorio.uncp.edu.pe/bitstream/handle/20.500.12894/1867/FLORES%20C%C3%93RDOVA%20Jos%C3%A9%20Antonio%20Cleon%20machacuay.pdf?sequence=1&isAllowed=y>

Priecina, L., & Karklina, D. (2015). Composition of major organic acids in vegetables and spices. CBU International Conference Proceedings, 3, 447–454. <https://doi.org/10.12955/cbup.v3.637>

Profile. (2022). Introducción al pandas. Recuperado de <https://profile.es/blog/pandas-python/>

Quispe, A., & Victor, B. (2017). Influencia del tiempo de soleado sobre la concentración de azúcares reductores y capacidad antioxidante de la mashua (*Tropaeolum tuberosum*) ecotipo negra (Tesis pregrado, Universidad Nacional de Huancavelica). Recuperado de <https://repositorio.unh.edu.pe/items/eee78f7d-c6d7-4ced-b92b-d32023d62bb9>

Rahman, M. S., Machado-Velasco, K. ., Sosa-Morales, M. ., & Velez-Ruiz, J. F. (2009). Freezing Point : Measurement, Data, and Prediction. In M. S. Rahman (Ed.), Food Properties Handbook (Second, p. 838). Boca Raton, FL: Taylor & Francis Group, LLC. <https://doi.org/10.1201/9781420003093>

Rahman, M. S., Rashid, M. M., & Hussain, M. A. (2012). Thermal conductivity prediction of foods by Neural Network and Fuzzy (ANFIS) modeling techniques. Food and Bioproducts Processing, 90(2), 333–340. <https://doi.org/10.1016/j.fbp.2011.07.001>

Rahman, M. Shafiur (Ed.). (1995). Food properties handbook. Florida: CRC Press.

Rahman, M. Shafiur (Ed.). (2008). Food properties handbook. CRC Press.

Rahman, M. Shafiur, Guizani, N., Al-Khaseibi, M., Ali Al-Hinai, S., Al-Maskri, S. S., & Al-Hamhami, K. (2002). Analysis of cooling curve to determine the end point of freezing. Food Hydrocolloids, 16(6), 653–659. [https://doi.org/10.1016/s0268-005x\(02\)00031-0](https://doi.org/10.1016/s0268-005x(02)00031-0)

Rejeb, A., Rejeb, K., Zailani, S., Keogh, J. G., & Appolloni, A. (2022). Examining the interplay between artificial intelligence and the agri-food industry. Artificial Intelligence in Agriculture, 6, 111–128. <https://doi.org/10.1016/j.aiia.2022.08.002>

Reyes, M., Gómez-Sánchez, I., & Espinoza, C. (2009). Tablas peruanas de composición de alimentos—8va ed. — Lima: Ministerio de Salud, Instituto Nacional de Salud.

Recuperado de <https://repositorio.ins.gob.pe/bitstream/handle/20.500.14196/1034/tablas-peruanas-QR.pdf?sequence=3&isAllowed=y>

Reyes, M., Prieto, I. G.-S., & Barrientos, C. E. (2017). Tablas Peruanas de Composición de Alimentos. Gob.pe. Recuperado de <https://repositorio.ins.gob.pe/bitstream/handle/20.500.14196/1034/tablas-peruanas-QR.pdf>

Rincón Rueda, M. A., Ruiz Berrio, H. D., Molano Díaz, J. M., Alvarez Herrera, J. G., & Pinto Acero, Y. L. (2021). Postharvest characterization of seven arracacha cultivars (*Arracacia xanthorrhiza* Bancroft). Revista Facultad Nacional De Agronomía Medellín, 74(3), 9745–9756. <https://doi.org/10.15446/rfnam.v74n3.92658>

Rodas, R. (1992). Obtención y Caracterización de la Harina de arracacha Amarilla (*Arracacia xanthorrhiza* Bancroft) obtenida por el secado en Túnel de Aire Caliente (Tesis pregrado, Universidad Nacional Agraria La Molina). Recuperado de <https://repositorio.lamolina.edu.pe/handle/>

Rojano, A., Salazar, R., Miranda, L., & Ojeda, W. (2021). Algoritmo Adam en la inteligencia artificial. Artículo COMEII-21005.

Rojas, E. (2015). Optimización de la incorporación de Aloe Vera en yacón (*Smallanthus sonchifolius* Poepp. & Endl.) mediante impregnación a vacío (Tesis de pregrado, Universidad Nacional Agraria La Molina). Recuperado de <https://repositorio.lamolina.edu.pe/handle/20.500.12996/2599>

Ruiz, B., & Marcelo, B. (2011). Determinación de las características físicas y químicas de la Zanahoria Blanca (*Arracacia xanthorrhiza bancrofti*) proveniente de la Zona de San José de Minas Provincia de Pichincha (Tesis de pregrado, Universidad Técnica del Norte). Recuperado de <https://repositorio.utn.edu.ec/handle/123456789/5/simple-search?filterquery=Benalc%C3%A1zar+Ruiz%2C+Byron+Marcelo&filtername=author&filtertype>equals>

Sablani, S. S., & Shayya, W. H. (2000). Computerization of Stumbo's method of thermal process calculations using neural networks. Journal of Food Engineering, 47(3), 233–240. [https://doi.org/10.1016/s0260-8774\(00\)00121-7](https://doi.org/10.1016/s0260-8774(00)00121-7)

