

UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI



FACULTAD DE INDUSTRIAS AGROPECUARIAS Y CIENCIAS AMBIENTALES

CARRERA DE ALIMENTOS

Tema: **“Modelamiento predictivo mediante deep learning de las características sensoriales y texturales de las galletas enriquecidas con nanopartículas de carbonato de calcio y su relación con las propiedades fisicoquímicas”**

Trabajo de Integración Curricular previo a la obtención del
título de Ingenieras en Alimentos

AUTORAS: Jiménez Chávez Mayerli Lisbeth
Reyes Tonguino Adriana Patricia

TUTOR: MSc. Burbano Pulles Marco Rubén PhD

Tulcán, 2026.

CERTIFICADO DEL TUTOR

Certifico que las estudiantes Jiménez Chávez Mayerli Lisbeth y Reyes Tonguino Adriana Patricia con el número de cédula 0450149067 y 1050159704 respectivamente han desarrollado el Trabajo de Integración Curricular: "Modelamiento predictivo mediante deep learning de las características sensoriales y texturales de las galletas enriquecidas con nanopartículas de carbonato de calcio y su relación con las propiedades fisicoquímicas"

Este trabajo se sujeta a las normas y metodología dispuesta en la Codificación del Reglamento de Régimen Académico y de Estudiantes de la UPEC, por lo tanto, autorizo la presentación de la sustentación para la calificación respectiva.



MSc. Burbano Pulles Marco Rubén PhD

TUTOR

Tulcán, septiembre de 2026

AUTORÍA DE TRABAJO

El presente Trabajo de Integración Curricular constituye un requisito previo para la obtención del título de Ingenieras en la Carrera de alimentos de la Facultad de Industrias Agropecuarias y Ciencias Ambientales.

Nosotras, Jiménez Chávez Mayerli Lisbeth y Reyes Tonguino Adriana Patricia con cédula de identidad número 0450149067 y 1050159704 respectivamente declaramos que la investigación es absolutamente original, auténtica, personal y los resultados y conclusiones a los que hemos llegado son de nuestra absoluta responsabilidad.



Jiménez Chávez Mayerli Lisbeth

AUTORA



Reyes Tonguino Adriana Patricia

AUTORA

Tulcán, septiembre de 2026

ACTA DE CESIÓN DE DERECHOS DEL TRABAJO DE INTEGRACIÓN CURRICULAR

Nosotras Jiménez Chávez Mayerli Lisbeth y Reyes Tonguino Adriana Patricia declaramos ser autoras de los criterios emitidos en el Trabajo de Integración Curricular: "Modelamiento predictivo mediante deep learning de las características sensoriales y texturales de las galletas enriquecidas con nanopartículas de carbonato de calcio y su relación con las propiedades fisicoquímicas" y se exime expresamente a la Universidad Politécnica Estatal del Carchi y a sus representantes de posibles reclamos o acciones legales.



Jiménez Chávez Mayerli Lisbeth
AUTORA



Reyes Tonguino Adriana Patricia
AUTORA

Tulcán, septiembre de 2026

AGRADECIMIENTO

Quiero agradecer primero a Dios por darme la sabiduría y fortaleza suficiente para culminar esta etapa académica.

A mis padres, por su apoyo incondicional, sus sacrificios y por creer siempre en mí, porque sin su esfuerzo y dedicación este logro no habría sido posible; a mi hermana Mireya, por su compañía y aliento constante a lo largo de todo el camino.

A mis amigos, quienes de una u otra forma estuvieron presentes brindándome ánimo y compañía, y de manera especial a Jhonatan Chamorro, por estar siempre ahí apoyándome en los momentos difíciles y celebrando conmigo cada avance, incluso cuando yo misma dudaba de poder lograrlo.

A la Universidad Politécnica Estatal del Carchi, por abrirme sus puertas y brindarme la formación académica necesaria para mi desarrollo profesional. A mi tutor, por su guía, paciencia y disposición constante para orientarme a lo largo de este trabajo, su asesoría profesional fue fundamental para alcanzar los objetivos planteados.

Y finalmente, a la Red de Aprovechamiento Integral de Cereales, Pseudocereales, Tubérculos, Leguminosas y Raíces de Ecuador, su respaldo institucional permitió el desarrollo experimental de esta investigación.

A todos ellos, mi más sincero reconocimiento pues cada aporte por pequeño que parezca fue parte esencial en la construcción de este logro.

Mayerli Lisbeth Jiménez Chávez

A Dios por haberme permitido llegar hasta este punto, llenarme de fortaleza en medio del dolor.

A mis padres y hermanos, por su apoyo incondicional en cada etapa de este camino, gracias por ser mi motor.

A mi tutor, PhD. Marco Burbano por su acompañamiento durante el proceso, por su apoyo, por confiar en nosotras y en nuestras capacidades. Su dedicación y compromiso fueron fundamentales para poder culminar este trabajo de investigación con éxito.

A mis compañeros Lucia, Toa y Jhonatan, por compartir conmigo este camino, brindarme su apoyo en cada etapa universitaria.

Finalmente, agradezco a todo el cuerpo docente de la carrera de alimentos, a la Red de Aprovechamiento Integral de Cereales, Pseudocereales, Tubérculos, Leguminosas y Raíces de Ecuador, por la colaboración, la cual contribuyó al desarrollo experimental de la investigación.

Adriana Patricia Reyes Tonguino

DEDICATORIA

Dedico este trabajo ante todo a Dios, quien me dio la vida y me acompañó a lo largo de este camino hasta poder alcanzar esta etapa tan significativa de mi formación profesional. A mis padres, por ser el motor de cada uno de mis pasos, por su esfuerzo constante y su amor incondicional, que hoy llevo con orgullo sabiendo que este logro también les pertenece. A mi hermana Mireya, por su compañía incondicional y por estar siempre presente en cada etapa de mi vida, alentándome con su cariño incluso en los días más difíciles de este proceso. Y a mis amigos, por su apoyo sincero y presencia constante, en especial a Jhonatan Chamorro, por creer en mi incluso cuando yo dejaba de hacerlo, y por convertirse en una parte importante de este camino que hoy llega a su fin.

Con todo mi cariño les dedico este trabajo fruto de esfuerzo, paciencia y perseverancia.

Mayerli Lisbeth Jiménez Chávez

Dedico este trabajo de investigación a mi tía, que, aunque ya no esté físicamente conmigo su esencia estará siempre en mi corazón, este logro también es suyo. A mi familia, por ser mi pilar, por su amor y apoyo incondicional que me han acompañado en cada paso de este camino y a mi pareja por siempre estar a mi lado alentándome a seguir adelante sin importar las circunstancias.

Adriana Patricia Reyes Tonguino

ÍNDICE

RESUMEN	15
ABSTRACT.....	16
INTRODUCCIÓN	17
I. EL PROBLEMA	18
1.1. PLANTEAMIENTO DEL PROBLEMA	18
1.2. FORMULACIÓN DEL PROBLEMA	19
1.3. JUSTIFICACIÓN	19
1.4. OBJETIVOS Y PREGUNTAS DE INVESTIGACIÓN.....	21
1.4.1. Objetivo General	21
1.4.2. Objetivos Específicos	21
1.4.3. Preguntas de Investigación	21
II. FUNDAMENTACIÓN TEÓRICA	22
2.1. ANTECEDENTES DE LA INVESTIGACIÓN	22
2.2. MARCO TEÓRICO.....	26
2.2.1. Generalidades sobre productos de panificación y galletas.....	26
2.2.2. Galletas sin gluten y alimentos funcionales.....	28
2.2.3. Materias primas no convencionales: chocho y amaranto	30
2.2.4. Nanotecnología en alimentos.....	33
2.2.5. Propiedades fisicoquímicas de productos de panificación.....	36
2.2.6. Propiedades reológicas y texturales	39
2.2.7. Análisis sensorial de alimentos	41
2.2.8. Relación entre propiedades fisicoquímicas, texturales y sensoriales	44
2.2.9. Inteligencia artificial en la ciencia de alimentos	48

2.2.10. Modelamiento predictivo con Deep Learning	51
2.2.11. Métricas de evaluación de modelos predictivos	53
2.2.12. Aplicación del Deep Learning en productos de panificación	55
2.2.13. Integración del enfoque: alimentos + IA	58
III. METODOLOGÍA.....	62
3.1. ENFOQUE METODOLÓGICO	62
3.1.1. Enfoque	62
3.1.2. Tipo de Investigación	62
3.2. HIPÓTESIS	63
3.3. DEFINICIÓN Y OPERACIONALIZACIÓN DE LAS VARIABLES	63
3.3.1. Definición de las variables	63
3.3.2. Operacionalización de las variables	64
3.4. MÉTODOS UTILIZADOS	65
3.4.1. Proceso de elaboración de galletas y métodos	65
3.4.2. Caracterización fisicoquímica.....	66
3.4.3. Textura de galletas	72
3.4.4. Análisis sensorial	73
3.4.5. Desempeño del modelo Deep learning	73
3.5 DISEÑO EXPERIMENTAL	73
3.5.1. Análisis Estadístico	73
3.5.2. Tratamientos.....	74
3.5.3. Formulación de las galletas	74
IV. RESULTADOS Y DISCUSIÓN007A	75
4.1. RESULTADOS.....	75
4.1.1. Caracterización de los tratamientos formulados	75
4.1.2. Desarrollo del modelo de optimización	94

4.1.3. Validación del modelo optimizado	111
4.2. DISCUSIÓN	131
4.2.1. Caracterización de los tratamientos formulados	131
4.2.2. Desarrollo del modelo de optimización	136
4.2.3. Validación del modelo optimizado	138
V. CONCLUSIONES Y RECOMENDACIONES	144
5.1. CONCLUSIONES	144
5.2. RECOMENDACIONES	146
VI. REFERENCIAS BIBLIOGRÁFICAS	148
VII. ANEXOS	160

ÍNDICE DE TABLAS

Tabla 1. Contenido nutricional del amaranto	31
Tabla 2. Contenido nutricional del chocho	32
Tabla 3. Operacionalización de las variables para el tema “Modelamiento predictivo mediante Deep Learning de las características sensoriales y texturales de galletas enriquecidas con nanopartículas de carbonato de calcio y su relación con las propiedades fisicoquímicas”	64
Tabla 4. Análisis textural.....	73
Tabla 5. Formulación de tratamientos	74
Tabla 6. Ingredientes	74
Tabla 7. Prueba de Kruskal-Wallis + Dunn para acidez.	75
Tabla 8. Prueba de Kruskal-Wallis para acidez.	75
Tabla 9. Prueba de ANOVA + Tukey para almidón.	76
Tabla 10. Prueba de ANOVA para almidón.	76
Tabla 11. Prueba de ANOVA + Tukey para carbohidratos.....	77
Tabla 12. Prueba de ANOVA para carbohidratos.....	77
Tabla 13. Prueba de ANOVA + Tukey para cenizas.	78
Tabla 14. Prueba de ANOVA para cenizas.....	78
Tabla 15. Prueba de ANOVA +Tukey para extracto etéreo.....	79
Tabla 16. Prueba de ANOVA para extracto etéreo.	79
Tabla 17. Prueba de Kruskal-Wallis+ Dunn para fibra.	80
Tabla 18. Prueba de Kruskal-Wallis para fibra.....	80
Tabla 19. Prueba de Kruskal-Wallis + Dunn para humedad.	81
Tabla 20. Prueba de Kruskal-Wallis para humedad.	81
Tabla 21. Prueba de ANOVA+Tukey para proteína.....	82
Tabla 22. Prueba ANOVA para proteína.....	82
Tabla 23. Prueba de ANOVA + Tukey para dureza.	83
Tabla 24. Prueba de ANOVA para dureza.....	83
Tabla 25. Prueba de ANOVA + Tukey para fracturabilidad.	84
Tabla 26. Prueba de ANOVA para fracturabilidad.....	84
Tabla 27. Prueba de ANOVA + Tukey para cohesividad.....	85
Tabla 28. Prueba de ANOVA para cohesividad.	85
Tabla 29. Prueba de Kruskal-Wallis + Dunn para masticabilidad.....	86
Tabla 30. Prueba de Kruskal-Wallis para masticabilidad.	86
Tabla 31. Prueba Kruskal-Wallis + Dunn para trabajo realizado.....	87
Tabla 32. Prueba de Kruskal-Wallis para trabajo realizado.	87
Tabla 33. Atributo de color en galleta.....	89
Tabla 34. Atributo de Olor en galleta.....	89
Tabla 35. Atributo de sabor en galleta.	89
Tabla 36. Atributo de crujencia en galleta.	90
Tabla 37. Atributo de textura quebradiza en galleta.	90
Tabla 38. Atributo de dureza en galleta.....	91
Tabla 39. Atributo de aceptabilidad en galleta.	91
Tabla 40. Análisis PCA	94
Tabla 41. PCA de Variables	94
Tabla 42. PCA de tratamientos	94
Tabla 43. MFA de grupos	95
Tabla 44. MFA de tratamientos	95
Tabla 45. MFA de variables.....	95

Tabla 46. Métricas de desempeño del modelo PLS para atributos texturales instrumentales.....	98
Tabla 47. Métricas de desempeño del modelo PLS para atributos sensoriales.....	98
Tabla 48. Valores VIP de variables fisicoquímicas en el modelo PLS.....	99
Tabla 49. Métricas de desempeño del modelo de red neuronal para las variables texturales instrumentales.....	101
Tabla 50. Métricas de desempeño del modelo de red neuronal para los atributos sensoriales.....	101
Tabla 51. Valores observados de los atributos texturales instrumentales por tratamiento.....	102
Tabla 52. Valores predichos de los atributos texturales instrumentales por tratamiento.....	103
Tabla 53. Valores observados de los atributos sensoriales por tratamiento.....	104
Tabla 54. Valores predichos de los atributos sensoriales por tratamiento.....	105
Tabla 55. Formulación óptima continua estimada mediante función de deseabilidad global.....	110
Tabla 56. Prueba de Kruskal-Wallis + Dunn para acidez en el tratamiento optimizado.....	111
Tabla 57. Prueba de Kruskal-Wallis + Dunn para almidón en el tratamiento optimizado.....	112
Tabla 58. Prueba de ANOVA + Tukey para carbohidratos totales en el tratamiento optimizado.....	113
Tabla 59. Prueba de ANOVA+Tukey para ceniza en el tratamiento optimizado.....	114
Tabla 60. Prueba ANOVA+Tukey para extracto etéreo en el tratamiento optimizado.....	115
Tabla 61. Prueba de Kruskal-Wallis + Dunn para fibra en el tratamiento optimizado.....	116
Tabla 62. Prueba de ANOVA+Tukey para humedad en el tratamiento optimizado.....	117
Tabla 63. Prueba de ANOVA+Tukey para proteína en el tratamiento optimizado.....	118
Tabla 64. Prueba de ANOVA+Tukey para dureza en el tratamiento optimizado.....	119
Tabla 65. Prueba de ANOVA+Tukey para fracturabilidad en el tratamiento optimizado.....	120
Tabla 66. Prueba ANOVA+Tukey para cohesividad en el tratamiento optimizado.....	121
Tabla 67. Prueba Kruskal-Wallis + Dunn para masticabilidad en el tratamiento optimizado.....	122
Tabla 68. Prueba de Kruskal-Wallis + Dunn para trabajo realizado en el tratamiento optimizado.....	123
Tabla 69. Atributo de color para galletas en el tratamiento optimizado.....	124
Tabla 70. Atributo de sabor para galletas en el tratamiento optimizado.....	125
Tabla 71. Atributo de olor para galletas en el tratamiento optimizado.....	126
Tabla 72. Atributo de crujencia para galletas en el tratamiento optimizado.....	127
Tabla 73. Atributo de dureza para galletas en el tratamiento optimizado.....	128
Tabla 74. Atributo de aceptabilidad para galletas en el tratamiento optimizado.....	129
Tabla 75. Atributo textura para galletas en el tratamiento optimizado.....	130

ÍNDICE DE FIGURAS

Figura 1. Planta de chocho	30
Figura 2. Planta de amaranto	31
Figura 3. Diagrama de galletas de harina de amaranto y chocho.	65
Figura 4. Diagrama caja y bigote para acidez.....	76
Figura 5. Diagrama de caja y bigote para almidón.	77
Figura 6. Diagrama de caja y bigote para carbohidratos.....	78
Figura 7. Diagrama de caja y bigote para cenizas.....	79
Figura 8. Diagrama de caja y bigote para extracto etéreo.....	80
Figura 9. Diagrama de caja y bigote para fibra.....	81
Figura 10. Diagrama de caja y bigote para humedad.....	82
Figura 11. Diagrama de caja y bigote para proteína.....	83
Figura 12. Diagrama de caja y bigote para dureza.....	84
Figura 13. Diagrama de caja y bigote para fracturabilidad.	85
Figura 14. Diagrama de caja y bigote para cohesividad.....	86
Figura 15. Diagrama de caja y bigote para masticabilidad.	87
Figura 16. Diagrama de caja y bigote para trabajo realizado.	88
Figura 17. Diagrama de caja y bigote para aceptabilidad.....	91
Figura 18. Diagrama de caja y bigote para sabor.....	92
Figura 19. Diagrama de caja y bigote para crujencia.....	92
Figura 20. Diagrama de caja y bigote para textura quebradiza.....	93
Figura 21. Diagrama de caja y bigote para dureza.....	93
Figura 22. Biplot tratamientos y variables.....	96
Figura 23. Matriz de correlación.....	96
Figura 24. Círculo de correlación de variables.....	97
Figura 25. Contribución de bloques.....	97
Figura 26. Importancia de variables predictoras según VIP.....	100
Figura 27. Observado vs predicho: dureza.....	106
Figura 28. Observado vs predicho: fracturabilidad.....	106
Figura 29. Observado vs predicho: masticabilidad.....	107
Figura 30. Observado vs predicho: sabor sensorial.....	108
Figura 31. Observado vs predicho: crujencia sensorial.....	108
Figura 32. Observado vs predicho: aceptabilidad sensorial.....	109
Figura 33. Curva de deseabilidad global continua en función del porcentaje de sustitución con harina de <i>Lupinus mutabilis</i>	110
Figura 34. Diagrama y caja de bigote de acidez- tratamiento optimizado.....	112
Figura 35. Diagrama y caja de bigote de almidón- tratamiento optimizado.....	113
Figura 36. Diagrama y caja de bigote de carbohidratos totales- tratamiento optimizado.....	114
Figura 37. Diagrama y caja de bigote de cenizas -tratamiento optimizado.....	115
Figura 38. Diagrama y caja de bigote de extracto etéreo- tratamiento optimizado.....	116
Figura 39. Diagrama y caja de bigote de fibra- tratamiento optimizado.....	117
Figura 40. Diagrama y caja de bigote de humedad -tratamiento optimizado.....	118
Figura 41. Diagrama y caja de bigote de proteína- tratamiento optimizado.....	119
Figura 42. Diagrama y caja de bigote de dureza-tratamiento optimizado.....	120
Figura 43. Diagrama y caja de bigotes de fracturabilidad-tratamiento optimizado.....	121
Figura 44. Diagrama y caja de bigote de cohesividad-tratamiento optimizado.....	122
Figura 45. Diagrama y caja de bigote de masticabilidad-tratamiento optimizado.....	123