- Sablani, S. S., & Shayya, W. H. (2002). Neural network based non-iterative calculation of the friction factor for power law fluids. *Journal of Food Engineering*, 57(4), 327–335. [https://doi.org/10.1016/s0260-8774\(02\)00347-3](https://doi.org/10.1016/s0260-8774(02)00347-3)
- Salas-Valerio, W., Solano-Cornejo, M., Zelada-Bazán, M., & Vidaurre-Ruiz, J. (2019). Three-dimensional modeling of heat transfer during freezing of suspended and in-contact-with-a-surface yellow potatoes and ullucus. *Journal of Food Process Engineering*, 42(6), 1–10. <https://doi.org/10.1111/jfpe.13174>
- Salazar, M. (2014). Procesamiento de harina de mashua (*Tropaeolum tuberosum*) para la aplicación en productos de panadería. (Tesis de pregrado, Escuela Superior Politécnica de Chimborazo). Recuperado de <http://dspace.espoch.edu.ec/handle/123456789/9914>
- Samaniego, L. (2010). Caracterización de la mashua (*Tropaeolum tuberosum*) en el Ecuador. (Tesis de pregrado, Universidad Tecnológica Equinoccial). Recuperado de <https://repositorio.ute.edu.ec/handle/123456789/4870?mode=full>
- Schwartzberg, H. G. (1976). Effective Heat Capacities for the Freezing and Thawing of Food. *Journal of Food Science*, 41(1), 152–156. <https://doi.org/10.1111/j.1365-2621.1976.tb01123>.
- Scher, CF. 2009. Estudo do branqueamento e da secagem mediante ar quente do yacon (*Smallanthus sonchifolius*) (Tesis de pregrado, Universidade Federal do Rio Grande do Sul). Recuperado de <https://lume.ufrgs.br/handle/10183/12730>
- Seminario, J., Valderrama, M., & Manrique, I. (2003). El Yacón: fundamentos para el aprovechamiento de un recurso promisorio. Centro Internacional de la Papa (CIP), Universidad Nacional de Cajamarca, Agencia Suiza para el Desarrollo y la Cooperación (COSUDE), Lima: Perú, 60 páginas.
- Shanmugavelan, P., Kim, S. Y., Kim, J. B., Kim, H. W., Cho, S. M., Kim, S. N., Kim, S. Y., Cho, Y. S., & Kim, H. R. (2013). Evaluation of sugar content and composition in commonly consumed Korean vegetables, fruits, cereals, seed plants, and leaves by HPLC-ELSD. *Carbohydrate Research*, 380, 112–117. <https://doi.org/10.1016/j.carres.2013.06.024>

- Sifuentes, G., León, S., & Paucar, L. M. (2015). Study of Maca (*Lepidium meyenii* Walp.), Andean crop with therapeutic properties. *Scientia agropecuaria*, 131–140. <https://doi.org/10.17268/sci.agropecu.2015.02.06>
- Sinha, N. K. (Ed.). (2011). *Handbook of Vegetables and Vegetable Processing*. Wiley. <https://doi.org/10.1002/9780470958346>
- Soukup. (1986). Entrevista Personal. Instituto de Altos Estudios Agrícolas.
- Sun, D.-W. (2012). *Handbook of Frozen Food Processing and Packaging* (Vol. 160). CRC Press.
- Torres, J. (2018). Deep Learning – Introducción práctica con Keras. Jordi Torres. Recuperado de <https://torres.ai/deep-learning-inteligencia-artificial-keras/>
- Universidad Complutense de Madrid. (2022). ¿Qué es el Machine Learning? Máster Data Science. Recuperado de <https://www.masterdatascienceucm.com/que-es-machine-learning/>
- Valcárcel-Yamani, B., Rondán-Sanabria, G. G., & Finardi-Filho, F. (2013). The physical, chemical and functional characterization of starches from Andean tubers: oca (*Oxalis tuberosa* Molina), olluco (*Ullucus tuberosus* Caldas) and mashua (*Tropaeolum tuberosum* Ruiz & Pavón). *Brazilian Journal of Pharmaceutical Sciences*, 49(3), 453–464. <https://doi.org/10.1590/s1984-82502013000300007>
- Valentová, K., Buckiová, D., Kren, V., Peknicová, J., Ulrichová, J., & Simánek, V. (2006). The in vitro biological activity of *Lepidium meyenii* extracts. *Cell Biology and Toxicology*, 22(2), 91–99. <https://doi.org/10.1007/s10565-006-0033-0>
- USDA (2023). FoodDataCentral. Usda.gov. Recuperado de <https://fdc.nal.usda.gov/fdc-app.html#/>
- Vargas, A., Becerra, A. S., Sayago, S. G., Palma, H. M., García, M. de L., & Montalvo, E. (2017). Combined effect of the application of 1-MCP and different edible coatings on the fruit quality of jackfruit bulbs (*Artocarpus heterophyllus* Lam) during cold storage. *Scientia Horticulturae*, 214, 221–227.

- Vos AP, van Esch BC, Stahl B, M'Rabet L, Folkerts G, Nijkamp FP, Garssen J (2007) Dietary supplementation with specific oligosaccharide mixtures decreases parameters of allergic asthma in mice. *Int Immunopharmacol* 7(Suppl 12):1582–1587
- Wang, S. & Zhu, F. (2019). Chemical composition and health effects of maca (*Lepidium meyenii*). *Food Chemistry*, 288, 422-443. Recuperado de <https://pubmed.ncbi.nlm.nih.gov/30902313/>
- Wang, Y., Wang, Y., McNeil, B., & Harvey, L. M. (2007). Maca: An Andean crop with multi-pharmacological functions. *Food Research International* (Ottawa, Ont.), 40(7), 783–792. <https://doi.org/10.1016/j.foodres.2007.02.005>
- Yalçın, O. G. (2021). The guide to my content on artificial intelligence - Orhan G. Yalçın. Medium. Recuperado de <https://blog.orhangazyalcin.com/a-guide-to-my-content-on-artificial-intelligence-c70c9b4a3b17>
- Yavar, Y. (2016). Efecto del empaque en las características sensoriales y fisicoquímicas del Olluco (*Ullucus tuberosus*) entero al estado fresco (Tesis de pregrado, Universidad Nacional Agraria de la Selva). Recuperado de <https://repositorio.unas.edu.pe/handle/20.500.14292/1259>
- Zapana, R. (2007). Estudio químico-bromatológico de algunas variedades de yacón (*Smallanthus sonchifolius*) (Poepp & Endl) H. Robinson. De la provincia de Sandia-Puno (Tesis de pregrado, Universidad Nacional Mayor de San Marcos). Recuperado de <https://core.ac.uk/download/pdf/323350075.pdf>
- Zardini, E. (1991). Ethnobotanical notes on yacon, *Polymnia sonchifolia* (asteraceae). *Econ Bot* 45(Suppl 1):72–85
- Zhou, Q. (2016). Influence of the freezing process on quality retention of frozen tomato slices. The Ohio State University.
- Zhu, Q., Liu, Z., & Yan, J. (2021). Machine learning for metal additive manufacturing: predicting temperature and melt pool fluid dynamics using physics-informed neural networks. *Computational Mechanics*, 67(3), 619–635. <https://doi.org/10.1007/s00466-020-01952-9>

Zhu, S., Le Bail, A., & Ramaswamy, H. S. (2006). High-pressure differential scanning calorimetry: Comparison of pressure-dependent phase transition in food materials. *Journal of Food Engineering*, 75(2), 215–222.
<https://doi.org/10.1016/j.jfoodeng.2005.04.009>

VIII. ANEXOS

ANEXO 1: CÓDIGOS PARA LA GENERACIÓN DE UNA MATRIZ DE CALOR A TRAVÉS DE GOOGLE COLABORATORY

```
import pandas as pd

import seaborn as sns
import matplotlib.pyplot as plt
from google.colab import drive

# Ruta al archivo de Excel en tu
# Google Drive
file_path = "/content/31
vegetales..xlsx"

# Lee los datos del archivo de Excel
df = pd.read_excel(file_path)
```

```
# Calcula la matriz de correlación
correlation_matrix = df.corr()

# Configura el estilo de la figura
sns.set(style="white")

# Crea la figura y el gráfico
plt.figure(figsize=(10, 8))
sns.heatmap(correlation_matrix, annot=True,
cmap="coolwarm", center=0)

# Configura el título del gráfico
plt.title("Matriz de Correlación")

# Muestra el gráfico
plt.show()
```

ANEXO 2: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE AGUA DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para el contenido de agua de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	1254.89	4	313.722	93369.69	0.0000
INTRA GRUPOS	0.0336	10	0.00336		
TOTAL (CORREGIDO)	1254.92	14			

Pruebas de Múltiple Rangos para el contenido de agua de Tubérculos y Raíces

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Maca	3	69.27	X
Arracacha	3	71.2067	X
Yacón	3	85.3467	X
Mashua	3	88.91	X
Olluco	3	91.1733	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	1.93667	0.155776
Arracacha – Mashua	*	-17.7033	0.155776
Arracacha – Olluco	*	-19.9667	0.155776
Arracacha – Yacón	*	-14.14	0.155776
Maca – Mashua	*	-19.64	0.155776
Maca – Olluco	*	-21.9033	0.155776
Maca – Yacón	*	-16.0767	0.155776
Mashua – Olluco	*	-2.26333	0.155776
Mashua – Yacón	*	3.56333	0.155776
Olluco – Yacón	*	5.82667	0.155776

* indica una diferencia significativa.

ANEXO 3: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE PROTEÍNA DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para el contenido de proteína de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	19.3016	4	4.82541	5896.63	0.0000
INTRA GRUPOS	0.00818333	10	0.000818333		
TOTAL (CORREGIDO)	19.3098	14			

Pruebas de Múltiple Rangos para el contenido de proteína de Tubérculos y Raíces

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Yacón	3	0.17	X
Arracacha	3	0.826667	X
Olluco	3	1.12333	X
Mashua	3	1.125	X
Maca	3	3.51	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	-2.68333	0.0768769
Arracacha – Mashua	*	-0.298333	0.0768769
Arracacha – Olluco	*	-0.296667	0.0768769
Arracacha – Yacón	*	0.656667	0.0768769
Maca – Mashua	*	2.385	0.0768769
Maca – Olluco	*	2.38667	0.0768769
Maca – Yacón	*	3.34	0.0768769
Mashua – Olluco	*	0.00166667	0.0768769
Mashua – Yacón	*	0.955	0.0768769
Olluco – Yacón	*	0.953333	0.0768769

* indica una diferencia significativa.