Figura 46. Diagrama y caja de bigote de trabajo realizado-tratamiento optimizado.	124
Figura 47. Diagrama y caja de bigote de Friedman para color-tratamiento optimizado.	125
Figura 48. Diagrama y caja de bigote para sabor-tratamiento optimizado.....	126
Figura 49. Diagrama y caja de bigote para olor-tratamiento optimizado.....	127
Figura 50. Diagrama y caja de bigote para crujencia-tratamiento optimizado.....	128
Figura 51. Diagrama y caja de bigote para dureza-tratamiento optimizado.	129
Figura 52. Diagrama y caja de bigote para aceptabilidad-tratamiento optimizado.	130
Figura 53. Diagrama y caja de bigote para textura quebradiza-tratamiento optimizado.	131
Figura 54. Preparación de ácidos para los análisis fisicoquímicos	162
Figura 55. Tamizar la harina para obtener una muestra más fina	162
Figura 56. Peso del crisol para determinar humedad	162
Figura 57. Determinación de cenizas por incineración.....	162
Figura 58. Determinación de acidez en la muestra.....	162
Figura 59. Determinación de fibra-Método weende	162
Figura 60. Determinación de almidón en harinas	163
Figura 61. Determinación de grasa por el método de Soxhlet.....	163
Figura 62. Proceso de digestión y destilación para proteína	163
Figura 63. Análisis de TPA en galletas.....	164
Figura 64. Análisis de textura en los tratamientos.....	165
Figura 65. Elaboración de galletas.....	166
Figura 66. Cata sensorial de las galletas	166

ÍNDICE DE ANEXOS

Anexo 1. Certificado del abstract por parte de idiomas.....	160
Anexo 2. Análisis fisicoquímico de las harinas de amaranto con chocho.....	162
Anexo 3. Análisis textural en galletas	164
Anexo 4. Análisis sensorial de galletas	166
Anexo 5. Normativa INEN 2085: 2005 para galletas	167
Anexo 6. Ficha de evaluación sensorial para galletas	172

RESUMEN

El presente estudio tuvo como objetivo modelar, mediante *Deep Learning*, la relación entre las propiedades fisicoquímicas y las características sensoriales y texturales de galletas sin gluten elaboradas con harinas de amaranto (*Amaranthus spp.*) y chocho (*Lupinus mutabilis*), enriquecidas con nanopartículas de carbonato de calcio, con el propósito de optimizar su formulación. Se evaluaron diferentes tratamientos mediante análisis fisicoquímicos (humedad, proteína, grasa, fibra, cenizas, carbohidratos, almidón y acidez), pruebas instrumentales de textura y análisis sensorial de aceptabilidad. Posteriormente, se desarrollaron y validaron modelos predictivos basados en redes neuronales profundas, comparando su desempeño con modelos estadísticos convencionales. Los resultados demostraron que el modelo de *Deep Learning* presentó una elevada capacidad predictiva, alcanzando coeficientes de determinación (R^2) entre 0,8902 y 0,9911 para las variables texturales y entre 0,9942 y 0,9996 para los atributos sensoriales, superando ampliamente el desempeño del modelo PLS. Asimismo, la optimización mediante la función de deseabilidad global identificó como formulación óptima una sustitución de 83,19 % de harina de amaranto y 16,81 % de harina de chocho, correspondiente al tratamiento T5, el cual presentó el mejor equilibrio entre las propiedades fisicoquímicas, texturales y sensoriales. La validación experimental confirmó la coherencia de esta formulación con los valores predichos por el modelo, evidenciando un adecuado comportamiento tecnológico y una elevada aceptabilidad del producto desarrollado. Se concluye que la integración de materias primas andinas de alto valor nutricional con herramientas de inteligencia artificial constituye una estrategia innovadora para optimizar el desarrollo de productos de panificación sin gluten, reducir la experimentación convencional y apoyar la toma de decisiones en el diseño de alimentos funcionales con mayor eficiencia y precisión.

Palabras Claves: Inteligencia artificial; alimentos funcionales; galletas sin gluten; *Lupinus mutabilis*; *Amaranthus spp.*

ABSTRACT

This study aimed to model, through Deep Learning, the relationship between the physicochemical properties and the sensory and textural characteristics of gluten-free cookies produced from amaranth (*Amaranthus spp.*) and lupin (*Lupinus mutabilis*) flours enriched with calcium carbonate nanoparticles, in order to optimize their formulation. Different formulations were evaluated through physicochemical analyses (moisture, protein, fat, fiber, ash, carbohydrates, starch, and acidity), instrumental texture measurements, and sensory acceptability tests. Subsequently, predictive models based on deep neural networks were developed and validated, and their performance was compared with conventional statistical models. The results demonstrated that the Deep Learning model exhibited high predictive performance, achieving coefficients of determination (R^2) ranging from 0.8902 to 0.9911 for textural variables and from 0.9942 to 0.9996 for sensory attributes, substantially outperforming the Partial Least Squares (PLS) model. Furthermore, optimization using the global desirability function identified the optimal formulation as 83.19% amaranth flour and 16.81% lupin flour, corresponding to treatment T5, which provided the best balance between physicochemical, textural, and sensory properties. Experimental validation confirmed the consistency between the predicted and observed values, demonstrating the technological suitability and high consumer acceptability of the optimized formulation. It is concluded that integrating nutrient-rich Andean raw materials with artificial intelligence techniques represents an innovative strategy for optimizing the development of gluten-free bakery products, reducing conventional experimental efforts, and supporting decision-making in the design of functional foods with greater efficiency and accuracy.

Keywords: Artificial intelligence; functional foods; gluten-free cookies; *Lupinus mutabilis*; *Amaranthus spp.*

INTRODUCCIÓN

En el ámbito alimentario, la aplicación de modelos de Deep learning ha permitido predecir características texturales, vida útil y aceptación sensorial de productos procesados, mejorando sus limitaciones de los métodos estadísticos convencionales frente a sistemas de alta complejidad (Jeon et al., 2022). Estos modelos para predecir son eficaces en el desarrollo de alimentos funcionales, donde la incorporación de ingredientes nanomateriales da lugar a interacciones que son complejas de modelar mediante regresiones lineales o diseños factoriales tradicionales. Por lo tanto, incluir la IA en el control de calidad de los alimentos es un progreso significativo para el sector industrial y la investigación científica (Zhou, 2019).

El desarrollo de productos funcionales ha obtenido relevancia los últimos años, incentivando la necesidad de fortalecer el perfil nutricional de alimentos con bajo contenido en gluten, la tendencia hacia la ingesta de alimentos sin gluten en Ecuador ha crecido notablemente el aumento de los casos de celiaquía, una enfermedad que causa daños al intestino delgado y dificulta la digestión de esta proteína. La enfermedad celíaca afecta al 1% de los habitantes en el mundo (Hidalgo, 2025).

Los granos andinos como chocho y amaranto son reconocidos como superalimentos debido a su alto valor nutricional y bajo contenido en gluten, su incorporación mejora el perfil proteico y funcional ambos cultivos no han sido aprovechados dentro del mercado a pesar de sus beneficios (Sindhuja, 2019).

El presente trabajo de investigación se desarrolló con la finalidad de modelar mediante Deep learning las características sensoriales y texturales de galletas enriquecidas con nanopartículas de carbonato de calcio y su relación con las propiedades fisicoquímicas. Los resultados indicaron que la formulación optimizada obtuvo mejor aceptabilidad en los atributos sensoriales y texturales.

La innovación en productos funcionales de galletería crea una alternativa, contribuye a la demanda creciente de alimentos sin gluten. Esta investigación posibilita el aprovechamiento de los granos andinos como materia prima para el desarrollo de alimentos con valor agregado.

I. EL PROBLEMA

1.1. PLANTEAMIENTO DEL PROBLEMA

En la actualidad, la industria alimentaria ha adoptado tecnologías de aprendizaje automático (Machine Learning) y aprendizaje profundo (Deep Learning) para el diseño y desarrollo de productos funcionales que ofrecen beneficios para la salud más allá de la nutrición básica. Asimismo, las demandas de los consumidores por productos de mayor calidad, seguridad e inocuidad han impulsado la búsqueda de estas tecnologías más eficientes. Sin embargo, su implementación en el sector alimentario es limitada debido a varios factores críticos. En primer lugar, los sistemas alimentarios son muy complejos de predecir y desarrollar, y la capacidad del Deep Learning para comprender, captar la atención y transformar las demandas del consumidor en atributos fisicoquímicos y sensoriales del producto final sigue siendo uno de los mayores desafíos (Sarayreh, 2023). Adicionalmente, aunque el avance tecnológico ha introducido herramientas innovadoras que prometen optimizar procesos de inspección y control de calidad, estos modelos son difíciles de interpretar y validar. Por último, en el ámbito tecnológico y científico requiere de grandes volúmenes de datos para su correcto funcionamiento y existe muy poca personal capacitado que pueda desarrollar, implementar y mantener estos sistemas en entornos productivos de alimentos (Fuentes, 2022).

Particularmente en la última década, la aplicación de modelos de aprendizaje profundo en la ciencia de alimentos ha crecido significativamente en áreas como la clasificación de alimentos, detección de adulteraciones y control de calidad. No obstante, persiste una carencia importante de estudios que utilicen y validen modelos para predecir características sensoriales y texturales en productos de panificación, especialmente en productos sin gluten (Dumin, 2025). Esta limitación se agrava por la débil correlación documentada entre las propiedades fisicoquímicas de ingredientes funcionales y el comportamiento sensorial y textural de los productos finales, lo cual impide el desarrollo racional de productos aceptables por el consumidor. Aunque el Deep Learning posee un gran potencial para modelar estas complejas interacciones,

este recurso permanece escasamente explorado y subutilizado en la industria (Zhou, 2019).

En el mismo contexto, la tendencia hacia el consumo de alimentos y dietas exentos o libres de gluten en Ecuador, ha ido en aumento debido al incremento de casos de celiaquía, que se caracteriza por la incapacidad del cuerpo para digerir esta proteína, generando daños en el revestimiento del intestino delgado y afectando de una manera considerable el sistema inmunitario (Buzzdev, 2021). La celiaquía afecta aproximadamente al 1% de la población en el país, se estima que alrededor de 3 de cada 200 individuos ha sido diagnosticado con dicha enfermedad (Rojas y Villalobos, 2021).

El gluten presente en los cereales como el trigo contiene alrededor del 80% de las proteínas, que para personas sanas aporta fibras, vitaminas y minerales. Sin embargo, acorde a la investigación de Aguirre (2025), para personas que padecen de la enfermedad celíaca, el consumo desenfrenado de esta proteína puede ser perjudicial para su salud, porque provoca mala absorción de los nutrientes. Por otro lado, el consumo de alimentos libres de gluten sin un complemento apropiado de compuestos bioactivos, minerales y vitaminas puede ser perjudicial para la salud e incluso contribuir al desarrollo de obesidad y enfermedades cardiovasculares (Sánchez, 2022).

De acuerdo con lo anterior, el amaranto y el chocho son muy famosos en la cultura andina por estar exentos de gluten y su valor nutricional, pero su uso en las dietas cotidianas continúa siendo limitado, por la falta de documentación y conocimiento sobre sus beneficios. La industria alimentaria no aprovecha adecuadamente estas materias primas para el desarrollo de productos innovadores que puedan satisfacer las demandas de alimentos nutritivos y funcionales (Sindhuja, 2019).

1.2. FORMULACIÓN DEL PROBLEMA

¿Cómo influye el modelamiento predictivo mediante deep learning de las características sensoriales y texturales de galletas enriquecidas con nanopartículas de carbonato de calcio y su relación con las propiedades fisicoquímicas?

1.3. JUSTIFICACIÓN

El presente estudio se realiza con la finalidad de determinar por medio de Deep learning la relación entre las propiedades fisicoquímicas de galletas sin gluten

enriquecidas con nanopartículas de carbonato de calcio y sus características sensoriales y texturales. Actualmente se busca alternativas de variar aditivos e ingredientes sin el contenido de gluten con la finalidad de beneficiar y aportar un valor sano, tomando en cuenta el valor nutricional presente en la harina de chocho y amaranto.

La implementación de harina de chocho y amaranto genera expectativas en el uso de la industria de panificación esencialmente en galletas, debido a su alto valor nutricional. Según Valladares y otros (2025), para este año se espera un crecimiento de alrededor del 14%, de la implementación de dichas harinas con la finalidad de introducir la obtención de productos bajos en gluten.

En la actualidad, la adaptabilidad a la inteligencia artificial ha generado nuevas alternativas para análisis poco conocidos y convencionales, adentrándose a la nueva era digital, Deep learning es una nueva rama proveniente de la creación de inteligencias artificiales, con la finalidad del aprendizaje automatizado. Su utilidad se extiende a varios enfoques desde visualización en un computador hasta la medicina, debido a su gran capacidad para superar ciertas limitaciones en métodos tradicionales (Zeltzin, 2026).

Según Mora (2022), Deep learning permite desarrollar un sistema inteligente capaz de identificar e inspeccionar cada galleta de madera individual, esta inteligencia ofrece un control sobre la red neuronal garantizando resultados confiables, una de las principales ventajas de Deep learning es su capacidad para optimizar el rendimiento mediante la paralelización, lo que reduce significativamente el tiempo de procesamiento. El uso de Deep learning en la industria de los alimentos, está en crecimiento como una herramienta para detectar y clasificar los productos libres o bajos de gluten principalmente en harinas y pan, a partir de imágenes y datos espectroscópicos, ofreciendo soluciones rápidas y precisas, mejorando la seguridad alimentaria, generando nuevas expectativas para la elaboración de productos aptos para celíacos, alimentos bajo en gluten.

1.4. OBJETIVOS Y PREGUNTAS DE INVESTIGACIÓN

1.4.1. Objetivo General

Modelar mediante deep learning la relación entre las propiedades fisicoquímicas de galletas sin gluten enriquecidas con nanopartículas de carbonato de calcio y sus características sensoriales y texturales.

1.4.2. Objetivos Específicos

- Evaluar las características fisicoquímicas de las diferentes formulaciones de harinas.
- Analizar la influencia de la incorporación progresiva de harina de chocho por la de amaranto en la percepción sensorial y características texturales en el producto.
- Diseñar e implementar modelos de deep learning para predecir atributos sensoriales y texturales.
- Validar los modelos y proponer mejoras en la formulación basadas en los resultados obtenidos.

1.4.3. Preguntas de Investigación

- ¿Cómo se correlacionan los parámetros sensoriales, físicos y texturales en los diferentes tratamientos formulados?
- ¿Cómo influye la incorporación progresiva de harina de chocho por la de amaranto en productos de galletería en la percepción sensorial y textural?
- ¿Qué características tiene el modelo predictivo deep learning que permita predecir atributos sensoriales y texturales del producto desarrollado?
- ¿Qué tipo de mejoras se pueden apreciar con los modelos desarrollados a partir de deep learning?

II. FUNDAMENTACIÓN TEÓRICA

2.1. ANTECEDENTES DE LA INVESTIGACIÓN

Parreño y otros (2025), en su investigación titulada "Elaboración de una galleta a partir de la mezcla de harinas de granos andinos del Ecuador: quinua (*Chenopodium quinoa*) y amaranto (*Amaranthus*)" obtuvo un 5,47% de fibra, un 3,20% de humedad, un 14,3% de grasa y un 1,44% de cenizas; las proteínas constituyeron el 9,69%. Estos hallazgos indican que las galletas son una buena fuente de nutrientes esenciales, y que la mezcla de amaranto y harina de quinua potencia tanto el valor nutricional del producto como sus características organolépticas. Esta investigación apoya que la combinación de harina de amaranto y quinua puede ser una alternativa factible para elevar la calidad nutricional de productos horneados que se consumen mucho, como las galletas.

Párraga (2023), en la investigación titulada "Elaboración de galletas con sustitución parcial de harina de trigo por harina de fréjol de palo y fréjol castilla" planteó la sustitución de harinas para comprobar cuál es más apta para la elaboración de galleta, utilizando harinas obtenidas del procesamiento de los fréjoles de palo y castilla. Los procesos que intervinieron para la obtención de las harinas para ambos fréjoles, los cuales en la etapa de secado se realizó por medio de un horno dentro de un período entre 4 – 6 horas a una temperatura de 150°C para los dos fréjoles; alcanzando en el procesamiento un rendimiento para la harina de fréjol de palo de 47,15% y para la harina de fréjol castilla de 50,25%; por lo que los fréjoles de palo y castilla son excelentes en la obtención de las harinas para la fabricación de las galletas. Se puede afirmar que la mezcla de harina de trigo y de fréjol castilla es beneficiosa para elevar el valor nutricional en la elaboración de galletas, lo cual las vuelve aptas para ser consumidas.

Yanalá y otros (2024) desarrollaron la investigación titulada "Formulación de una galleta funcional para el aprovechamiento de las propiedades nutricionales de la harina de chocho (*Lupinus mutabilis*)" este estudio desarrolló una galleta funcional

utilizando harina de chocho, examinando sus características reológicas, fisicoquímicas y de textura, así como su aceptabilidad a través de análisis sensoriales. El análisis de textura mostró una fracturabilidad y durezas más elevadas. Por último, el estudio reológico efectuado en Mixolab mostró que la harina de chocho tiene un desarrollo de masa (120 Nm) y una capacidad de hinchamiento (0.50 Nm) similares a los de la harina de trigo. La investigación indica que la galleta de harina de chocho podría ser una opción viable de snack para personas celíacas, con un alto contenido proteico y un nivel de aceptabilidad placentero para toda clase de consumidor.