ANEXO 4: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE GRASA DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para el contenido de grasa de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	0.05109	4	0.0127725	851.50	0.0000
INTRA GRUPOS	0.00015	10	0.000015		
TOTAL (CORREGIDO)	0.05124	14			

Pruebas de Múltiple Rangos para el contenido de grasa de Tubérculos y Raíces

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Yacón	3	0.105	X
Maca	3	0.125	X
Mashua	3	0.19	X
Olluco	3	0.195	X
Arracacha	3	0.27	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	0.145	0.0104082
Arracacha – Mashua	*	0.08	0.0104082
Arracacha – Olluco	*	0.075	0.0104082
Arracacha – Yacón	*	0.165	0.0104082
Maca – Mashua	*	-0.065	0.0104082
Maca – Olluco	*	-0.07	0.0104082
Maca – Yacón	*	0.02	0.0104082
Mashua – Olluco		-0.005	0.0104082
Mashua – Yacón	*	0.085	0.0104082
Olluco – Yacón	*	0.09	0.0104082

* indica una diferencia significativa.

ANEXO 5: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE FIBRA DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para el contenido de fibra de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	4.77675	4	1.19419	3363.91	0.0000
INTRA GRUPOS	0.00355	10	0.000355		
TOTAL (CORREGIDO)	4.7803	14			

Pruebas de Múltiple Rangos para el contenido de fibra de Tubérculos y Raíces

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Olluco	3	0.11	X
Mashua	3	0.425	X
Yacón	3	0.52	X
Arracacha	3	0.655	X
Maca	3	1.765	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	-1.11	0.0506343
Arracacha – Mashua	*	0.23	0.0506343
Arracacha – Olluco	*	0.545	0.0506343
Arracacha – Yacón	*	0.135	0.0506343
Maca – Mashua	*	1.34	0.0506343
Maca – Olluco	*	1.655	0.0506343
Maca – Yacón	*	1.245	0.0506343
Mashua – Olluco	*	0.315	0.0506343
Mashua – Yacón	*	-0.095	0.0506343
Olluco – Yacón	*	-0.41	0.0506343

* indica una diferencia significativa.

ANEXO 6: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE CALCIO DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para el contenido de calcio de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	96492.5	4	24123.1	180923446.43	0.0000
INTRA GRUPOS	0.00133333	10	0.000133333		
TOTAL (CORREGIDO)	96492.5	14			

Pruebas de Múltiple Rangos para el contenido de calcio de Tubérculos y Raíces

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Olluco	3	35.0167	X
Mashua	3	76.9967	X
Yacón	3	114.0	X
Arracacha	3	118.0	X
Maca	3	272.0	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	-154.0	0.0310313
Arracacha – Mashua	*	41.0033	0.0310313
Arracacha – Olluco	*	82.9833	0.0310313
Arracacha – Yacón	*	4.0	0.0310313
Maca – Mashua	*	195.003	0.0310313
Maca – Olluco	*	236.983	0.0310313
Maca – Yacón	*	158.0	0.0310313
Mashua – Olluco	*	41.98	0.0310313
Mashua – Yacón	*	-37.0033	0.0310313
Olluco – Yacón	*	-78.9833	0.0310313

* indica una diferencia significativa.

ANEXO 7: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE FÓSFORO DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para el contenido de fósforo de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	19532.6	4	4883.16	221894.49	0.0000
INTRA GRUPOS	0.220067	10	0.0220067		
TOTAL (CORREGIDO)	19532.9	14			

Pruebas de Múltiple Rangos para el contenido de fósforo de Tubérculos y Raíces

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Yacón	3	49.9	X
Olluco	3	59.4	X
Mashua	3	71.1	X
Arracacha	3	77.4467	X
Maca	3	151.5	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	-74.0533	0.398665
Arracacha – Mashua	*	6.34667	0.398665
Arracacha – Olluco	*	18.0467	0.398665
Arracacha – Yacón	*	27.5467	0.398665
Maca – Mashua	*	80.4	0.398665
Maca – Olluco	*	92.1	0.398665
Maca – Yacón	*	101.6	0.398665
Mashua – Olluco	*	11.7	0.398665
Mashua – Yacón	*	21.2	0.398665
Olluco – Yacón	*	9.5	0.398665

* indica una diferencia significativa.

ANEXO 8: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE MAGNESIO DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para el contenido de magnesio de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	645.443	4	161.361	1510.59	0.0000
INTRA GRUPOS	1.0682	10	0.10682		
TOTAL (CORREGIDO)	646.511	14			

Pruebas de Múltiple Rangos para el contenido de magnesio de Tubérculos y Raíces

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Yacón	3	6.8	X
Olluco	3	9.8	X
Arracacha	3	13.5467	X
Mashua	3	17.4533	X
Maca	3	25.6467	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	-12.1	0.878329
Arracacha – Mashua	*	-3.90667	0.878329
Arracacha – Olluco	*	3.74667	0.878329
Arracacha – Yacón	*	6.74667	0.878329
Maca – Mashua	*	8.19333	0.878329
Maca – Olluco	*	15.8467	0.878329
Maca – Yacón	*	18.8467	0.878329
Mashua – Olluco	*	7.65333	0.878329
Mashua – Yacón	*	10.6533	0.878329
Olluco – Yacón	*	3.0	0.878329

* indica una diferencia significativa.