Chauhan y otros (2021) llevaron a cabo la investigación titulada "Physical, textural, and sensory characteristics of wheat and amaranth flour blend cookies" en la cual se trabajó el comportamiento de horneado de las galletas y los efectos que producen las sustituciones de amaranto integral en distintas proporciones. Se elaboraron seis variedades de galletas con harina integral de amaranto que poseen concentraciones del 20, 40, 60, 80 y el 100%. Se evaluaron estas galletas con respecto a sus características físicas (grosor, diámetro, relación de extensión y pérdida durante el horneado), así como su textura y propiedades organolépticas. Se observó que las galletas de harina de amaranto integral tenían un diámetro y relaciones de extensión más elevadas, en concreto 52,20 mm y 6,46 respectivamente. Estos valores eran superiores a los que presentaban otras mezclas (20-80 %) de galletas, en las que el diámetro era de entre 51,37 y 51,92 mm y la relación de extensión oscilaba entre 6,13 y 6,36. La dureza de las galletas se redujo con la incorporación de harina de amaranto, según lo indicado por la medición de textura. Las galletas de harina integral de amaranto necesitaron una fuerza de chasquido menor (72,4 N) que las galletas control (las elaboradas con harina integral de trigo) (145 N). La harina de amaranto adicional obtuvo una puntuación media más baja en cuanto a la aceptabilidad general, pero las galletas de amaranto con un 60% o menos fueron consideradas aceptables.

Carrillo (2020), en su investigación titulada "Evaluación de la calidad bromatológica y sensorial de galletas con sustitución parcial de harina trigo (*Triticum spp*) por amaranto (*Amaranthis spp*)", tuvo como objetivo analizar la calidad sensorial de las galletas en las que se reemplazó parcialmente la harina de trigo (*Triticum spp*) por amaranto (*Amaranthus spp.*). Los resultados del análisis Sensorial demostraron que los tratamientos T1, T3 y T7 obtuvieron mayor aceptación en los tributos de sabor, color, textura, olor y aceptabilidad. Asimismo, el análisis microbiológico evidenció la

ausencia total de aerobios mesófilos, mohos y levaduras, cumpliendo con los parámetros normativos establecidos y garantizando la seguridad alimentaria del producto.

Cayambe (2023), desarrolló la investigación titulada "Elaboración de galletas con harina de chocho y quinua, endulzadas con miel de abeja", en este estudio se buscó desarrollar galletas con harina de chocho y quinua, que fueran endulzadas con miel de abeja. Se examinaron las galletas con distintos grados de esta miel (10, 15 y 20%) y un tratamiento control (sin miel), en el análisis sensorial el mejor nivel aceptable fue el T3 concluyendo que las galletas con el 20% de miel, presentó mayor aceptación.

López (2019), en su investigación titulada "Application of Deep Learning in Food" realizaron un estudio de Deep Learning como instrumento para el análisis de datos y la solución de dificultades en el sector alimentario. Se examinó, además, la capacidad del aprendizaje profundo como una herramienta avanzada para la investigación sensorial y el consumo de alimentos. Como resultado, señala que el aprendizaje profundo es superior a otros procedimientos, como los extractores manuales de características y los algoritmos tradicionales de aprendizaje automático, así como un instrumento prometedor para verificar la calidad y la seguridad alimentaria.

Vidal y otros (2024), en su investigación denominada "Neural networks allow the automatic verification of the type of flour, analysing the starch granule morphology, to ensure the protected geographical indication 'Galician Bread'", su objetivo principal fue automatizar la identificación, segmentación y determinación del tamaño medio de los gránulos de almidón en harinas para el control de calidad del "Pan Gallego". Desarrollaron un estudio experimental utilizando el modelo predictivo Deep Learning para la predicción del tipo y tamaño de gránulos de almidón, su muestra incluyó un conjunto de datos de 1308 imágenes microscópicas (2564 × 1924 píxeles) conteniendo 17000 gránulos de almidón etiquetados para dos tipos de trigo: harina comercial "Castillas" (tipo 0) y harina autóctona gallega "Caaveiro" (tipo 1). Los resultados demostraron que el modelo alcanzó una precisión global categórica de aproximadamente 88,6%, con una discrepancia respecto a las áreas de los gránulos estimados por expertos humanos inferior al 4%. El estudio concluyó que existe una fuerte correlación entre los resultados de expertos y los de la red neuronal, confirmando la validez práctica de la propuesta para automatizar un proceso que realizado manualmente resulta complejo y consume mucho tiempo.

Elyashar y otros (2025) realizaron la investigación titulada "Automated Gluten Detection in Bread Images Using Convolutional Neural Networks" su objetivo principal fue detectar la presencia de gluten en pan a través del análisis de imágenes mediante el modelo RGB (Reconocimiento de Gluten en Pan) utilizando Deep Learning. Para desarrollar de este método, emplearon un diseño experimental usando tres conjuntos de datos únicos de imágenes de pan. Este estudio concluyó que la detección de gluten basada en imágenes es viable en productos panificados, ofreciendo una alternativa no invasiva y rentable a los métodos tradicionales, permitiendo a personas con enfermedad celíaca obtener información inmediata sobre el contenido de gluten.

Rashvand y otros (2025) desarrollaron la investigación titulada "Quality detection of common beans flour using hyperspectral imaging technology: Potential of machine learning and deep learning" realizaron contenido de carbohidratos es uno de los factores más cruciales en la calidad de la harina de frijol común después del procesamiento. Este estudio determinó la calidad evaluando el contenido de carbohidratos utilizando la tecnología. Las muestras de este trabajo se compusieron de 12 variedades de frijol y cada variedad fue tratada mediante el método de hidratación-deshidratación. Después de varios pasos de preprocesamiento, se extrajeron características de los perfiles espectrales utilizando diferentes métodos de extracción. Se estableció la regresión de mínimos cuadrados parciales, la regresión de máquinas de vectores de soporte y la red convolucional temporal con atención para predecir el contenido de carbohidratos. Los mejores valores de R^2 , RMSE y RPD fueron 0,982, 0,165 y 4,905. Los resultados demostraron que, si bien deep learning presenta mayor precisión que los modelos de machine learning, estos últimos no solo proporcionaron una precisión aceptable y confiable, sino que también influyeron significativamente en el análisis temporal. Además, la visualización de los resultados de esta investigación reveló que los modelos y el sistema desarrollados pueden integrarse con sensores inteligentes para fines de digitalización.

Rina y otros (2026) realizaron la investigación titulada "Machine learning combined with sensory evaluation and multi-sensor technology to evaluate the overall quality of commercial soybean paste in China" realizaron una metodología actual con el fin de examinar de manera exhaustiva la calidad de la pasta de soja que se comercializa a través de una evaluación sensorial. Con el objetivo de detectar, se llevaron a cabo evaluaciones sensoriales en 33 variedades de pasta de soja comercial con tres tipos

de sensores: un colorímetro, una lengua electrónica (E-tongue) y una nariz electrónica (E-nose). Los hallazgos de las evaluaciones sensoriales y la detección por sensores indicaron diferencias notables entre las distintas pastas de soja. Con el uso de tres sensores, es posible diferenciar las pastas de soja. El modelo de caracterización cuantitativa, fundado en los datos de los sensores, mostró que el modelo SVR tuvo el coeficiente de determinación (R^2) más elevado, con un valor de 0,9998 para el conjunto de entrenamiento y 0,9970 para el conjunto de predicción; cifras muy cercanas a la ideal de 1. Asimismo, el error cuadrático medio del conjunto de predicción fue el menor, con un valor de 0,5359. Estos hallazgos indican que el modelo SVR tiene un rendimiento más alto en las pruebas y la validación cruzada, lo cual se ajusta de cerca a las percepciones sensoriales humanas, por lo que es considerado el modelo predictivo más efectivo. Este estudio enfatiza la capacidad de fusionar datos obtenidos de sensores con métodos contemporáneos de aprendizaje automático, con el fin de complementar las evaluaciones sensoriales tradicionales y conseguir una valoración y caracterización exhaustiva de la calidad de la pasta de soja. Los hallazgos de esta investigación brindan datos y guía importantes para el progreso y la optimización de la calidad en la industria de la pasta de soja.

2.2. MARCO TEÓRICO

2.2.1. Generalidades sobre productos de panificación y galletas

2.2.1.1. Definición y clasificación de productos de panificación

Las técnicas de producción y los productos de panificación varían considerablemente a nivel mundial; la finalidad de la panificación es transformar las harinas de cereales en alimentos sabrosos, atractivos y fáciles de digerir. La harina es el ingrediente primordial en los procesos de panificación, y la calidad de esta, junto con su idoneidad para el proceso y el producto a elaborar, influye significativamente en el resultado final. Hoy en día, la demanda de los consumidores en muchos países no se limita a pan de calidad, sino que también incluye una diversidad de productos (Valdez, 2022).

Tipos de panificación:

- Panes: Mezcla cuatro ingredientes básicos (levadura, sal, agua y harina) para hacer uno de los alimentos más antiguos, que está en casi todas las culturas.

- Brioche: Es un tipo de pan francés que se distingue por su interior esponjoso y sabroso. Incluye azúcar, mantequilla, leche, sal, levadura y harina.
- Pastelería: Incorpora productos tales como tartas, pasteles, pastelería fina y productos confeccionados con masa choux o cremas como el bavaoise.
- Galletas: Se clasifican en blandas o rellenas (tipo shortbread, sablé), secas y crujientes (tipo María, digestive), con una tradición artesana.

2.2.1.2. Importancia de las galletas en la industria alimentaria

La dieta de la sociedad contemporánea implica un consumo elevado de alimentos de bajo valor nutritivo, con altas concentraciones de grasas saturadas, azúcares refinados, aditivos, conservadores y elevado valor calórico. Se ha observado una tendencia ascendente en el consumo de alimentos, en el caso de productos de panadería, como las galletas, se ha registrado un consumo importante desde edades tempranas, convirtiéndose en unas de las opciones preferidas. Las galletas se definen como bocadillos obtenidos de pasta única o compuesta sometidas a un proceso de cocción en horno y se preparan generalmente de harina de trigo, sin embargo, se ha notado que el contenido nutricional se eleva en función de la materia prima empleada, como leguminosas, harina de trigo unida a soya o germen de maíz, y otros (Martínez et al., 2023).

2.2.1.3. Estructura y composición de las galletas

La mayor parte de las galletas se distinguen de otros productos horneados a partir de cereales debido a que contienen poca humedad. Los panes y pasteles acabados contienen un 35-40% y un 15-30% de humedad, respectivamente; por su parte, las galletas tienen solo entre el 1 y el 5%. Los componentes esenciales son la grasa, el azúcar y la harina de trigo; sin embargo, después de eso, las opciones son prácticamente ilimitadas. Las galletas tienen la posibilidad de ser agrupadas de diversas formas, en función de su dureza y textura, su transformación de forma durante el horneado y moldeado, la extensibilidad u otras propiedades de la masa o cómo se maneja esta última antes de que se forme la galleta. Estas diferencias en la formulación, el procesamiento y las características del producto final dependen de la consistencia o reología de la masa (Azike y Asogwa ,2020).

2.2.1.4. Factores que influyen en la calidad de galletas

La harina para galletas, que es un elemento clave para la elaboración, representa entre el 30 y el 40 % de la fórmula total y resulta indispensable si se quiere obtener unas

galletas de gran calidad. La harina de galletas, que tiene un contenido proteínico bajo, afecta la textura (dureza, crujido, masticabilidad, pegajosidad y fragilidad), el color (el tono) y la estructura. El tipo y la cantidad de harina empleada en el proceso de cocción inciden directamente sobre la calidad del producto final. La capacidad de extensión está relacionada con la transición vítrea de las proteínas del trigo durante la cocción. Las galletas hechas con harinas de bajo contenido proteico (menos del 12 %) tienden a extenderse más rápida y prolongadamente que las hechas con harinas de alto contenido proteico (Cristinaot, 2025).

2.2.2. Galletas sin gluten y alimentos funcionales

La industria de la panadería está en constante crecimiento, con innovaciones tanto en productos alimentarios como en métodos. El avance en la creación de versiones más saludables de galletas ha sido notable y tiene un rol relevante para los clientes que se preocupan más por su salud. No obstante, emplear el proceso de mejora para crear galletas con bajo contenido de gluten es una labor complicada que consume mucho tiempo. En la producción de dietas sin gluten, se pueden utilizar diversas harinas como sustitutos de la harina de trigo en las industrias (Akram et al., 2025).

Los alimentos funcionales son alimentos innovadores formulados para contener sustancias o microorganismos vivos con posibles beneficios para la salud o la prevención de enfermedades, en una concentración segura y suficientemente alta para lograr el beneficio deseado. Los ingredientes añadidos pueden incluir nutrientes, fibra dietética, fitoquímicos, otras sustancias o probióticos (Temple, 2022).

2.2.2.1. Concepto de alimentos libres de gluten

Una dieta libre de gluten es un programa alimentario en el que se excluyen todos los alimentos que contienen una proteína conocida como gluten. El gluten contribuye a que los alimentos conserven su forma. Se encuentra en cereales o granos, por ejemplo, cebada, centeno y trigo. Además, se halla en combinaciones de estos cereales o granos, como el triticale, que es una mezcla de centeno y trigo (Clinic, 2025).

Los granos o cereales, los almidones y las harinas que pueden formar parte de una dieta sin gluten incluyen los siguientes:

- Amaranto
- Chocho

- Alforfón
- Maíz
- Quinoa.
- Sorgo.
- Soya.

2.2.2.2. Enfermedad celíaca y tendencias de consume

La enfermedad celíaca, la forma más común de sensibilidad al gluten que afecta al 1 % de la población mundial, es una reacción autoinmune en el intestino delgado desencadenada por la ingestión de gluten. La tendencia general de crecimiento en el sector de productos sin gluten es ascendente esto se debe a las mejoras en sabor y textura de los productos. A medida que los consumidores elevan sus expectativas, es probable que las marcas que innovan en funcionalidad ofrecen avances genuinos las opciones mejoran constantemente. Una de las principales causas de los consumidores de productos sin gluten es la limitada disponibilidad de una variedad de productos sin gluten en los supermercados (Hassan et al., 2024).

2.2.2.3. Limitaciones tecnológicas en productos sin gluten

Debido a la funcionalidad del gluten en la elaboración de productos horneados, producir alimentos libres de gluten no es una tarea fácil y representa un reto tecnológico. Cuando a la harina de trigo se le añade agua y se le aplica trabajo mecánico (amasado, mezclado), las proteínas de la harina forman una red continua de gluten. Esto genera una masa viscoelástica que tiene la capacidad de retener gas y producir productos horneados aireados y livianos, como los bizcochos, panes y galletas. Los productos obtenidos al utilizar ingredientes sin gluten deben parecerse a sus equivalentes que sí contienen gluten, pero su eliminación conlleva varios desafíos en el procesamiento, la estructura, la textura y el tamaño de los productos finales. La utilización de varios aditivos alimentarios y cotexturizadores es necesaria para sobrepasar estas restricciones tecnológicas. No obstante, dado que se deben considerar otras propiedades organolépticas, como el aroma, el color y el gusto, es posible que las fórmulas de los productos contengan ligantes acuosos y espesantes, gomas de diferentes clases, almidones alterados, saborizantes y proteínas de orígenes diversos (por ejemplo: pescado, leche o soja), surfactantes, emulsionantes y demás (Mita ,2025).

2.2.2.4. Enfoque de alimentos funcionales en panificación

La Organización Mundial de la Salud (OMS) define los productos funcionales como aquellos que, además de sus propiedades nutricionales fundamentales, tienen impactos positivos para la salud que superan los efectos nutricionales básicos. Por consiguiente, se relaciona con el término "alimento funcional" a ciertos elementos que poseen cualidades que favorecen la salud y un efecto positivo. La mejora de los procesos fisiológicos humanos, el riesgo más bajo de padecer enfermedades y la contribución a un estado de salud óptimo son los impactos más significativos que tienen los alimentos funcionales sobre la salud. Los elementos de los alimentos funcionales abarcan todos los compuestos que se encuentran naturalmente en los alimentos o que se incorporan a ellos específicamente por sus beneficios para la salud. Es posible hallar un gran número de grupos de elementos funcionales, como por ejemplo: isotiocianatos, fibra dietética, fitoestrógenos, polioles, vitaminas y minerales, probióticos y prebióticos, ácidos grasos, carotenoides, flavonoides y ácidos fenólicos (Guiné y Florenca, 2024).

2.2.3. Materias primas no convencionales: chocho y amaranto

- Chocho

El tarwi o chocho (*Lupinus mutabilis*) es la única especie de *Lupinus* domesticada como leguminosa en América y se origina en los Andes de América del Sur. A pesar de que su distribución va desde Colombia hasta el norte argentino, hoy en día es especialmente importante en Bolivia, Ecuador y Perú, donde se le considera un cultivo de alta prioridad, es una leguminosa herbácea erecta de tallos robustos, algo leñosa que alcanza una altura de 1,8 a 2 metros (Llerena, 2022).



Figura 1. Planta de chocho
Fuente: (Llerena, 2022)

- Amaranto

El amaranto es una planta que forma parte de la familia *amaranthaceae* y del género *Amaranthus*. El nombre científico es *Amaranthus spp.* La planta de amaranto cuenta con una panícula (panoja) muy similar al sorgo, con una longitud media de entre 50 centímetros y un metro. Esta panoja está compuesta por numerosas espigas que albergan una gran cantidad de florecitas pequeñas, que albergan una diminuta semilla de entre 0,9 y 1,7 milímetros de diámetro, es el producto principal de la planta de amaranto, con el cual se producen diversos productos como harinas, cereales y golosinas (García et al., 2019).



Figura 2. Planta de amaranto

Fuente:(Chile ,2020)

2.2.3.1. Composición nutricional del amaranto

El amaranto es un ingrediente muy interesante por su buena composición nutricional, sobre todo porque tiene minerales y vitaminas. La mezcla exclusiva de Fibra, Proteínas, Mg y Zinc en niveles elevados posibilita su utilización como suplemento en alimentos para celíacos (Torrez ,2023).