ANEXO 9: ANÁLISIS DE VARIANZA PARA EL CONTENIDO DE POTASIO DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para el contenido de potasio de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	289438.	4	72359.6	48850.24	0.0000
INTRA GRUPOS	14.8125	10	1.48125		
TOTAL (CORREGIDO)	289453.	14			

Pruebas de Múltiple Rangos para el contenido de potasio de Tubérculos y Raíces

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Yacón	3	112.95	X
Olluco	3	126.95	X
Mashua	3	171.55	X
Maca	3	407.453	X
Arracacha	3	427.797	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha - Maca	*	20.3433	3.27074
Arracacha - Mashua	*	256.247	3.27074
Arracacha - Olluco	*	300.847	3.27074
Arracacha - Yacón	*	314.847	3.27074
Maca - Mashua	*	235.903	3.27074
Maca - Olluco	*	280.503	3.27074
Maca – Yacón	*	294.503	3.27074
Mashua – Olluco	*	44.6	3.27074
Mashua – Yacón	*	58.6	3.27074
Olluco – Yacón	*	14.0	3.27074

* indica una diferencia significativa.

ANEXO 10: ANÁLISIS DE VARIANZA PARA LA VITAMINA C DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para la Vitamina C de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	8228.28	4	2057.07	1112.51	0.0000
INTRA GRUPOS	18.4903	10	1.84903		
TOTAL (CORREGIDO)	8246.77	14			

Pruebas de Múltiple Rangos para Vitamina C de Raíces y Tubérculos

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Maca	3	0.846667	X
Yacón	3	12.67	X
Olluco	3	16.33	X
Arracacha	3	18.8667	X
Mashua	3	68.66	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	18.02	3.65429
Arracacha – Mashua	*	-49.7933	3.65429
Arracacha – Olluco		2.53667	3.65429
Arracacha – Yacón	*	6.19667	3.65429
Maca – Mashua	*	-67.8133	3.65429
Maca – Olluco	*	-15.4833	3.65429
Maca – Yacón	*	-11.8233	3.65429
Mashua – Olluco	*	52.33	3.65429
Mashua – Yacón	*	55.99	3.65429
Olluco – Yacón	*	3.66	3.65429

* indica una diferencia significativa.

ANEXO 11: ANÁLISIS DE VARIANZA PARA EL pH DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para el pH de Raíces y Tubérculos

Análisis de varianza

Tabla ANOVA para el pH de Raíces Y Tubérculos

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	5.21718	4	1.3043	1527.40	0.0000
INTRA GRUPOS	0.00853933	10	0.000853933		
TOTAL (CORREGIDO)	5.22572	14			

Pruebas de Múltiple Rangos para el pH de Raíces y Tubérculos

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Yacón	3	5.06	X
Maca	3	5.58	X
Arracacha	3	6.24567	X
Mashua	3	6.39	X
Olluco	3	6.68333	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	0.665667	0.0785313
Arracacha – Mashua	*	-0.144333	0.0785313
Arracacha – Olluco	*	-0.437667	0.0785313
Arracacha – Yacón	*	1.18567	0.0785313
Maca – Mashua	*	-0.81	0.0785313
Maca – Olluco	*	-1.10333	0.0785313
Maca – Yacón	*	0.52	0.0785313
Mashua – Olluco	*	-0.293333	0.0785313
Mashua – Yacón	*	1.33	0.0785313
Olluco – Yacón	*	1.62333	0.0785313

* indica una diferencia significativa.

ANEXO 12: ANÁLISIS DE VARIANZA PARA LA ACIDEZ DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para la acidez de Raíces y Tubérculos

Análisis de varianza

Tabla ANOVA para la acidez de Raíces Y Tubérculos

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	0.574067	4	0.143517	336.37	0.0000
INTRA GRUPOS	0.00426667	10	0.000426667		
TOTAL (CORREGIDO)	0.578333	14			

Pruebas de Múltiple Rangos para la acidez de Raíces y Tubérculos

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Arracacha	3	0.05	X
Yacón	3	0.12	X
Olluco	3	0.15	X
Mashua	3	0.163333	X
Maca	3	0.6	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	-0.55	0.0555105
Arracacha – Mashua	*	-0.113333	0.0555105
Arracacha – Olluco	*	-0.1	0.0555105
Arracacha – Yacón	*	-0.07	0.0555105
Maca – Mashua	*	0.436667	0.0555105
Maca – Olluco	*	0.45	0.0555105
Maca – Yacón	*	0.48	0.0555105
Mashua – Olluco		0.0133333	0.0555105
Mashua – Yacón		0.0433333	0.0555105
Olluco – Yacón		0.03	0.0555105

* indica una diferencia significativa.