En la tabla 1 se presenta el contenido nutricional del amaranto

Tabla 1. Contenido nutricional del amaranto

Componente	Porcentaje
Proteínas	14,30%
Fibra	4,11%
Zinc	3,6%
Magnesio	38%
Agua	14%

Fuente: (Torrez ,2023)

2.2.3.2. Composición nutricional del chocho

El chocho, en comparación con otros alimentos de origen vegetal, es uno de los que tiene una mayor cantidad nutricional. Tiene un contenido proteínico semejante al de la soja, pero menos grasa y más fibra. Asimismo, el chocho es libre de gluten, lo que lo convierte en una alternativa adecuada para individuos con sensibilidad al gluten. En la tabla 2 se presenta el contenido nutricional del chocho.

Tabla 2. Contenido nutricional del chocho

Componente	Porcentaje
Proteínas	47,80%
Fibra	11,07%
Zinc	42,84%
Magnesio	0,24%
Agua	10,13%

Fuente: (Llerena ,2022)

2.2.3.3. Propiedades tecnofuncionales de las harinas

La harina de chocho (*Lupinus mutabilis*) es conocida por su habilidad para absorber agua, su buena solubilidad y su capacidad de emulsificación, lo que la hace una opción funcional al trigo y un potenciador proteico superior. Contiene fibra insoluble y grasas saludables (omega 3 y 9) en abundancia, alcanzando hasta un 44,60% de proteínas (Lemache, 2025).

El amaranto es un pseudocereal ancestral que fue cultivado por civilizaciones de Mesoamérica, como los aztecas y los incas. El amaranto, a pesar de ser relativamente menos conocido que otros cereales más frecuentes, tales como el maíz o el trigo, ha comenzado a sobresalir por su versatilidad en la cocina y sus ventajas para la salud. La harina de amaranto es uno de los productos derivados del amaranto que ha cobrado más popularidad; se distingue porque es 100 % natural, no contiene gluten y tiene un alto contenido en fibra (Herrero, 2022).

2.2.3.4. Aplicaciones en productos de panificación

Las aplicaciones en productos de panificación incluyen la optimización técnica a través de enzimas y mejorantes, así como software administrativo y maquinaria automatizada. Se centran en optimizar el volumen, la textura, la conservación y el valor nutricional (fibras, proteínas), incorporando instrumentos digitales para calcular recetas (porcentaje panadero), controlar inventarios y utilizar aplicaciones de

administración de punto de venta (TPV) con el fin de garantizar la eficacia en términos productivos (Melange, 2025).

Aplicaciones:

- Porcentaje panadero: Aplicaciones para hacer cálculos de fórmulas de pan, que simplifican la escalabilidad de las recetas.
- Gestión de producción y TPV: Herramientas como Capterra, Recipok o Toast para el control de costos, inventarios, ventas y trazabilidad.

2.2.4. Nanotecnología en alimentos

Es la ciencia y tecnología a escala nanométrica prometen estar entre los campos de mayor innovación durante largo tiempo. El propósito de la nanotecnología es controlar y alterar los sistemas y la materia a escala nanométrica para cambiar de manera importante sus propiedades en comparación con las que se observan a escala macroscópica (Ojeda et al., 2019).

En la actualidad, la implementación de esta innovadora tecnología permitiría el desarrollo potencial de productos con niveles regulares de grasa entre un 25.0% y un 35.0 %, reconfigurándolos con contenidos inferiores a 1.0% y manteniendo sus atributos de textura y paladar al nivel de aceptación del producto estándar. Los alimentos a nivel molecular o atómico crean nanopartículas de ingredientes y componentes activos con el propósito de perfeccionar las propiedades nutritivas y aumentar la seguridad alimentaria, así como mejorar características organolépticas típicas (García, 2023).

2.2.4.1. Introducción a la nanotecnología alimentaria

La nanotecnología ha mostrado en tiempos recientes un enorme potencial para crear productos y aplicaciones novedosos en varias áreas de la industria. La nanotecnología ha sido muy prometedora en el sector alimentario, brindando una extensa variedad de oportunidades a lo largo de las últimas décadas. Asimismo, las nanopartículas tienen características exclusivas a causa de su química superficial y, por lo tanto, son adecuadas para distintas aplicaciones en la industria alimentaria. Los investigadores y especialistas buscan tecnologías y procedimientos eficaces para elevar la calidad de los alimentos, que sean saludables y proporcionen beneficios nutricionales extra, ante el aumento en la demanda por parte de los consumidores respecto a la calidad de los alimentos y sus ventajas para la salud (Ghosh, 2025).

2.2.4.2. Nanopartículas en sistemas alimentarios

Las nanopartículas tienen un gran impacto en la industria alimentaria. Desde los métodos para cultivar, producir y procesar alimentos hasta cómo se envasan, transportan y consumen. Las aplicaciones de los nanomateriales en la alimentación se pueden encontrar en el procesado de alimentos, aditivos alimentarios y en materiales en contacto con alimentos (empacado). Los componentes orgánicos presentes en los alimentos como proteínas, carbohidratos y grasas pueden variar en tamaño. Desde grandes cadenas poliméricas hasta moléculas más simples en el rango nanométrico (Portal Food Tech, 2022).

Ventajas nutricionales y técnicas

- Ampliación de la vida útil: Los recipientes que contienen dióxido de titanio o nanopartículas de plata disminuyen la proliferación bacteriana y fúngica.
- Funcionalidad: Creación de nuevos alimentos con características antioxidantes y antimicrobianas más desarrolladas.
- Biodisponibilidad aumentada: Los liposomas, facilitan que los nutrientes fundamentales se absorban de manera más eficiente.

2.2.4.3. Carbonato de calcio: propiedades y aplicaciones

El carbonato de calcio es un compuesto inorgánico que se utiliza en una amplia variedad de aplicaciones, tanto industriales como domésticas. Es un polvo de color blanco, compuesto por cristales sin olor, incoloros e insípidos, que no se disuelven en alcohol y tienen escasa solubilidad en alcohol, con baja solubilidad en agua, altamente soluble en ácidos diluidos y cloruro de amonio.

Este compuesto, frecuentemente denominado calcita, constituye una sal de calcio derivada del ácido carbónico, que exhibe las siguientes propiedades:

- Fórmula química: CaCO_3
- Pequeña solubilidad en agua: mg/l a 25°C: 14 (muy escasa), este compuesto al disolverse en agua y con dióxido de carbono, forma carbonato ácido de calcio, es decir bicarbonato de calcio.
- Descomposición al ser sometido a calor: al someterlo a temperaturas de entre 800 y 825°C, este se descompone y empieza el proceso de calcinación, además al llegar a esta etapa, el carbonato libera óxido de calcio y dióxido de carbono.

- Reacción con ácidos: reacciona con algunos ácidos como es la combinación de carbonato de calcio y ácido clorhídrico, que da como resultado la liberación violenta de dióxido de carbono.
- Brillo (colorímetro): 95 min.
- Densidad: presenta una densidad de 2.6 a 2.95 g/cm³.
- Dureza: presenta una dureza de 3 a 4 en una escala de Mohs.
- Humedad: 0.09% (Morillo, 2017).

2.2.4.4. Impacto de nanopartículas en matrices alimentarias

Los nanomateriales, especialmente las nanopartículas metálicas, han aportado de manera importante a la elaboración de alimentos y empaques más sanos, seguros y de mejor calidad. Estas tienen características particulares como una capacidad de barrera superior contra gases, mayor repelencia al agua, resistencia mecánica aumentada y la facultad para inhibir la contaminación por microorganismos; todo ello garantiza una calidad más alta y un tiempo de vida útil del producto más largo. Además, pueden integrarse a sensores biológicos y químicos, lo que facilita la creación de aparatos de monitoreo que son sensibles y veloces para determinar la calidad de los alimentos, desde su frescura hasta la identificación de patógenos transmitidos por la comida, toxinas o alérgenos (Couto y Almeida, 2022).

2.2.4.5. Seguridad e inocuidad de nanomateriales

La nanotecnología es el término científico que se utiliza para referirse a la transformación de las materias primas mediante el uso de sus propiedades y tamaño. Esta modificación tan significativa ofrece grandes ventajas en términos de actividades eléctricas y ópticas. Las nanopartículas, en la industria, contribuyen a crear nuevos productos al mejorar el color, el gusto y la textura de estos. Además, aumentan la biodisponibilidad de nutrientes y previenen que los alimentos se deterioren por efecto microbiano.

La inocuidad y la seguridad de los nanomateriales es un campo emergente esencial, porque su pequeña dimensión y gran reactividad tienen el potencial de provocar daños en la salud, como estrés oxidativo y la inflamación de los pulmones que son diferentes a los de sus contrapartes macroscópicas. La valoración de los riesgos se centra en el ciclo vital completo y la inhalación es el riesgo más significativo, lo que requiere medidas estrictas para proteger a las personas individual y colectivamente (Cordis, 2022).

2.2.5. Propiedades fisicoquímicas de productos de panificación

Las propiedades fisicoquímicas de los productos de panificación, que son esenciales para su calidad y duración son los siguientes:

- Volumen específico: Muestra la expansión de la masa. Un pan más esponjoso y ligero suele ser el resultado de un volumen mayor, que se obtiene frecuentemente mediante la aplicación de enzimas o aditivos.
- Textura (Perfil de textura - TPA): Se examina a través de parámetros como la elasticidad, la resiliencia, la cohesividad, la firmeza y la dureza. La frescura de la miga se vincula con una consistencia menos firme del pan.
- Color: La reacción de Maillard (que involucra azúcares y proteínas) y la caramelización durante el proceso de horneado tienen un impacto significativo en el color de la miga y la corteza.
- Actividad de agua y humedad: La cantidad de agua (usualmente en productos horneados) tiene un impacto directo sobre la suavidad y el tiempo de duración del producto en estante.
- Estructura alveolar: La textura y la esponjosidad del pan están determinadas por cómo se distribuyen los alvéolos en la miga (Montiel, 2023).

2.2.5.1. Humedad y actividad de agua

La humedad y la actividad del agua (A_w) constituyen dos conceptos fundamentales en el análisis alimentario; por lo tanto, entender la diferencia entre ambos es necesario para asegurar la calidad, seguridad y vida útil de los productos alimenticios.

- Humedad

La humedad presente en alimentos es la cantidad total de agua que contiene un alimento en términos de porcentajes. Uno de los parámetros más relevantes en el análisis de alimentos es el contenido de humedad, porque tiene un impacto directo en diversas propiedades del producto, por ejemplo, su sabor, aspecto y textura. En la evaluación de alimentos, establecer el contenido de humedad es el primer paso. El procedimiento varía dependiendo del tipo de alimento y se basa en la pérdida de masa del producto cuando se calienta bajo condiciones controladas, eliminando agua y otros compuestos volátiles a través del secado en estufa a 105°C (Tecnal, 2024).

- Actividad de agua

La actividad del agua es fundamental para garantizar la seguridad alimentaria porque tiene un impacto directo en el desarrollo de microorganismos, como levaduras, hongos y bacterias. Los alimentos que contienen un A_w elevado son más susceptibles a que se deterioren debido a la acción de los microorganismos, lo cual puede poner en riesgo su calidad y seguridad. Por ejemplo, la posibilidad de que las bacterias patógenas se desarrollen es mayor en los alimentos con A_w más alta de 0,85; por el contrario, los productos con A_w más baja de 0,60 suelen ser más estables y menos susceptibles a la contaminación (Tecnal, 2024).

2.2.5.2. Contenido de proteína, grasa y fibra

Los macronutrientes de los alimentos son las grasas, los carbohidratos y las proteínas. Se trata de nutrientes que el cuerpo necesita en grandes cantidades todos los días. Constituyen el 90% del peso seco de la alimentación y el 100% de su energía.

- Proteína

Las proteínas están formadas por unidades llamadas aminoácidos, que se agrupan en cadenas largas. El organismo requiere más tiempo para disociar las proteínas debido a la complejidad molecular de estas. Por lo tanto, representan una fuente de energía más lenta y duradera que los carbohidratos (Shilpa, 2025).

- Grasa

Son la fuente de energía más lenta, pero a la vez la más eficaz. Cada gramo de grasa aporta al cuerpo alrededor de 9 kcal, que es más del doble de lo que aportan las proteínas o los carbohidratos. El cuerpo utiliza esta eficiencia para guardar cualquier exceso energético en forma de grasa (Shilpa, 2025).

- Fibra

La fibra ha demostrado ser un elemento fundamental de la alimentación para mantener una salud óptima. Dado que el consumo de esta se encuentra debajo de lo recomendado, es crucial fomentar su ingesta. Los elementos más relevantes y generales de la fibra dietética, su variedad de tipos y sus funciones, además de su relevancia para prevenir enfermedades no transmisibles y gastrointestinales, así como su impacto positivo en el control del peso corporal.

Los productos alimenticios que presentan un elevado contenido de fibra dietética incluyen: granos andinos, cereales, frutas, vegetales y semillas (Calizaya y Mamani , 2023).

2.2.5.3. Carbohidratos y cenizas

Los carbohidratos son uno de los nutrientes más importantes en nuestra dieta, estos contribuyen a suministrar energía al organismo. Los alimentos contienen tres clases fundamentales de carbohidratos: almidones, azúcares y fibra. Para calcular la calidad de la harina, se determina el contenido de cenizas en ella para estimar el nivel de separación del salvado y el endospermo a lo largo del proceso de molienda. A medida que la harina está más refinada, hay menos cenizas (Torres, 2023).

2.2.5.4. Métodos de análisis (normas AOAC)

Los métodos de (AOAC), son necesarios para diferentes sectores industriales, para asegurar la calidad y la seguridad de los alimentos. La industria alimentaria examina contaminantes y contenido nutricional, particularmente en sus procedimientos de análisis de composición, pureza y la supervisión de calidad. Los análisis son los siguientes:

- Humedad

Esta técnica se basa en pulverizar y pesar la muestra, ponerla sobre una placa de aluminio que ha sido pesada con anterioridad y secarla en un horno a una temperatura concreta durante un periodo de tiempo específico. Después de eso, la muestra se enfría en un desecador antes de volver a pesarse. Para obtener el porcentaje de humedad, se debe sustraer el peso de la muestra antes del secado al peso después del mismo conforme la normativa AOAC 925.10 (Vitaly ,2023).

- Proteína

El procedimiento Kjeldahl es el método utilizado para determinar el contenido de proteína, conforme a la norma AOAC 960.52 y al método 2001.11. Este procedimiento, que tiene tres fases principales, digestión, destilación y titulación.

- Cenizas

Para la determinación del contenido de cenizas, se emplea el método de incineración descrito por la norma AOAC 923.03.

- Fibra dietética

El contenido de fibra de un alimento se determina mediante un proceso de digestión ácida y alcalina, seguido de un lavado y secado, que permite separar la fibra insoluble por la norma AOAC 962.09.

- Carbohidratos

El contenido de carbohidratos en un alimento se determina por diferencia, restando de 100% los porcentajes de agua, proteína, grasa y fibra cruda en la muestra.

2.2.5.5. Relación entre composición y calidad del producto

La calidad de un producto se define como el conjunto de atributos que le permiten satisfacer el objetivo. En otras palabras, lo que el consumidor desea y necesita (Yang, 2019). Se conforman, en mayor o menor grado, de varios conjuntos de micro y macronutrientes, especialmente lo que se refiere a los energéticos (si bien todos, incluso los "micros", son muy importantes en las reacciones metabólicas y en la producción de energía). La diferencia entre "micros" y "macros" se define por la cantidad que nuestro cuerpo requiere de cada uno (Grueso, 2024).

2.2.6. Propiedades reológicas y texturales

La reología es el análisis de la deformación y el flujo de los materiales. Se enfoca en la reacción de los materiales a las fuerzas aplicadas, incluyendo tanto sólidos como líquidos. La reología estudia propiedades como la elasticidad, la viscosidad y la plasticidad, lo cual posibilita entender el comportamiento de los materiales en distintas circunstancias. Son características de un material que pueden ser sentidas por el tacto y por la boca. La textura en el campo de la alimentación abarca características como la suavidad, la crocancia, la dureza y la masticabilidad (Keller, 2025).

2.2.6.1. Concepto de reología en alimentos

Permite clasificar las características de flujo y deformación de los alimentos, que tienen un impacto directo en su sabor, textura, estabilidad y calidad en general. La reología alimentaria se dedica a la caracterización del material, abarcando el comportamiento frente a deformaciones menores que investiga la estructura viscoelástica, significativas que determinan la fractura, la fluencia y la textura durante el procesamiento y el consumo (Chen y Feng, 2026).

2.2.6.2. Textura: definición e importancia

La textura hace referencia a las percepciones físicas que experimentamos al ingerir alimentos, como la suavidad, cremosidad, crocancia y masticabilidad. La composición, la estructura y el procesamiento del alimento influyen en ella. Es un atributo importante, porque afecta el procesamiento y manejo, influye en los hábitos, y tiene un impacto en la vida útil y la aceptación de los productos por parte de los consumidores (Clariana, 2020).

2.2.6.3. Parámetros texturales (TPA):

Existen 4 tipos de parámetros texturales que contribuyen a la experiencia sensorial:

- Dureza: Es necesaria para poder comprimir un alimento.
- Cohesión: Calcula la fuerza de un alimento durante la masticación.
- Elasticidad: Explica como los alimentos presentan estiramiento después de la deformación.
- Fracturabilidad: Facilidad de quebrantar un alimento (Colaborad, 2024).

2.2.6.4. Instrumentación (texturómetro, Mixolab)

El texturómetro es un equipo esencial en los laboratorios que se dedican a la industria alimentaria, farmacéutica, cosmética y de materiales industriales. Su propósito fundamental es evaluar las propiedades mecánicas de una muestra, incluyendo la cohesión, dureza, elasticidad y adhesividad. Estos atributos están vinculados de manera directa con la percepción a través de los sentidos, con la calidad del producto final y con su comportamiento durante el almacenamiento y procesamiento. Permite la obtención de información objetiva que complementa las pruebas sensoriales. Por ejemplo, en el sector de la alimentación, tiene la capacidad de establecer si una fruta es firme, un bocadillo es crocante o un yogur tiene viscosidad. En cosmética, es útil para analizar la firmeza de una crema o la resistencia al corte de un jabón (Giménez, 2025).

El profiler (Mixolab), es una herramienta desarrollada específicamente para fines de regularidad y calidad de las harinas, analizar el efecto de las enzimas y crear nuevas formulaciones, como aquellas que no contienen gluten y son ricas en fibra, con el fin de asegurar la uniformidad de los productos finales y un flujo productivo sin interrupciones. La serie Mixolab, que inicialmente fue creada para examinar la harina

de trigo blanco, proporciona hoy en día la gama más amplia de protocolos de análisis de ingredientes y harina de cualquier dispositivo (Bock y Dubat, 2019).