ANEXO 13: ANÁLISIS DE VARIANZA PARA SÓLIDOS SOLUBRES DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para sólidos solubles de Raíces y Tubérculos

Análisis de varianza

Tabla ANOVA para la acidez de Raíces Y Tubérculos

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	264.058	4	66.0145	3501.47	0.0000
INTRA GRUPOS	0.188533	10	0.0188533		
TOTAL (CORREGIDO)	264.246	14			

Pruebas de Múltiple Rangos para sólidos solubles de Raíces y Tubérculos

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Olluco	3	5.02333	X
Mashua	3	5.83333	X
Arracacha	3	6.3	X
Yacón	3	8.3	X
Maca	3	16.5	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	-10.2	0.368999
Arracacha – Mashua	*	0.466667	0.368999
Arracacha – Olluco	*	1.27667	0.368999
Arracacha – Yacón	*	-2.0	0.368999
Maca – Mashua	*	10.6667	0.368999
Maca – Olluco	*	11.4767	0.368999
Maca – Yacón	*	8.2	0.368999
Mashua – Olluco	*	0.81	0.368999
Mashua – Yacón	*	-2.46667	0.368999
Olluco – Yacón	*	-3.27667	0.368999

* indica una diferencia significativa.

ANEXO 14: CÓDIGOS DE VARIABLES DE ENTRADA Y DE SALIDA DE LAS DIFERENTES CONFIGURACIONES DE REDES NEURONALES

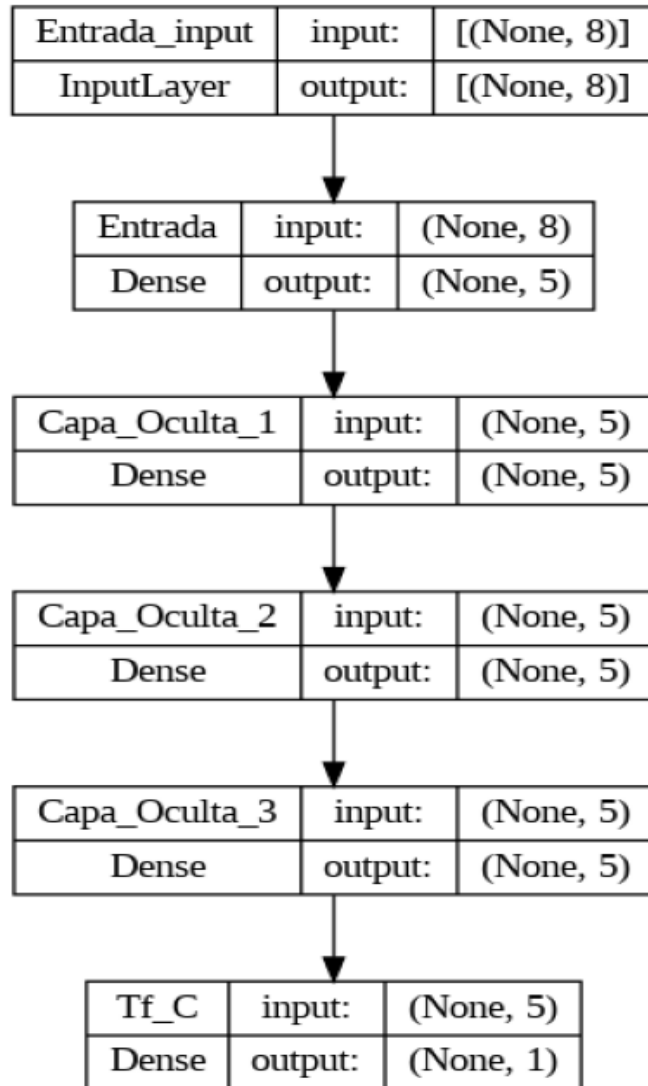
```
import tensorflow as tf  
  
import numpy as np  
  
import pandas as pd  
  
df=pd.read_excel('/content/31 vegetales..xlsx')  
  
df.head()
```

```
import tensorflow as tf  
  
import numpy as np  
  
import pandas as pd  
  
df=pd.read_excel('/content/31 vegetales sin  
proteínas,lípidos y fibra.xlsx')  
  
df.head()
```