2.2.6.5. Relación estructura-textura en galletas

La textura de las galletas (su dureza, su crujiente y su masticabilidad) es el resultado directo de la estructura interna que se forma por los ingredientes y el proceso de horneado. Por lo tanto, la calidad sensorial de las galletas depende de esta relación entre textura y estructura. Una textura dura y crujiente es el resultado de una estructura compacta y seca (con poca humedad), mientras que las grasas y la humedad alta generan texturas suaves. En términos sensoriales, la textura está compuesta por características geométricas, mecánicas y de humedad. Se miden las propiedades mecánicas, como la respuesta al esfuerzo, siendo la dureza del producto el aspecto textural más relevante para el análisis sensorial. Para determinar el parámetro textural de dureza, se debe aplicar una fuerza hasta que la deformación alcance un nivel específico; esto se consigue mediante una masticación del producto (González et al., 2023).

2.2.7. Análisis sensorial de alimentos

En la década de 1940, surgió la evaluación sensorial como una ciencia con el propósito de ofrecer un método sistemático y objetivo para evaluar los alimentos producidos en ese periodo, con miras a su venta en el mercado. El gusto y las preferencias del conocimiento que el propietario de la fábrica o taller tenía sobre el cliente de su producto eran los criterios fundamentales para elegir las características que un alimento debía poseer antes de la revolución industrial. En la industria alimentaria se realiza este tipo de análisis como control de calidad de los productos, ya sea durante la etapa de desarrollo o durante el proceso de rutina; por ejemplo, si una empresa cambia un insumo, este puede afectar en las características sensoriales del producto y, por tanto, afectar su calidad. Existen tres tipos de análisis sensorial que los siguientes:

- Análisis discriminativo: Se utiliza para verificar si existen diferencias entre productos. Normalmente se emplea cuando hay un intercambio de ingredientes esenciales que tiene el potencial de alterar las propiedades sensoriales de los alimentos. Por ejemplo, se pregunta qué muestra tiene más acidez o dulzura entre A y B.

- **Análisis descriptivo:** Esta trata de describir las propiedades sensoriales y medirlas; por lo tanto, tiene un enfoque cualitativo y cuantitativo simultáneamente. Por un lado, al describir las propiedades sensoriales, se busca observar qué recuerdos se vinculan con el producto y de qué manera se podría describir su aroma.
- **Análisis del consumidor:** Para esta prueba se utilizan personas que no están entrenadas, y se les hace la pregunta si un alimento les gusta o no. Para este análisis se suele requerir que la persona sea un consumidor habitual del producto en evaluación (Hidrolab, 2022).

2.2.7.1. Fundamentos del análisis sensorial

El análisis sensorial constituye una disciplina científica de naturaleza multidimensional que ha consolidado su relevancia como herramienta indispensable en la industria alimentaria moderna. Como campo del conocimiento, esta disciplina evalúa sistemáticamente cómo las propiedades intrínsecas de los alimentos son percibidas por los sentidos humanos, funcionando como el puente que conecta las características físicas y químicas de los productos con la experiencia compleja del acto de comer; mide, analiza e interpreta las respuestas a los productos tal como son percibidas a través de la vista, el olfato, el gusto, el tacto y el oído (Melikoglu, 2026).

2.2.7.2. Tipos de pruebas sensoriales

El análisis sensorial contempla una diversidad de pruebas cuya elección responde al objetivo del estudio, las características del producto y el perfil de los evaluadores. De manera general, estas pruebas se clasifican en tres grandes categorías: discriminativas, descriptivas y afectivas.

- **Pruebas discriminativas:** Tienen como objetivo determinar si existen diferencias perceptibles entre dos o más muestras. En este tipo de pruebas, los panelistas indican si perciben o no diferencias entre las muestras y si son capaces de describir dicha diferencia, existiendo diversas variantes como la prueba triangular, la prueba dos de cinco o entre otras (Manfugás, 2007).
- **Pruebas descriptivas:** Profundizan en la identificación y cuantificación de los atributos sensoriales que caracterizan a un alimento. Los métodos descriptivos se realizan habitualmente con evaluadores entrenados para analizar los productos de manera objetiva, puesto que los consumidores no entrenados suelen estar influenciados por sus valoraciones hedónicas. Entre las técnicas

más robustas destaca el Análisis Descriptivo Cuantitativo (QDA), cuyo rigor metodológico le ha otorgado el estatus de estándar de referencia en el perfilado sensorial (Almeida y Melo ,2019).

- Pruebas afectivas o hedónicas: Orientan su atención hacia la respuesta del consumidor. Estas pruebas sirven para conocer la respuesta individual de consumidores habituales o potenciales frente a un producto determinado, indicando su nivel de satisfacción o preferencia (Manfugás, 2007).

2.2.7.3. Escalas hedónicas y evaluación de aceptabilidad

Las escalas hedónicas son instrumentos de medición diseñados para cuantificar el grado de agrado o desagrado que experimenta un consumidor frente a un producto. Las pruebas hedónicas miden el grado en que un consumidor gusta, acepta o prefiere un producto determinado, y las escalas pueden variar entre 1 y 5, 7, 9 o más puntos, siendo la escala de 9 puntos la más frecuente en la literatura científica (Huey et al., 2024).

En productos de galletería, el uso de la escala hedónica de 9 puntos resulta especialmente frecuente. La aceptabilidad general de un producto puede evaluarse mediante una escala hedónica que consiste en una lista de respuestas con diferentes grados de satisfacción, donde el consumidor indica su respuesta basándose en su percepción sensorial. En la aplicación concreta de esta escalada, la categoría más alta corresponde a "me gusta extremadamente" (9 puntos) y la más baja a "me disgusta extremadamente" (1 punto), con categorías intermedias acompañadas frecuentemente de términos descriptivos y emoticones que facilitan la comprensión del evaluador (Silva Paz et al., 2024).

2.2.7.4. Factores que afectan la percepción sensorial

La percepción sensorial de los alimentos es un proceso multifactorial en el que intervienen, de manera simultánea, características propias del producto, condiciones fisiológicas del evaluador y el entorno en que se realiza la evaluación. Desde el primer contacto con el alimento, el color actúa como señal anticipatoria: antes de probar una galleta, el consumidor ya ha formulado una expectativa sobre su sabor y calidad basándose en su apariencia visual y en experiencias previas con productos similares; cuando esa expectativa no se cumple, por ejemplo, ante colores inusuales o incongruentes con el producto esperado, la respuesta hedónica tiende a ser más baja, independientemente de las propiedades reales del alimento. De manera

similar, la textura condiciona profundamente la experiencia de consumo: atributos como la firmeza, la crocancia o la sensación en boca no se perciben igual en todos los individuos ni en todas las matrices alimentarias, lo que hace de su evaluación una tarea metodológicamente exigente. A estos factores se añade la dimensión fisiológica e individual del propio evaluador, pues la percepción del gusto no opera de forma aislada, sino que está modulada por la temperatura del producto, su textura, y la sensibilidad gustativa particular de cada persona; incluso variables aparentemente periféricas, como el estado de ánimo del panelista, su nivel de motivación o sus sesgos de expectativa, pueden comprometer la objetividad de los resultados si no se controlan adecuadamente durante la sesión de evaluación (Hunter, 2022).

2.2.7.5. Relación entre análisis sensorial y calidad del producto

La relación entre el análisis sensorial y la calidad del producto ha sido ampliamente documentada en la ciencia de los alimentos, y su importancia radica en que ningún parámetro fisicoquímico por sí solo es capaz de reflejar la experiencia completa del consumidor frente a un alimento. Los métodos analíticos convencionales, ofrecen datos objetivos y reproducibles, pero son los atributos organolépticos los que, en última instancia, determinan si un producto será aceptado o rechazado en el mercado. En ese sentido, la correlación entre variables fisicoquímicas como el color, la textura, el contenido de azúcares o los compuestos volátiles y los atributos sensoriales percibidos por el panel evaluador permite comprender con mayor profundidad cómo las decisiones de formulación y procesado se traducen en la experiencia real de consumo; esta integración resulta aún más relevante en productos enriquecidos, donde la adición de ingredientes funcionales puede alterar de forma simultánea e interrelacionada múltiples dimensiones del perfil de calidad (Mihafu y Kamiyango ,2019).

2.2.8. Relación entre propiedades fisicoquímicas, texturales y sensoriales

La calidad de un producto alimenticio no puede reducirse a un único parámetro ni comprenderse desde una sola dimensión analítica. Lo que el consumidor experimenta al probar una galleta es el resultado de un conjunto de interacciones que operan a niveles distintos, pero profundamente conectados. Comprender esa cadena de relaciones, desde lo fisicoquímico hasta lo perceptual, pasando por lo

textural, constituye el eje central de esta sección y el fundamento conceptual sobre el que se apoya el modelamiento predictivo propuesto en esta investigación.

En productos funcionales como las galletas enriquecidas con nanopartículas de carbonato de calcio, esta interdependencia adquiere especial relevancia, dado que la incorporación de ingredientes funcionales puede modificar simultáneamente la composición proximal, el comportamiento mecánico de la masa y los atributos percibidos por el panel evaluador. Por ello, abordar estas tres dimensiones de forma integrada es metodológicamente indispensable para una caracterización completa y coherente del producto (Igual y Monzó, 2022).

2.2.8.1. Interacciones fisicoquímicas en matrices alimentarias

Para comprender cómo un alimento se comporta ante el consumidor, es necesario antes entender qué ocurre en su interior. Los productos alimenticios no son simplemente mezclas de ingredientes: son sistemas organizados en los que cada componente interactúa con los demás a nivel molecular y estructural, generando propiedades emergentes que no podrían predecirse a partir del análisis aislado de cada uno. El procesamiento de los alimentos no solo extiende su vida útil, sino que también produce cambios en sus propiedades fisicoquímicas y estructurales, los cuales pueden ser deseables o indeseables; en ese sentido, las propiedades fisicoquímicas del alimento son las principales responsables de la calidad final del producto (Silva et al., 2025).

Esta perspectiva cobra especial relevancia cuando se analiza el concepto de matriz alimentaria. La matriz del producto puede definirse como el conjunto de sus componentes, sus interacciones, su organización estructural y las propiedades fisicoquímicas resultantes, y desempeña un papel determinante en aspectos tan distintos como la estabilidad del producto, sus propiedades sensoriales y sus efectos nutricionales y sobre la salud. Dicho de otro modo, no basta con conocer la composición centesimal de una galleta para predecir cómo se va a comportar en la boca: importa también cómo están organizados sus componentes y de qué manera se relacionan entre sí (Capillas y Herrero, 2021).

En el caso de las galletas enriquecidas con nanopartículas de carbonato de calcio, estas interacciones adquieren una complejidad adicional. Las propiedades deseables de los alimentos como la textura, el sabor y la biodisponibilidad de nutrientes dependen en gran medida de la estructura del producto y no únicamente

de las características fisicoquímicas intrínsecas de sus componentes aislados. Esto significa que la incorporación de un agente funcional como el carbonato de calcio puede alterar el comportamiento de la red proteica, la distribución de la grasa o la estructura del almidón, modificando de manera simultánea la textura instrumental y la percepción sensorial del producto final (Oliveira et al., 2022).

2.2.8.2. Correlación estructura–propiedad–percepción

Una de las partes fundamentales de la ciencia de los alimentos, es que existe una relación continua y bidireccional entre la estructura del alimento, sus propiedades medibles y la percepción que experimenta el consumidor. En productos de galletería, la textura es el atributo donde esa correspondencia se hace más evidente, y su estudio ha permitido establecer vínculos concretos entre lo que el texturómetro registra y lo que el panel evaluador describe. Bajo esa lógica, parámetros como la dureza, la fracturabilidad, la cohesión y la elasticidad obtenidos mediante el análisis de perfil de textura (TPA) no son datos abstractos: son el reflejo instrumental de lo que un panelista experimenta al morder una galleta (Rahman et al., 2021).

2.2.8.3. Modelos tradicionales de predicción en alimentos

Durante décadas, la ciencia y la tecnología de los alimentos han recurrido a una serie de herramientas estadísticas y matemáticas para modelar las relaciones entre las variables de formulación, las propiedades fisicoquímicas y los atributos sensoriales. Entre los enfoques más utilizados se encuentran: la regresión lineal múltiple, la metodología de superficie de respuesta (RSM) y la regresión por mínimos cuadrados parciales (PLS).

La RSM, en particular, ha sido ampliamente utilizada para optimizar formulaciones y condiciones de procesado. Esta metodología mapea un espacio multidimensional para predecir resultados en función de diversas variables, mediante experimentos en los que los factores se varían de manera sistemática y cuyas respuestas se modelan matemática y estadísticamente; en el ámbito alimentario, ha sido empleada para encontrar las combinaciones óptimas de condiciones que permiten controlar atributos de calidad específicos (Koyuncu ,2025).

Por su parte, la regresión PLS ha encontrado un nicho importante cuando se trabaja con conjuntos de datos donde existe alta colinealidad entre variables. El PLS es una técnica de análisis de regresión multivariante que permite comparar dos bloques de variables simultáneamente, y ha sido empleada para establecer relaciones entre

mediciones instrumentales y resultados de paneles sensoriales, aportando información sobre qué instrumentos o combinaciones de instrumentos predicen mejor los atributos sensoriales relevantes. Su capacidad para manejar múltiples variables de entrada y salida de forma simultánea lo convierte en una herramienta valiosa para correlacionar parámetros fisicoquímicos con respuestas sensoriales, aunque su eficacia depende en gran medida de que las relaciones entre variables sean de naturaleza lineal o aproximadamente lineal (Shaw y Beilken, 1999).

Los conjuntos de datos grandes son cada vez más frecuentes y, a menudo, complejos de interpretar. El análisis de componentes principales (PCA) es un método que permite disminuir la dimensionalidad de estos conjuntos de datos. Así, se mejora su interpretabilidad y se reduce la pérdida de información al mismo tiempo. Por esta razón, genera nuevas variables no correlacionadas que aumentan la varianza de manera sucesiva. Encontrar estas nuevas variables, llamadas componentes principales, significa resolver un problema de valores y vectores propios. Estas se definen a partir del conjunto de datos en cuestión (no a priori), lo que hace que el PCA sea una técnica adaptativa para analizar datos (Jolliffe y Cadima, 2016).

El análisis factorial múltiple MFA, es un procedimiento de análisis multivariante que permite sintetizar y representar gráficamente una tabla de datos compleja, donde se presenta a los individuos a través de diversos grupos de variables (cualitativas y/o cuantitativas). Para determinar la distancia entre individuos, considera el aporte de todos los grupos activos de variables (Suarez, 2023).

Un mapa de calor o heatmap, se utiliza como herramienta que sirve para analizar las interacciones. Es una ilustración gráfica en dos dimensiones de datos de microarrays, donde los valores se expresan a través de colores. La agrupación de muestras individuales también se lleva a cabo, además de la agrupación de genes para crear una impresión de semejanza en la expresión. Respecto a la mezcla de colores, el rojo suele señalar una expresión elevada y el verde, una expresión baja (Farrell, 2010).

2.2.8.4. Limitaciones de los enfoques convencionales

A pesar de su utilidad, los modelos estadísticos convencionales presentan limitaciones estructurales que se vuelven evidentes cuando se trabaja con sistemas alimentarios complejos. Su principal restricción radica en el supuesto de linealidad: fueron diseñados para aproximar relaciones entre variables mediante funciones

polinomiales o lineales, lo cual resulta insuficiente cuando el sistema en estudio responde a dinámicas no lineales e interdependientes.

Las técnicas estándar de regresión como los mínimos cuadrados ordinarios y la regresión PLS se aplican eficazmente para predicciones por interpolación lineal bajo condiciones estacionarias, pero son propensas a la confusión de variables y a predicciones fallidas bajo condiciones no estacionarias no entrenadas previamente. Esta limitación se agrava cuando se trabaja con datos de alta dimensionalidad, situación cada vez más frecuente en el análisis de productos funcionales enriquecidos. Gracias a su alta precisión predictiva, el aprendizaje automático se ha consolidado como una alternativa poderosa frente a modelos tradicionales como la regresión PLS y la estadística bayesiana en el campo de la ciencia sensorial, dado que identifica relaciones altamente complejas dentro de grandes conjuntos de datos. En ese contexto, los modelos basados en *deep learning* representan la respuesta más adecuada para capturar la complejidad real de las interacciones entre las propiedades fisicoquímicas, texturales y sensoriales de las galletas enriquecidas con nanopartículas de carbonato de calcio (Huey et al., 2024).

2.2.9. Inteligencia artificial en la ciencia de alimentos

La adopción de la inteligencia artificial en la industria alimentaria ha transformado profundamente la manera en que se aborda el análisis, el control y el desarrollo de los alimentos. Lo que durante décadas se resolvió con métodos estadísticos clásicos y evaluaciones manuales, hoy se encuentra en los algoritmos de aprendizaje automático una alternativa más eficiente y precisa para gestionar la complejidad de los sistemas alimentarios. Esta transición no obedece a una moda tecnológica, sino a una necesidad real: los alimentos son sistemas complejos en los que cientos de variables fisicoquímicas, sensoriales y de proceso interactúan de forma simultánea, generando relaciones no lineales que los modelos convencionales difícilmente pueden capturar en su totalidad (Haohan Ding et al., 2023). En este sentido, el aprendizaje profundo como rama de la inteligencia artificial ha surgido como una herramienta capaz de extraer patrones predictivos de alta complejidad, con aplicaciones que abarcan desde el control de calidad hasta la optimización de formulaciones y la evaluación sensorial automatizada (Khan y Karim ,2026).