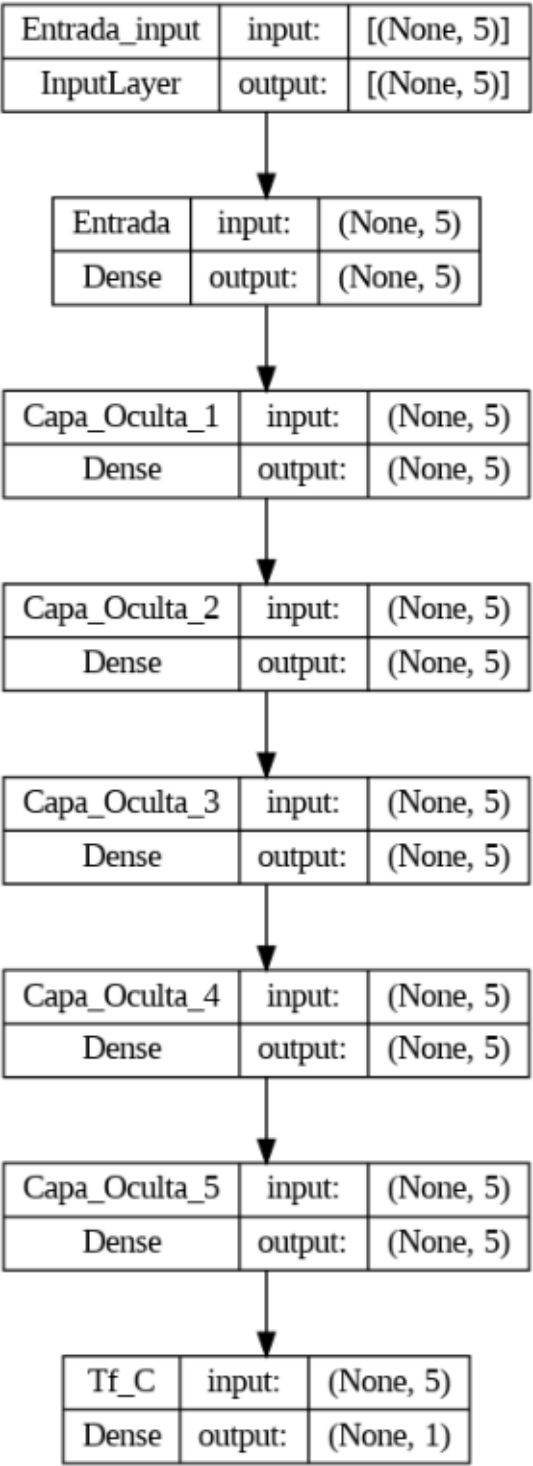
```
import tensorflow as tf  
  
import numpy as np  
  
import pandas as pd  
  
df=pd.read_excel('/content/6000datos.xlsx')  
  
df.head()
```

```
import tensorflow as tf  
  
import numpy as np  
  
import pandas as pd  
  
df=pd.read_excel('/content/6000datossinproteína,lí  
pidosyfibra.xlsx')  
  
df.head()
```

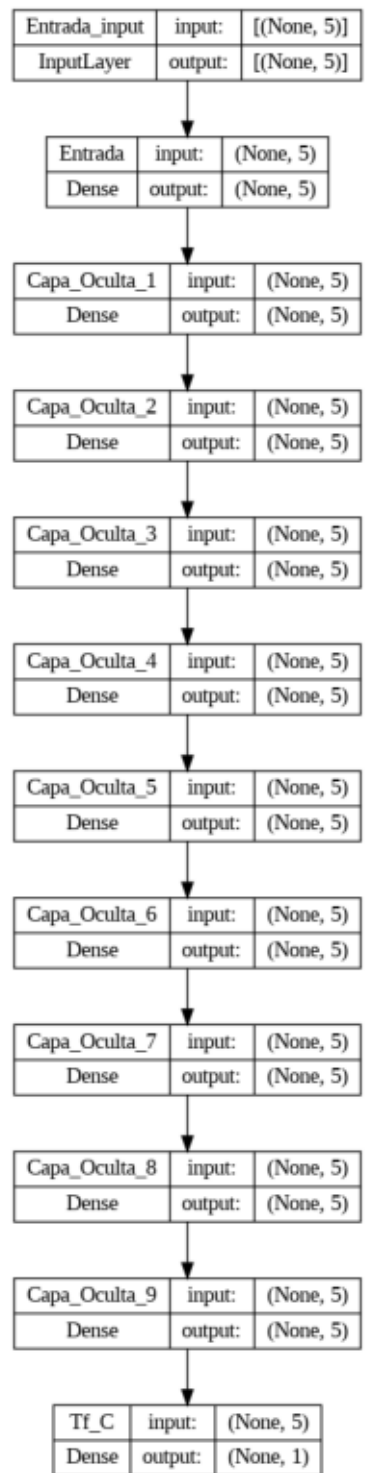
**ANEXO 15: ARQUITECTURA DE RED NEURONAL CON 8
VARIABLES DE ENTRADA, 3 CAPAS OCULTAS, 5 NEURONAS Y 1
VARIABLE DE SALIDA**



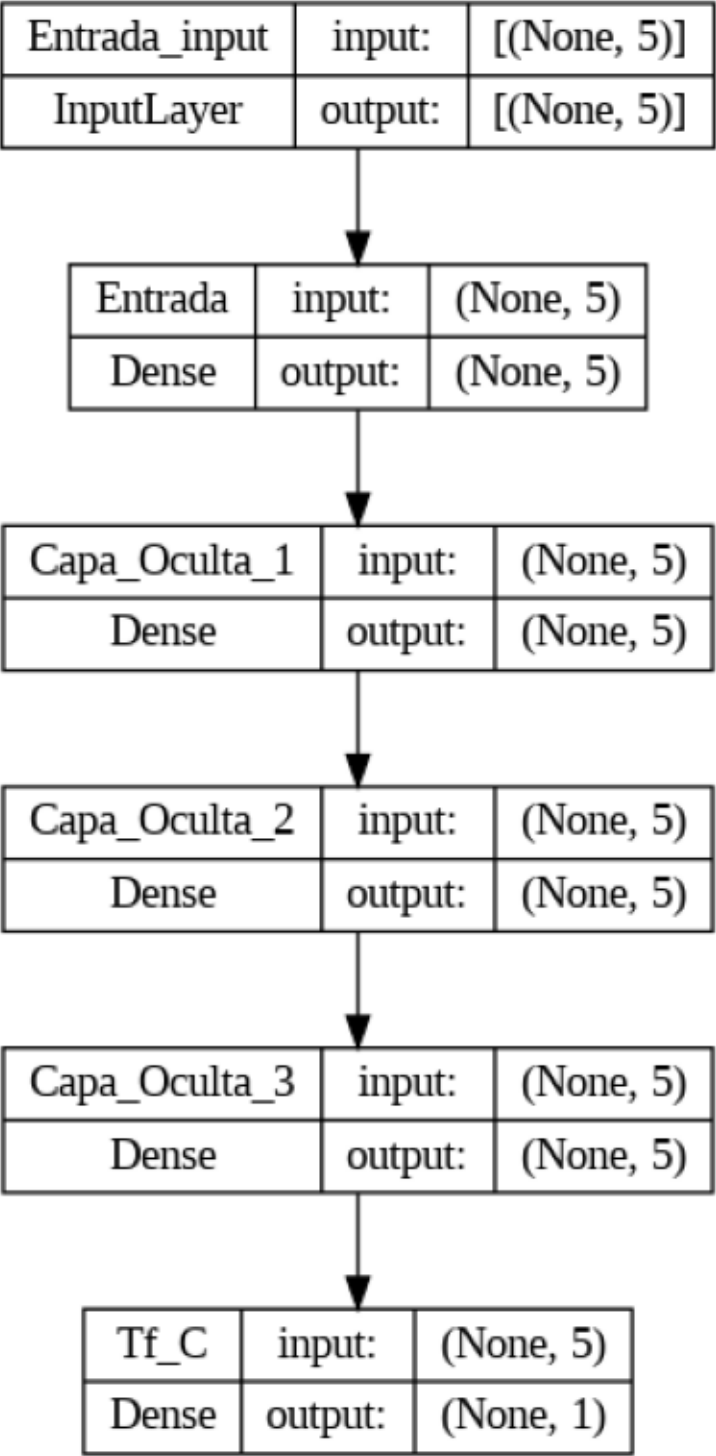
**ANEXO 16: ARQUITECTURA DE RED NEURONAL CON 5
VARIABLES DE ENTRADA, 5 CAPAS OCULTAS, 5 NEURONAS Y 1
VARIABLE DE SALIDA**



**ANEXO 17: ARQUITECTURA DE RED NEURONAL CON 5
VARIABLES DE ENTRADA, 9 CAPAS OCULTAS, 5 NEURONAS Y 1
VARIABLE DE SALIDA**



**ANEXO 18: ARQUITECTURA DE RED NEURONAL CON 5
VARIABLES DE ENTRADA, 3 CAPAS OCULTAS, 5 NEURONAS Y 1
VARIABLE DE SALIDA**



ANEXO 19: ANÁLISIS DE VARIANZA PARA EL Tf DE RAÍCES Y TUBÉRCULOS

Multifactor ANOVA para Tf de Raíces y Tubérculos

Análisis de varianza

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>GL</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
ENTRE GRUPOS	3.23524	4	0.80881	81.59	0.0000
INTRA GRUPOS	0.0991333	10	0.00991333		
TOTAL (CORREGIDO)	3.33437	14			

Pruebas de Múltiple Rangos para Tf por Tubérculos y Raíces

Método: 95.0 porcentaje Tukey HSD

<i>Nivel</i>	<i>Casos</i>	<i>Media</i>	<i>Grupos Homogéneos</i>
Maca	3	-2.02667	X
Yacón	3	-1.37333	X
Arracacha	3	-1.10333	X
Mashua	3	-0.863333	XX
Olluco	3	-0.706667	X

<i>Contraste</i>	<i>Sig.</i>	<i>Diferencia</i>	<i>+/- Límites</i>
Arracacha – Maca	*	0.923333	0.267572
Arracacha – Mashua		-0.24	0.267572
Arracacha – Olluco	*	-0.396667	0.267572
Arracacha – Yacón	*	0.27	0.267572
Maca – Mashua	*	-1.16333	0.267572
Maca – Olluco	*	-1.32	0.267572
Maca – Yacón	*	-0.653333	0.267572
Mashua – Olluco		-0.156667	0.267572
Mashua – Yacón	*	0.51	0.267572
Olluco – Yacón	*	0.666667	0.267572

* indica una diferencia significativa.

**ANEXO 20: CÓDIGOS DEL ENTRENAMIENTO DE LA RED
NEURONAL ÓPTIMA (5 VARIABLES DE ENTRADA, 1 VARIABLE
DE SALIDA, 3 CAPAS OCULTAS Y 5 NEURONAS) CON 31
CONJUNTO DE DATOS**

```
X = df.drop(columns=['Tf predicho (°C)'])
Y = df[['Tf predicho (°C)']]

oculta1 = tf.keras.layers.Dense(units=5, input_shape=[5,])
oculta2 = tf.keras.layers.Dense(units=5)
oculta3 = tf.keras.layers.Dense(units=5)

salida = tf.keras.layers.Dense(units=1,)
modelo = tf.keras.Sequential([oculta1, oculta2, oculta3, salida])
modelo.compile(
    optimizer=tf.keras.optimizers.Adam(0.1),
    loss='mean_squared_error'
)
print("Comenzando entrenamiento...")
historial = modelo.fit(X, Y, epochs=1000, verbose=False)
print("Modelo entrenado!")
```