2.2.9.1. Introducción a la inteligencia artificial (IA)

La inteligencia artificial se define como el conjunto de tecnologías orientadas a replicar sistemas computacionales, capacidades propias del pensamiento humano, entre ellas el razonamiento, el aprendizaje autónomo y la toma de decisiones (Hussain et al., 2026). Su origen se remonta a la Conferencia de Dartmouth en 1956, donde John McCarthy propuso el término; no obstante, fue en las últimas dos décadas cuando alcanzó su mayor desarrollo, impulsada por tres factores complementarios: la disponibilidad masiva de datos digitales, el incremento de la capacidad computacional mediante unidades de procesamiento gráfico (GPU) y el surgimiento de arquitecturas de aprendizaje más eficientes (Haenlein y Kaplan, 2019). Entre sus principales ramas se encuentran el machine learning, el deep learning, la visión por computadora y el procesamiento del lenguaje natural, las cuales comparten un mismo principio: la capacidad de aprender a partir de la experiencia sin la necesidad de estar programadas explícitamente para cada tarea, lo que las convierte en herramientas especialmente adecuadas para la industria alimentaria, donde la heterogeneidad y el volumen de los datos superan la capacidad analítica de los métodos tradicionales (Haohan Ding et al., 2023).

2.2.9.2. Machine Learning en alimentos

El machine learning (ML) es la rama de la IA que permite a los sistemas identificar patrones, aprender de los datos y mejorar sus predicciones de forma autónoma. En la ciencia de alimentos, su adopción ha crecido de manera sostenida, con aplicaciones que van desde la detección de adulteraciones en materias primas hasta la optimización de formulaciones en el desarrollo de nuevos productos (Hussain et al., 2026). De acuerdo con la investigación de Liakos (2025), concluyó que las redes neuronales artificiales dominan los enfoques aplicados en control de calidad, seguidas del aprendizaje en conjunto (*ensemble learning*), con el aprendizaje supervisado prevaleciendo en la mayoría de las tareas. Los algoritmos más frecuentemente reportados en aplicaciones alimentarias incluyen los bosques aleatorios, las máquinas de soporte vectorial (SVM) y las redes neuronales artificiales (ANN) (Suárez et al., 2025). En cuanto a las galletas, Loncar (2024) aplicó modelos ANN y SVM para predecir 32 parámetros de calidad, entre ellos atributos sensoriales, propiedades de horneado y capacidad antioxidante, confirmando la eficiencia superior de las ANN para la predicción simultánea de variables de naturaleza diversa, lo que constituye un antecedente directo para el presente estudio.

2.2.9.3. Deep Learning: fundamentos

El deep learning o aprendizaje profundo, es una subdisciplina del ML que emplea redes neuronales artificiales con múltiples capas ocultas para aprender representaciones jerárquicas de los datos. A diferencia de los modelos convencionales, que realizan una o dos transformaciones sobre las variables de entrada, las redes profundas ejecutan sucesivas transformaciones: las capas iniciales capturan patrones simples, mientras que las capas más profundas construyen representaciones de alto nivel que integran la información acumulada previamente (Ramos, 2020). En la investigación de LeCun (2015), consolidó el aprendizaje profundo como paradigma dominante en reconocimiento de voz, visión por computadora y procesamiento del lenguaje natural. El mecanismo que hace posible este entrenamiento es el algoritmo de retropropagación, que ajusta iterativamente los pesos de toda la red propagando hacia atrás el error cometido en la predicción, guiado por el descenso de gradiente estocástico (Hinton y Williams ,1986). En la ciencia de alimentos, esta capacidad resulta especialmente valiosa porque los modelos de deep learning, entrenados con datos multidimensionales, pueden capturar con precisión los efectos de interacción no lineal entre variables como la humedad, la porosidad, la dureza y la aceptabilidad sensorial, relaciones que los modelos empíricos tradicionales no logran representar adecuadamente (Hussain et al., 2026). Aplicado a productos como las galletas enriquecidas, esto significa que el modelo puede aprender directamente de los datos experimentales cómo la incorporación de un ingrediente funcional altera simultáneamente múltiples atributos fisicoquímicos y sensoriales, sin que el investigador deba definir de antemano la forma de esas relaciones.

2.2.9.4. Aplicaciones en calidad, seguridad y desarrollo de productos

El deep learning ha generado avances concretos en tres áreas clave de la industria alimentaria: control de calidad, seguridad alimentaria y desarrollo de productos. En cuanto a la calidad, las redes neuronales convolucionales (CNN) han alcanzado niveles de exactitud superiores al 99% en tareas de clasificación visual, como grado de madurez, detección de defectos y estimación de contenido de grasa mediante imagen hiperespectral, con potencial directo de aplicación en la evaluación del color y la textura aparente de galletas (Liao et al., 2026). En el ámbito de la seguridad alimentaria, Ding (2025) documentó que mientras las CNN destacan en el procesamiento de imágenes para identificar contaminantes, las redes neuronales

recurrentes (RNN-LSTM) son eficaces en el modelado de series temporales de variables de proceso, y su integración con IoT, blockchain y la IA explicable (XAI) representa la tendencia metodológica de mayor proyección. En lo que respecta al desarrollo de productos, Hussain y otros (2026) señalan que el ML y el deep learning permiten analizar datos sensoriales, espectrales y metabolómicos con una escala y reproducibilidad que los métodos tradicionales no pueden ofrecer, posibilitando la predicción de perfiles de sabor y textura. Este potencial es descrito por Marimuthu (2026), quien concluyó que los modelos de IA analizan las interacciones entre formulación, proceso y calidad con una precisión inalcanzable para los enfoques estadísticos convencionales, lo que sustenta metodológicamente su uso en el modelamiento de galletas enriquecidas con nanopartículas de carbonato de calcio.

2.2.10. Modelamiento predictivo con Deep Learning

El aprendizaje profundo, también conocido como deep learning, es un subconjunto del aprendizaje automático o machine learning, que a su vez es una rama de la inteligencia artificial. El deep learning se enfoca en diseñar algoritmos que tengan la capacidad de aprender por medio de redes neuronales profundas. Los sistemas de redes neuronales profundas están modelados en la actividad del cerebro humano y se conforman por una serie de capas que contienen nodos interconectados, su función es procesar y modificar los datos (Hernández, 2023). El modelo de machine learning (aprendizaje automático) es una rama de la inteligencia artificial que permite que las máquinas aprendan ciertas tareas sin ser programadas de manera específica para ellas, utilizan estadísticas para predecir y reconocer patrones (Muelas, 2026).

2.2.10.1. Redes neuronales artificiales

Las redes neuronales artificiales (ANN) son modelos computacionales inspirados en el funcionamiento del sistema nervioso biológico, diseñados para aprender patrones a partir de datos mediante unidades de procesamiento interconectadas. Una ANN es un modelo simplificado del sistema nervioso compuesto por neuronas artificiales cuyos pesos de conexión entre capas desempeñan un papel determinante en la predicción de los datos de salida, y tiene la capacidad de mapear relaciones no lineales sin conocimiento previo, prediciendo respuestas incluso con información incompleta. En el ámbito alimentario, la ANN constituye la tecnología de inteligencia artificial más utilizada para evaluar la calidad de los alimentos, y ha sido aplicada en

el análisis de inocuidad, el procesamiento de imágenes y el modelado de operaciones térmicas y no térmicas de procesamiento (Visalli y Galmarini, 2024).

2.2.10.2. Redes neuronales profundas (DNN)

Las redes neuronales profundas representan la evolución arquitectónica de las ANN convencionales. Su diferencia fundamental radica en la incorporación de múltiples capas ocultas que permiten aprender representaciones jerárquicas de los datos, pasando de patrones simples en las primeras capas a relaciones cada vez más complejas en las más profundas. Una DNN estructura sus neuronas en una capa de entrada, varias capas ocultas y una capa de salida; los datos fluyen de manera unidireccional a través de transformaciones sucesivas hasta generar predicciones continuas como contenido de azúcar o concentración de grasa. El *deep learning* es precisamente una rama especializada del aprendizaje automático que utiliza redes con muchas capas ocultas para aprender automáticamente características jerárquicas a partir de conjuntos de datos grandes y no estructurados. En la predicción de atributos sensoriales y texturales de galletas enriquecidas, esta profundidad arquitectónica resulta determinante para capturar las relaciones no lineales entre la composición fisicoquímica, los parámetros del TPA y las respuestas del panel evaluador (Silva Paz et al., 2024).

2.2.10.3. Redes neuronales recurrentes (RNN)

Una red neuronal recurrente (RNN) es un modelo de aprendizaje profundo que ha sido entrenado para transformar y tratar una entrada de datos secuencial en una salida también secuencial, con características específicas. Los datos secuenciales son palabras, oraciones o datos de series temporales en los que los elementos interactúan según reglas complejas de tipo sintáctico y semántico. Es un sistema de software que se compone de múltiples elementos interconectados, los cuales simulan la manera en que las personas llevan a cabo transformaciones de datos secuenciales, como la traducción de texto entre diferentes idiomas. La inteligencia artificial (IA) que se basa en transformadores y modelos de lenguaje de gran tamaño, los cuales son mucho más eficaces para procesar datos de manera amplia (Lonos, 2025).

2.2.10.4. Modelos aplicados a alimentos

La aplicación de modelos de *deep learning* en la industria alimentaria ha crecido de manera sostenida, abarcando desde la autenticidad y el control de calidad hasta la

predicción sensorial y la optimización de formulaciones. En productos de panadería y galletería, algoritmos como las ANN, los bosques aleatorios y las DNN permiten analizar de manera compleja las interacciones entre formulación, procesado y calidad, facilitando la predicción de atributos como la textura, la estructura interna y el riesgo de deterioro del producto. En lo que respecta específicamente a la predicción sensorial, el *deep learning* sobresale en el manejo de entradas de alta dimensionalidad, imágenes, datos espectroscópicos y señales sensoriales, lo que lo convierte en una herramienta eficaz para el reconocimiento de atributos de sabor y la clasificación de patrones de aroma en sistemas alimentarios (Lee et al., 2025).

2.2.11. Métricas de evaluación de modelos predictivos

La evaluación del desempeño de un modelo predictivo es tan importante como su construcción. En modelos de regresión aplicados a la predicción de variables continuas, como los atributos sensoriales y texturales de galletas, esta evaluación se realiza mediante métricas que cuantifican la discrepancia entre los valores predichos y los valores reales. Cada métrica cumple un propósito específico y presenta sus propias fortalezas y limitaciones; por ello, combinar múltiples métricas ofrece una visión integral del desempeño del modelo y conduce a decisiones más fundamentadas sobre su validez (Jo et al., 2025).

2.2.11.1. Error cuadrático medio (MSE)

Se emplean métricas como el Error Cuadrático Medio (MSE) y el coeficiente de determinación R^2 para valorar su rendimiento en cuestiones de regresión. El MSE evalúa la magnitud promedio de los errores de predicción al cuadrado (penaliza más los errores grandes), mientras que el coeficiente de determinación R^2 mide qué porcentaje de la variabilidad en los datos es explicada por el modelo si está cerca del 1, significa que se ajusta mejor (Learn, 2025).

2.2.11.2. Coeficiente de determinación (R^2)

El coeficiente de determinación (R^2) es una de las métricas más utilizadas en la evaluación de modelos de regresión por su interpretabilidad directa. El R^2 puede interpretarse como el porcentaje de varianza explicada por el modelo, un valor de 0.75 indica que el modelo explica el 75% de la varianza en la variable objetivo y representa la mejora del modelo respecto a utilizar simplemente la media como predicción. Sin embargo, un R^2 elevado no garantiza necesariamente un buen modelo, porque puede verse afectado por valores atípicos o por sobreajuste; por ello,

es recomendable complementarlo con otras métricas diagnósticas como el MSE o la validación cruzada para una evaluación más completa y confiable del modelo (Warrens y Jurman, 2021).

2.2.11.3. Validación y ajuste de modelos

Construir un modelo predictivo con buenos resultados en la muestra utilizada para entrenarlo no garantiza que funcione bien con datos nuevos. Por esa razón, la validación constituye un paso irrenunciable en el ciclo de desarrollo de cualquier modelo de machine learning o deep learning: su propósito es estimar cuánto puede generalizarse el modelo a situaciones que no vio durante el aprendizaje. La técnica más ampliamente empleada para este fin es la validación cruzada k-fold, que divide el conjunto de datos disponible en k subconjuntos o "pliegues"; en cada iteración, el modelo se entrena con k-1 pliegues y se evalúa con el restante, repitiendo el proceso hasta que todos los pliegues hayan servido como conjunto de prueba (Pandian 2022). El rendimiento final se obtiene promediando las métricas de cada iteración, lo que proporciona una estimación más estable y menos dependiente de una partición particular de los datos. Esta ventaja resulta especialmente relevante en estudios de ciencia de alimentos, donde los conjuntos de datos suelen ser pequeños y cualquier división arbitraria entre entrenamiento y prueba puede distorsionar los resultados.

Junto a la validación, el ajuste de hiperparámetros como la tasa de aprendizaje, el número de capas ocultas, el número de neuronas por capa o la función de activación, es decisivo para obtener un modelo con buen equilibrio entre sesgo y varianza. Ajustar estos parámetros directamente sobre el conjunto de prueba introduce sobreajuste implícito, por lo que la práctica correcta es emplear un tercer subconjunto de validación o bien una validación cruzada anidada, en la que el bucle exterior mide el desempeño del modelo, mientras que el ciclo interior optimiza los parámetros de configuración (Turner, 2026). En el contexto del modelamiento predictivo de galletas enriquecidas, donde los datos experimentales son limitados y costosos de obtener, la elección de una estrategia adecuada de validación y ajuste puede marcar la diferencia entre un modelo robusto y uno que simplemente memoriza los datos de entrenamiento.

2.2.11.4. Interpretabilidad de modelos

Una de las tensiones más características del deep learning es la que existe entre su capacidad predictiva y su opacidad interna: cuanto más compleja y precisa es una

red neuronal profunda, más difícil resulta entender por qué genera una predicción determinada. Este fenómeno, conocido como el problema de la "caja negra", representa un obstáculo significativo para su adopción en contextos donde la toma de decisiones debe ser justificada, como el control de calidad alimentario o el diseño de formulaciones funcionales (Arrighi et al., 2026). En respuesta a este desafío, ha surgido el campo de la Inteligencia Artificial Explicable (XAI), que agrupa un conjunto de técnicas orientadas a hacer transparentes las decisiones de los modelos sin necesidad de sacrificar su rendimiento predictivo.

Entre las herramientas XAI más utilizadas en ciencia de alimentos destacan SHAP (SHapley Additive Explanations), que cuantifica la contribución de cada variable de entrada a la predicción del modelo de manera consistente y fundamentada en la teoría de juegos cooperativos; LIME (Local Interpretable Model-agnostic Explanations), que genera aproximaciones lineales locales para explicar predicciones individuales; y Grad-CAM, aplicado principalmente en modelos de visión por computadora para identificar las regiones de una imagen que más influyeron en la clasificación (Arrighi et al., 2026).

2.2.12. Aplicación del Deep Learning en productos de panificación

La industria de panificación genera productos de alta complejidad fisicoquímica, donde pequeñas variaciones en los ingredientes o en las condiciones de proceso pueden traducirse en cambios sustanciales en la textura, el color, el sabor y la aceptabilidad del producto final. Esta complejidad, lejos de ser un obstáculo para la aplicación del deep learning, representa precisamente el escenario donde estas arquitecturas demuestran mayor valor agregado. La revisión de Murugesan y otros (2026) sobre inteligencia artificial en panificación documenta que los modelos de IA, incluyendo ANN, SVM, RF y DNN, son capaces de analizar las interacciones entre formulación, procesamiento y calidad de manera compleja, prediciendo variables como el volumen del pan, la estructura de la miga, el riesgo de deterioro y las propiedades sensoriales con una precisión que los enfoques empíricos convencionales no alcanzan. Esta capacidad abre posibilidades concretas para el diseño racional de formulaciones enriquecidas, donde la incorporación de ingredientes funcionales, como las nanopartículas de carbonato de calcio, introduce interacciones adicionales que exigen herramientas analíticas de mayor poder de resolución.

2.2.12.1. Predicción de calidad en galletas

La predicción de la calidad en galletas mediante modelos computacionales ha evolucionado desde aproximaciones empíricas simples hasta el uso de arquitecturas de deep learning capaces de procesar simultáneamente variables fisicoquímicas, de proceso y sensoriales. Un referente importante en esta línea es el trabajo de Loncar (2024), quien construyó modelos ANN y SVM para predecir 32 parámetros de calidad en galletas enriquecidas con durazno deshidratado, incluyendo composición química, contenido mineral, propiedades de horneado, color, atributos sensoriales y capacidad antioxidante. Los resultados mostraron que las ANN alcanzaron coeficientes de determinación de hasta $R^2 = 1.000$, con las SVM presentando valores de hasta $R^2 = 0.981$, lo que evidenció la eficiencia superior de las ANN para la predicción simultánea de variables de diferente naturaleza. En un estudio relacionado, Eryesil y Koklu (2025) emplearon algoritmos de aprendizaje profundo orientados a identificar unidades defectuosas dentro de la producción industrial de galletas, reduciendo los errores humanos en el control de calidad mediante la clasificación automática de imágenes con arquitecturas CNN, alcanzando niveles de exactitud comparables a los obtenidos con otros productos de panificación. Ambos estudios confirman que el deep learning no solo es viable en el contexto de las galletas, sino que representa una herramienta metodológicamente superior a los enfoques estadísticos convencionales cuando el objetivo es integrar múltiples indicadores de calidad en un único sistema predictivo.

2.2.12.2. Modelado de atributos sensoriales

El modelado computacional de atributos sensoriales parte de una premisa central: las evaluaciones realizadas por paneles humanos, aunque insustituibles desde el punto de vista de la validez ecológica, son costosas, subjetivas y difíciles de escalar. En este sentido, los modelos de machine learning y deep learning ofrecen una alternativa capaz de predecir descriptores sensoriales como la dureza, la crocancia, el dulzor o la aceptabilidad global a partir de datos instrumentales y fisicoquímicos, sin requerir evaluaciones sensoriales sistemáticas en cada nueva formulación (Hussain et al., 2026). Esta capacidad es especialmente valiosa en el desarrollo de productos funcionales enriquecidos, donde los cambios en la formulación son frecuentes y cada iteración exigiría una nueva evaluación sensorial completa.

En este sentido, Lee y otros (2025) propusieron un autoencoder neuronal con sesgo sensorial para predecir la percepción de textura a partir de parámetros reológicos en alimentos líquidos, demostrando que las redes neuronales son especialmente adecuadas para capturar las relaciones no lineales entre las propiedades físicas del alimento y la percepción humana, relaciones que los modelos estadísticos lineales clásicos no logran representar de forma satisfactoria. Complementariamente, Ge y otros (2025) revisaron las aplicaciones del ML en la predicción y regulación del sabor en alimentos, concluyendo que los modelos de deep learning y aprendizaje en conjunto (*ensemble learning*) ofrecen el mejor desempeño en conjuntos de datos complejos y no lineales, y que herramientas XAI como SHAP mejoran la transparencia de las predicciones al vincularlas con los compuestos o variables responsables. Aplicado al caso de las galletas enriquecidas con nanopartículas de carbonato de calcio, este enfoque permitiría construir modelos que relacionen directamente las propiedades fisicoquímicas de la galleta, dureza, fracturabilidad, color, actividad de agua, con los atributos sensoriales evaluados por consumidores, aportando así una comprensión integral del efecto de las nanopartículas sobre la experiencia sensorial del producto.

2.2.12.3. Optimización de formulaciones

La optimización de formulaciones alimentarias representa uno de los problemas más complejos de la tecnología de alimentos, dado que implica satisfacer simultáneamente múltiples objetivos, calidad sensorial, valor nutricional, costo de ingredientes y vida útil, bajo restricciones que interactúan de manera no lineal. Frente a los métodos estadísticos convencionales como la metodología de superficie de respuesta (RSM), que resultan eficientes cuando el número de variables es reducido, pero pierden precisión ante espacios de formulación de alta dimensionalidad, los modelos de machine learning ofrecen una alternativa de mayor alcance. Acorde con (Lončar et al., 2024), demostraron que las ANN permiten no solo predecir parámetros de calidad en galletas enriquecidas, sino también realizar optimización multiobjetivo para identificar la combinación óptima de ingredientes, concluyendo que la cantidad idónea de durazno liofilizado con pretratamiento osmótico fue del 15%, resultado obtenido exclusivamente a partir del análisis computacional del modelo. Del mismo modo, Hussain y otros (2026) evidenciaron que los modelos de ML entrenados con datos reológicos, estructurales y sensoriales permiten predecir rápidamente la combinación correcta de ingredientes, acelerando el ciclo de

desarrollo de productos funcionales sin necesidad de experimentación exhaustiva. Trasladado al contexto de las galletas enriquecidas con nanopartículas de carbonato de calcio, este enfoque permitiría identificar los rangos óptimos de incorporación de las nanopartículas que maximicen la aceptabilidad sensorial y minimicen los efectos adversos sobre la textura, guiando la reformulación con una base cuantitativa sólida.

2.2.12.4. Casos de estudio relevantes

La literatura científica reciente ofrece casos de estudio que ilustran, de forma concreta, el alcance y las posibilidades del deep learning aplicado a productos de panificación. Uno de los más directamente relacionados con la presente investigación es el de (Lončar et al., 2024), quienes construyeron modelos ANN y SVM para predecir 32 parámetros de calidad en galletas enriquecidas con durazno deshidratado, alcanzando coeficientes de determinación de hasta $R^2 = 1.000$ para atributos sensoriales y fisicoquímicos, lo que confirma la viabilidad del enfoque en productos de composición compleja. En el campo del control visual de calidad, Kilci y otros (2025), señalaron que el uso de arquitecturas CNN, incluyendo modelos YOLOv8, para la clasificación automatizada de galletas defectuosas en línea de producción industrial, con tasas de exactitud superiores al 98%, reduciendo errores humanos y costos operativos. Por su parte, en el ámbito de la panificación, Murugesan y otros (2026), demostraron que la implementación piloto de modelos LSTM para el control de fermentación en la empresa Barilla Group, así como el uso de redes neuronales profundas en Yamazaki Baking Co para predecir el perfil sensorial a partir de datos de nariz y lengua electrónicas, con correlaciones superiores a $r = 0.92$ con las evaluaciones de paneles entrenados. Estos casos, aunque desarrollados en contextos diferentes al de las galletas enriquecidas con nanopartículas de carbonato de calcio, establecen precedentes metodológicos sólidos que validan el uso del deep learning como herramienta predictiva en la industria de panificación y fundamentan su aplicación en el presente estudio.

2.2.13. Integración del enfoque: alimentos + IA

La convergencia entre la ciencia de alimentos y la inteligencia artificial no constituye simplemente la superposición de dos disciplinas, sino la emergencia de un enfoque integrado donde los modelos computacionales se nutren del conocimiento fisicoquímico y, a su vez, generan hipótesis que retroalimentan la investigación

experimental. Esta integración resulta especialmente relevante en el estudio de alimentos funcionales enriquecidos, donde la multiplicidad de variables y la complejidad de sus interacciones superan la capacidad de los enfoques analíticos convencionales. El resultado es un ciclo virtuoso en el que los datos experimentales alimentan los modelos, los modelos generan predicciones, y las predicciones orientan nuevos experimentos con mayor eficiencia y precisión (Liakos et al., 2025).

2.2.13.1. Modelos híbridos fisicoquímicos–computacionales

Los modelos híbridos representan una de las líneas de desarrollo más prometedoras en la intersección entre la ciencia de alimentos y la inteligencia artificial. Su lógica es sencilla pero poderosa: en lugar de elegir entre un modelo puramente mecanístico, basado en ecuaciones de transferencia de calor, cinética de reacción o principios termodinámicos, y uno puramente basado en datos, los enfoques híbridos combinan ambos, integrando el conocimiento de dominio como restricción o estructura del modelo y aprovechando los datos experimentales para ajustar los parámetros que la teoría no puede determinar a priori. Esta combinación tiene una consecuencia práctica fundamental: los modelos híbridos requieren conjuntos de datos de entrenamiento más pequeños para alcanzar un desempeño equivalente al de los modelos puramente basados en datos, lo que los hace especialmente adecuados en contextos donde los experimentos son costosos o la cantidad de muestras disponibles es limitada (Hassoun et al., 2024). En el caso del horneado de galletas enriquecidas, un modelo híbrido podría integrar ecuaciones de transferencia de masa y calor para describir la evaporación del agua y la gelatinización del almidón, mientras que la parte de aprendizaje automático capturaría las interacciones complejas entre las nanopartículas de carbonato de calcio y la red proteica que modifican la textura final del producto.

2.2.13.2. Digitalización de procesos alimentarios

La digitalización de los procesos alimentarios implica transformar las operaciones de producción en sistemas conectados, donde los datos generados en cada etapa, desde la recepción de materias primas hasta el producto terminado, son capturados, almacenados y analizados en tiempo real. Esta transformación se apoya en tecnologías como el Internet de las Cosas (IoT), los sensores inteligentes y el cómputo en la nube, que en conjunto permiten construir flujos continuos de datos sobre los que los modelos de IA pueden operar. Según Dadhaneeya y otros (2023), señalan que el

IoT tiene el potencial de mejorar la sostenibilidad general, reducir el consumo de energía y disminuir los costos de manufactura en la industria de procesamiento de alimentos, y que la convergencia entre IA, IoT y blockchain está impulsando la evolución hacia la Industria 4.0 alimentaria, con avances en análisis de alta precisión, automatización y control de calidad. Aplicada al proceso de elaboración de galletas, la digitalización permitiría capturar variables de proceso, temperatura y tiempo de horneado, humedad relativa, granulometría de las nanopartículas incorporadas y vincularlas directamente con los parámetros de calidad del producto final, generando el conjunto de datos necesario para entrenar modelos predictivos de deep learning con representatividad industrial.

2.2.13.3. Industria 4.0 en alimentos

La cuarta revolución industrial, o Industria 4.0, ha impulsado en la industria alimentaria una transformación profunda que va más allá de la automatización de procesos: implica la creación de sistemas ciberfísicos inteligentes donde la información fluye bidireccionalmente entre el entorno físico de producción y su representación digital. Hassoun y otras (2024), identifican como tecnologías habilitadoras clave la inteligencia artificial, el big data, el blockchain, los gemelos digitales, la computación en la nube, los sensores inteligentes, la robótica y el IoT, señalando que su integración permite crear sistemas interconectados e inteligentes que mejoran la automatización, la trazabilidad y la eficiencia operativa a lo largo de toda la cadena de valor alimentaria. Por su parte, Hassoun y otros (2023), menciona que los sensores inteligentes, la inteligencia artificial, el IoT y el big data como los principales habilitadores de la transformación digital en la industria de alimentos procesados. En este marco, el modelamiento predictivo de galletas enriquecidas mediante deep learning no es un caso aislado, sino una expresión concreta del paradigma de la Industria 4.0 aplicado al desarrollo de productos funcionales: integra datos instrumentales, sensoriales y de proceso en un sistema computacional que puede apoyar decisiones de formulación y control de calidad con base científica.

2.2.13.4. Perspectivas futuras en investigación

El panorama de la inteligencia artificial aplicada a la ciencia de alimentos está lejos de haberse consolidado; por el contrario, se encuentra en una fase de expansión activa donde emergen continuamente nuevas herramientas, enfoques y áreas de aplicación. Entre las tendencias de mayor proyección destacan la IA explicable (XAI),

el aprendizaje por transferencia (*transfer learning*), los modelos multimodales y la integración de datos ómicos con modelos de deep learning para el diseño de alimentos funcionales. Oz y otros (2025), concluyen que los modelos de deep learning ofrecen capacidades mejoradas para analizar datos espectrales, de imágenes y ómicos de alta dimensionalidad, y señalan que la IA explicable se perfila como un requisito indispensable para que los modelos puedan ser adoptados con confianza en la industria alimentaria, donde la comprensión mecanística de los resultados es tan importante como la precisión de las predicciones. De igual manera, Alkalbani y otros (2026), destacan que, para la transición de prototipos experimentales a la adopción industrial generalizada, los sistemas de IA del futuro deberán priorizar la explicabilidad, la inclusividad cultural, la solidez regulatoria y la responsabilidad ecológica. Estas perspectivas son directamente relevantes para la presente investigación: el modelamiento predictivo de galletas enriquecidas con nanopartículas de carbonato de calcio puede constituir un caso de estudio pionero en el que la convergencia entre nanotecnología alimentaria, análisis fisicoquímico y deep learning abra una línea de investigación replicable para otros alimentos funcionales enriquecidos con minerales a escala nanométrica.

2.2.13.5. Tipos de Deep Learning

El deep learning se basa en el uso de las redes neuronales artificiales (Tokio, 2023), las cuales están divididas en los siguientes tipos:

- Redes neuronales convolucionales (CNN)
- Redes neuronales recurrentes (RNN)
- Redes neuronales generativas adversarias (GAN)
- Redes neuronales profundas (DNN)
- Redes neuronales modulares (MNN)

III. METODOLOGÍA

3.1. ENFOQUE METODOLÓGICO

3.1.1. Enfoque

El presente proyecto de investigación se presentará mediante un enfoque cuantitativo, porque busca construir un modelo matemático para las características sensoriales y texturales a partir de las propiedades fisicoquímicas de la galleta. Se ha establecido este enfoque porque se basa en la recolección de datos que provienen de ensayos experimentales y condiciones controladas de las variables establecidas como: fisicoquímicas, texturales y sensoriales de la galleta permitiendo establecer un modelo matemático predictivo. Además, se emplearán análisis estadísticos para el procesamiento de datos, lo que permitirá la interpretación de los resultados conseguidos. La investigación se vuelve cuantitativo cuando se recopilan los datos y se interpretan estadísticamente (Millán, 2018).

3.1.2. Tipo de Investigación

Se desarrollará una investigación experimental, busca mejorar la textura de galletas enriquecidas con nanopartículas de carbonato de calcio utilizando redes neuronales recurrentes, aplicando el modelo predictivo deep learning. Se realizará una investigación experimental debido a que se manipularán variables controladas con el fin de examinar el impacto de las nanopartículas de carbonato de calcio en la textura de las galletas. Para asegurar los resultados que puedan ser comparados, se establecerán condiciones precisas de formulación y horneado, siguiendo un protocolo estructurado que posibilite la medición objetiva de los cambios en la textura. Asimismo, se utilizarán procedimientos establecidos en análisis sensorial y fisicoquímico, que se complementarán con un modelo predictivo de deep learning. La investigación experimental, determina las causas y los efectos de un fenómeno observados en el experimento (Sreekumar, 2024).

3.2. HIPÓTESIS

Hipótesis nula: El modelo predictivo obtenido a partir de deep learning no contribuye con la optimización las propiedades fisicoquímicas, texturales y sensorial de las galletas enriquecidas con nanopartículas de carbonato de calcio.

Hipótesis alterna: El modelo predictivo obtenido a partir de deep learning contribuye con la optimización de las propiedades fisicoquímicas, texturales y sensoriales de las galletas enriquecidas con nanopartículas de carbonato de calcio.

3.3. DEFINICIÓN Y OPERACIONALIZACIÓN DE LAS VARIABLES

3.3.1. Definición de las variables

Variable independiente:

- Desempeño del modelo predictivo deep learning

Variable dependiente:

- Características sensoriales
- Características texturales

Variables de control:

- Características fisicoquímicas

3.3.2. Operacionalización de las variables

Tabla 3. Operacionalización de las variables para el tema “Modelamiento predictivo mediante Deep Learning de las características sensoriales y texturales de galletas enriquecidas con nanopartículas de carbonato de calcio y su relación con las propiedades fisicoquímicas”

Variable	Dimensión	Indicador	Técnica de Medición	Instrumento
V. dependiente				
Características texturales	Textura instrumental	Dureza, fracturabilidad, cohesividad, masticabilidad, trabajo total realizado	Análisis TPA	(Aname 2024)
Características sensoriales	Evaluación subjetiva	Sabor, aroma, color, apariencia, crocancia	Prueba afectiva con escala hedónica de 5 Puntos	UNE-ISO 4121:2006
V. independiente				
Desempeño del modelo de DL	Modelamiento predictivo	Error Cuadrático Medio (MSE), R^2	Modelos de deep learning (redes neuronales)	(Tavishi 2023)
V. de control				
Propiedades fisicoquímicas	Composición	Humedad	Gravimetría	AOAC 925.10
Harinas		Proteína	Método de Kjeldahl	AOAC 960.52
		Extracto de etéreo	Método de Soxhlet	AOAC 945.16
		Cenizas	Gravimetría	AOAC 923.03
		Fibra cruda	Método de Weende	AOAC 945.88
		Carbohidratos	Diferencia de porcentajes	AOAC 985.25
		Contenido de almidón	Método de Wijs	(Lage et al., 1983)
		Acidez	Acidez titulable	NTE INEN 521:2013

3.4. MÉTODOS UTILIZADOS

3.4.1. Proceso de elaboración de galletas y métodos

En la siguiente figura se visualiza el diagrama de flujo de la elaboración de galletas con harinas de amaranto y chocho.




Figura 3. Diagrama de galletas de harina de amaranto y chocho.

Descripción del diagrama

- Recepción de Harina de amaranto y chocho: las materias primas se reciben y se les realiza un chequeo visual para asegurar que no haya impurezas visibles.

- Pesado: por medio de una gramera se pesan todos los ingredientes que se utilizarán para hacer las galletas.
- Mezclado: las claras de huevo se llevan a un punto de nieve.
- Homogenizado: se mezcló todos los ingredientes secos pesados previamente, se incorporó la margarina e ingredientes húmedo hasta obtener una masa uniforme.
- Refrigerado: se refrigeró a 5°C durante 30 minutos
- Pesado: pesar en porciones de 8,5g.
- Moldeado: se colocó la masa pesada en los moldes.
- Horneada: se horneó la masa a 165°C durante 50 min.
- Enfriado: dejar reposar y enfriar durante 24 h a temperatura ambiente.
- Empacado: se colocó en fundas herméticas para poder evitar contaminación y daños texturales.
- Almacenado: colocar en un ambiente seco.

3.4.2. Caracterización fisicoquímica

Las harinas y mezclas adquiridas serán sometidas a análisis de humedad, proteína, extracto etéreo, fibra, ceniza, carbohidratos, almidón y acidez; siendo estos los requisitos que las harinas deben cumplir. Las metodologías de ensayo se detallan específicamente en las normativas AOAC e INEN.

3.4.2.1. Determinación de humedad

Se utiliza la norma AOAC 925.10, donde se siguió los siguientes pasos:

- 1) Tarar previamente las capsulas en la estufa a 105°C durante 60 minutos hasta obtener un peso constante.
- 2) En una balanza analítica con precisión de $\pm 0,001$ g, se pesó una muestra de 3 a 5 gramos y se colocó en las capsulas etiquetadas con cada tratamiento.
- 3) Se llevó las muestras a la estufa a una temperatura de 103°C por un tiempo de 3 horas.
- 4) Se retiró las capsulas de la estufa, colocando en el desecador y dejando enfriar de 10 a 15 minutos. Una vez enfriado se pesó para obtener el peso final.
- 5) Se utilizó la siguiente ecuación:

$$\%H = \frac{W_1 - W_2}{W_M} \times 100$$

Donde:

W_1 = Peso capsula con muestra seca (en gr).

W_2 = Peso de la capsula vacío (en gr).

W_M = Peso de la muestra (en gr).

3.4.2.2. Determinación de proteína

Para la determinación del contenido de proteína se usó el método 2001.11 descrito en la norma AOAC 960.52, mediante el procedimiento Kjeldahl. Este procedimiento es un estándar reconocido que consta de tres etapas principales:

Digestión:

- Se pesó 1 g de muestra sobre un papel de pesaje previamente tarado y, posteriormente, se trasladó a un tubo Kjeldahl.
- A cada tubo se le incorporaron 12 ml de H_2SO_4 concentrado junto con 2 pastillas catalizadoras.
- Digerir hasta que la mezcla tenga un color verde claro.

Destilación:

- Se enfría las muestras durante 10 a 20 minutos dentro de la campana de flujo laminar, hasta que deje de salir humo proveniente de los tubos.
- Se agregó un poco de agua desionizada a cada tubo y, en caso de presentarse salpicaduras del líquido, se esperó unos minutos para que enfriara. Posteriormente, se añadió agua a cada tubo hasta alcanzar un volumen total de 80 mL y se llevó al destilador.
- Neutralización: Se incorporaron 50 mL NaOH 40% para liberar NH_3 .
- Se capta en un matraz Erlenmeyer la solución del NH_3 en solución de ácido bórico (H_3BO_3).

Titulación:

- La valoración se realizó empleando ácido clorhídrico 0.1 N, utilizando rojo de metilo como indicador.
- Cálculo mediante ecuación:

$$\%Nitrógeno = \frac{1,4 \cdot (V_1 - V_0) \cdot N}{P}$$

$$\%Proteína = \%Nitrógeno \cdot F$$

Donde:

P = peso en g de la muestra

V₁ = volumen de HCl consumido en la valoración (mL)

V₀ = volumen de HCl consumido en la valoración de un blanco

N = normalidad del HCl

F = Factor de conversión

3.4.2.3. Extracto de etéreo

Se utilizó el método de Soxhlet descrito por la norma AOAC 945.16:

1. Se pesó un balón limpio, seco y frío, anotando en el registro su peso en gramos junto con el número correspondiente.
2. Se elaboró un cartucho con papel filtro, el cual fue pesado antes de añadir entre 3 y 5 gramos de muestra seca.
3. Se colocó el cuerpo del equipo de Soxhlete colocó el cuerpo del equipo Soxhlet en su posición adecuada.
4. Se añadió hexano hasta que una parte del solvente descendió por el sifón hacia el balón y se conectó la fuente de calor, una cocina eléctrica.
5. Al calentarse el hexano a 69 °C, este se evaporó y ascendió hasta la parte superior de la cámara de extracción, donde se condensó mediante un sistema de refrigeración con agua. El líquido condensado cayó sobre la muestra y regresó al balón a través del sifón, arrastrando la grasa durante aproximadamente tres horas.
6. Se retiró el cartucho con la muestra desengrasada, y el balón fue extraído del aparato cuando contenía poco hexano.
7. Se evaporó el hexano remanente colocando el balón en una estufa a 100 °C.
8. Se sacó el balón de la estufa y se colocó en un desecador para su enfriamiento.
9. Se pesó el balón que contenía la grasa extraída.

El resultado se expresa en porcentaje, calculando según la fórmula:

$$\%Grasa = \frac{P_1 - P_2}{m} \times 100$$

Donde:

P₁ = Peso del balón más muestra grasa.

P₂ = Peso del balón vacío.

m = Peso de la muestra.

3.4.2.4. Cenizas

El contenido de cenizas se determinó mediante el método de incineración descrito por la norma AOAC 923.03:

- Se colocó un crisol limpio en una estufa a una temperatura de 100 °C durante una hora.
- Se retiró y se enfrió en un desecador, para luego pesarlo, manejándolo siempre con pinzas metálicas o guantes con el propósito de prevenir la contaminación proveniente de la grasa de las manos.
- Se pesó entre 1,5 y 2 gramos de la muestra y se deposita en el crisol de porcelana.
- El crisol con la muestra se introdujo en una mufla, manteniéndose a una temperatura constante de 550 °C por un lapso de 3 a 5 horas.
- Una vez transcurrido este tiempo de incineración, se extrajo el crisol de la mufla cuando la temperatura haya descendido a 100 °C y se volvió a colocar en un desecador para su enfriamiento.
- Se procedió a pesar nuevamente el crisol ahora con las cenizas obtenidas.

Calcular el porcentaje de cenizas con la siguiente ecuación:

$$\% \text{Cenizas} = \frac{(W_1 - W_2)}{W_M} \times 100$$

Donde:

W₁ = Peso de crisol más muestra (g).

W₂ = Peso crisol (g).

W_M = Peso de la muestra (g).

3.4.2.5. Determinación de Fibra

El contenido de fibra cruda de un alimento se determinó mediante un proceso de digestión ácida y alcalina, seguido de un lavado y secado, que permitió separar la

fibra insoluble. El procedimiento estandarizado por la Norma AOAC 962.09, se despliega a través de las siguientes etapas:

1. Se taró los crisoles previamente limpios, se seca en la estufa a 105 °C por un lapso de 60 minutos, hasta alcanzar una masa constante.
2. Pesaje en una balanza analítica, de una alícuota de 1 a 2 gramos de la muestra, la cual debe estar seca y previamente desengrasada.
3. El contenido de la muestra se pasó a un matraz con capacidad de 1 litro. A continuación, se le agregó 200 mL de ácido sulfúrico al 1.25%, el cual debió haber sido precalentado hasta su punto de ebullición.
4. Para impedir la generación de espuma a lo largo del proceso, se empleó un agente antiespumante.
5. El matraz se giró de manera periódica mientras la mezcla era hervida durante un lapso de 30 minutos bajo un condensador de reflujo. Es esencial para evitar que las partículas se adhieran a las paredes del recipiente.
6. Para filtrar la muestra, se utilizó un embudo de Hartley o Buchner y papel de filtro húmedo.
7. La muestra se lavó con agua caliente para arrastrar los componentes solubles hacia el matraz. Posteriormente, se incorporaron 200 mL de hidróxido de sodio Ecuación 5 60 al 1,25%; la mezcla se calienta a ebullición por otros 30 minutos. Tras este período, se realiza una segunda filtración.
8. El crisol recibió el material insoluble que quedó. El material fue lavado sucesivamente con agua hirviendo, ácido clorhídrico al 1% y, por último, con agua destilada hasta asegurar que se eliminaron totalmente todos los residuos ácidos.
9. Para purificar la fibra aún más, se efectuaron tres lavados con acetona y dos con etanol.
10. La fibra cruda adquirida se secó en el crisol, a 100 °C, en una estufa, hasta que su peso fue constante.
11. La fibra cruda presente en el crisol fue incinerada en una mufla a 550 °C, durante un lapso de una hora.
12. Luego de ser incinerado, el crisol con la fibra cruda se dejó enfriar en un desecador para que posteriormente pudiera pesarse.

Con la siguiente formula se determina el contenido de fibra cruda:

$$\%FC = \frac{(W_2 - W_3) - (B_2 - B_3)}{W_1} \times 100$$

Donde:

% FC = Porcentaje de fibra cruda en la muestra.

W₁ = Peso de la muestra original (g) utilizada para el análisis.

W₂ = Peso del crisol con el residuo después del secado.

W₃ = Peso del crisol con la ceniza (materia inorgánica) después de la incineración.

B₂ y B₃ = Pesos promedio de todos los blancos después del horno y la incineración.

3.4.2.6. Determinación de Carbohidratos totales

Para la determinación de carbohidratos, se utilizó el método propuesto por la norma AOAC 985.25 (2014), detalla utilizar la siguiente formula:

$$\text{Carbohidratos} = 100 - (\% \text{ Humedad} + \% \text{ proteína} + \text{grasas} + \text{fibra})$$

3.4.2.7. Contenido de almidón

Se utilizó el procedimiento mencionado en el artículo de (Lage et al. 1983), para establecer la cantidad de almidón presente en las muestras. Esta consta de:

1. Se pesó 0,1 gramos de la muestra y se taró con 10 mL de ácido perclórico al 52%; luego, se mezcló y se dejó reposar durante diez minutos.
2. La muestra se diluyó con agua destilada hasta alcanzar un volumen de 100 mL.
3. Se prepararon cuatro matraces volumétricos de 50 mL, añadiendo a cada uno 2,5 mL de ácido perclórico al 52%. Se les incorporó, uno a uno, 1 mL, 1.5 mL, 2 mL y 2.5 mL de la solución de almidón, llenando el volumen con agua destilada hasta la línea marcada correspondiente.
4. Se tomó 10 mL de cada matraz y se añadió 0,5 mL de la solución de yodo yodurada; después, se dejó reposar la mezcla por diez minutos en oscuridad total.

5. Se utilizó un espectrofotómetro para medir la absorbancia una vez pasado el tiempo fijado, tomando como referencia un blanco y anotando tanto el valor máximo como el que correspondía a una longitud de onda de 600 nm.

3.4.2.8. Acidez

Se utilizó la técnica que define la NTE INEN 521:2013 para establecer el nivel de acidez titulable en ejemplos de harinas vegetales. Para llevar a cabo este análisis, se realizó de la siguiente manera:

1. Se utilizó un matraz Erlenmeyer de 100 cm³ para pesar una muestra de 5 g.
2. Se colocó en la muestra 50 cm³ de alcohol al 90% (V/V) neutralizado, se tapó y se agitó fuerte.
3. Se dejó reposar por 24 horas, agitando de vez en cuando.
4. Se extrajo 10 cm³ del líquido sobrenadante y se depositó en un matraz Erlenmeyer de 50 cm³.
5. Se añadió 2 cm³ de fenolftaleína a la muestra y se realizó una titulación con un reactivo de hidróxido de sodio a 0,02 N (valorado).
6. Se añadió la solución poco a poco hasta que se logró un color rosado claro, que se mantuvo durante 30 segundos.
7. Se realizó el cálculo con la fórmula siguiente después de haber obtenido el volumen consumido:

$$A = \frac{490 \cdot N \cdot V}{m(100-H)} \times \frac{V_1}{V_2}$$

Donde:

A = Contenido de acidez en porcentaje de masa de ácido sulfúrico.

N = Normalidad de la solución de NaOH.

V = Volumen consumido de NaOH en la titulación en cm.

V1 = Volumen de alcohol empleado (cm³)

V2 = Volumen de la muestra tomada (cm³) m = Peso de la muestra (g)

H = Contenido de humedad (%)

3.4.3. Textura de galletas

El análisis de textura se realizó empleando el método de comprensión donde se midieron parámetros de dureza y fracturabilidad con un texturómetro (Brookfield

Ametek®, Estados Unidos) y el Software Texture Pro, a una velocidad de 0,5 mm/ s, distancia de penetración de 3 mm. Para cada uno de los tratamientos se realizaron 10 repeticiones, en las pruebas se emplearon una sonda de flexión de tres puntos de acuerdo con el método descrito por (González et al. 2023), con algunas modificaciones.

En la tabla 4 se observan los métodos para el análisis de las propiedades texturales de galletas.

Tabla 4. Análisis textural

Análisis	Método	Unidad
Dureza	TPA (texturómetro Brookfield)	N
Fracturabilidad	TPA (texturómetro Brookfield)	N
Cohesividad	TPA (texturómetro Brookfield)	SA
Masticabilidad	TPA (texturómetro Brookfield)	mJ
Trabajo total realizado	TPA (texturómetro Brookfield)	mJ

3.4.4. Análisis sensorial

El análisis sensorial consiste en examinar las características sensoriales de un producto utilizando los sentidos humanos, evaluando aspectos como la apariencia visual, olor, aroma, textura y sabor. Para medir la aceptación del producto, se empleará una escala hedónica de 5 puntos, un método reconocido y validado que permite cuantificar el nivel de agrado del consumidor (Chavez, 2023).

3.4.5. Desempeño del modelo Deep learning

Los modelos de aprendizaje profundo, que se fundamentan en redes neuronales profundas, son instrumentos para el modelado predictivo. Estos modelos adquieren patrones no lineales y complejos a partir de grandes cantidades de datos utilizando diversas capas de transformación (Fernández, 2023).

3.5 DISEÑO EXPERIMENTAL

3.5.1. Análisis Estadístico

La presente investigación se evaluará los diferentes porcentajes entre harina de chocho y amaranto, en la formulación de galletas, por lo cual, se estableció un DCA con 3 repeticiones. Se va a realizar análisis de Shapiro-Wilk con la finalidad determinar si son datos paramétricos o no paramétricos para determinar la influencia de variación de porcentajes.

3.5.2. Tratamientos

En la tabla 5 se muestra la formulación que se ocupó en los tratamientos experimentales.

Tabla 5. Formulación de tratamientos

Tratamiento	Esquema experimental	R	T. U
T0	100 % amaranto + 0% chocho	3	100%
T1	90% amaranto + 10% chocho	3	100%
T2	80% amaranto + 20% chocho	3	100%
T3	70% amaranto + 30% chocho	3	100%
T4	60% amaranto + 40% chocho	3	100%

T.U = tamaño de la unidad experimental y UE = Unidad experimental

Numero de tratamientos = 4

Numero de repeticiones = 3

Unidades experimentales = 12 incluyendo el blanco o T0 15 unidades experimentales.

3.5.3. Formulación de las galletas

En la tabla 6 se muestran los porcentajes de amaranto con chocho planteado para la elaboración de las galletas.

Tabla 6. Ingredientes

Descripción	Porcentaje (%)
Harina de amaranto o chocho	35.2
Huevo	13.77
Esencia de vainilla	0.25
Polvo para hornear	0.47
Panela	20.95
Margarina	28.31
Carbonato de calcio	0.1

IV. RESULTADOS Y DISCUSIÓN

4.1. RESULTADOS

4.1.1. Caracterización de los tratamientos formulados

4.1.1.1. Caracterización fisicoquímica de las harinas

- Acidez

En la tabla 7 se puede observar que los tratamientos T0, T1 y T2 mantienen su acidez, mientras que los otros tratamientos T3 y T4 se encuentran con variaciones mínimas.

Tabla 7. Prueba de Kruskal-Wallis + Dunn para acidez.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	0.137 ± 0.006	Kruskal-Wallis + Dunn
T1	A	0.137 ± 0.006	Kruskal-Wallis + Dunn
T2	A	0.137 ± 0.006	Kruskal-Wallis + Dunn
T3	A	0.14 ± 0.001	Kruskal-Wallis + Dunn
T4	A	0.133 ± 0.006	Kruskal-Wallis + Dunn

La tabla 8 presenta el resultado de la prueba no paramétrica Kruskal-Wallis donde se evaluó la acidez. Obteniendo un valor 0,59 que es superior a 0,05 se concluye que no existen diferencias significativas en los tratamientos por lo que respecta a esta variable.

Tabla 8. Prueba de Kruskal-Wallis para acidez.

Prueba	Chi cuadrado	Df	Valor-p
Kruskal-Wallis	2,8	4	0,59

El diagrama de caja y bigote presente en la figura 4; no existen diferencias estadísticamente significativas entre los diferentes tratamientos ($p < 0,05$).




Figura 4. Diagrama caja y bigote para acidez.

- Almidón

Como se observa en la tabla 9 mediante ANOVA y Tukey, una disminución progresiva desde el tratamiento T0 hasta T4. Las letras indican que son estadísticamente diferentes, los tratamientos T3 y T4 comparten la misma letra.

Tabla 9. Prueba de ANOVA + Tukey para almidón.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	173.033 ± 7.115	ANOVA + Tukey
T1	B	160.733 ± 2.479	ANOVA + Tukey
T2	C	140.633 ± 1.85	ANOVA + Tukey
T3	D	130.1 ± 2.7	ANOVA + Tukey
T4	D	124.433 ± 2.183	ANOVA + Tukey

Es posible afirmar que hay diferencias estadísticamente significativas, dado que el valor de p es notablemente menor a 0.05, como se ilustra en la tabla 10.

Tabla 10. Prueba de ANOVA para almidón.

Df	Sum	Mean	Valor-F	Valor-p
4	5083	1270,7	87,9	$9,45 \times 10^{-8}$
10	144	14,4		

La figura 5, presenta un diagrama de caja y bigote, se consigue mediante la comparación de los tratamientos. Indica que existen diferencias importantes, las cuales son señaladas con letras distintas por grupos.




Figura 5. Diagrama de caja y bigote para almidón.

- Carbohidratos

En la tabla 11 se analiza que cada tratamiento tiene una letra totalmente distinta, lo que señala diferencias significativas notables.

Tabla 11. Prueba de ANOVA + Tukey para carbohidratos.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	65.167 ± 0.404	ANOVA + Tukey
T1	B	55.733 ± 0.306	ANOVA + Tukey
T2	C	45.9 ± 0.361	ANOVA + Tukey
T3	D	41.067 ± 0.551	ANOVA + Tukey
T4	E	34.6 ± 0.721	ANOVA + Tukey

La tabla 12 del ANOVA muestra que el valor de p es considerablemente inferior a 0,05. Esto evidencia que estadísticamente existe diferencias significativas en la cantidad de almidón.

Tabla 12. Prueba de ANOVA para carbohidratos.

Df	Sum	Mean	Valor-F	Valor-p
4	1755	438,99	1814	$2,95 \times 10^{-14}$
10	2,42	0,242		

Al comparar los tratamientos, que se presenta la figura 6, que contiene un diagrama de caja y bigote. Indica que existen diferencias importantes, las cuales son señaladas con letras distintas por grupos.




Figura 6. Diagrama de caja y bigote para carbohidratos.

- Cenizas

En la tabla 13 se analiza que cada tratamiento tiene una letra completamente diferente indicando diferencias significativas.

Tabla 13. Prueba de ANOVA + Tukey para cenizas.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	3.76 ± 0.02	ANOVA + Tukey
T1	B	2.403 ± 0.025	ANOVA + Tukey
T2	C	2.3 ± 0.01	ANOVA + Tukey
T3	D	1.893 ± 0.015	ANOVA + Tukey
T4	E	1.69 ± 0.01	ANOVA + Tukey

Como se puede observar existe una diferencia significativamente entre los tratamientos evaluados respecto al contenido de cenizas, obteniéndose que el valor de p es inferior a 0,05 en la tabla 14.

Tabla 14. Prueba de ANOVA para cenizas.

Df	Sum	Mean	Valor-F	Valor-p
4	1755	438,99	1814	$4,33 \times 10^{-17}$
10	2,42	0,242		

En la figura 7, se encuentra el diagrama de caja y bigote. Las letras representan las diferencias estadísticas, $p < 0,05$.




Figura 7. Diagrama de caja y bigote para cenizas.

- Extracto etéreo

En tabla 15 se puede observar que el contenido de extracto etéreo presentó diferencias significativas entre los tratamientos.

Tabla 15. Prueba de ANOVA +Tukey para extracto etéreo.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	D	7.517 ± 0.123	ANOVA + Tukey
T1	C	7.7 ± 0.05	ANOVA + Tukey
T2	B	8.167 ± 0.042	ANOVA + Tukey
T3	B	8.31 ± 0.026	ANOVA + Tukey
T4	A	8.51 ± 0.036	ANOVA + Tukey

En la tabla 16 mostró diferencias significativas entre los tratamientos, puesto que su valor p es menor a 0,05. Los tratamientos influyeron significativamente en el contenido de extracto etéreo.

Tabla 16. Prueba de ANOVA para extracto etéreo.

Df	Sum	Mean	Valor-F	Valor-p
4	2,09	0,52	122,16	$1,98 \times 10^{-8}$
10	0,04	0,04		

La figura 8, que presenta un diagrama de caja y bigote, se obtiene al comparar los tratamientos. Indica que existen diferencias importantes, las cuales son señaladas por letras distintas para cada grupo.




Figura 8. Diagrama de caja y bigote para extracto etéreo.

- Fibra

De acuerdo con la tabla 17, la prueba Kruskal-Wallis demostró que el contenido de fibra presente en las harinas tiene diferencias significativas, mientras que la prueba Dunn evidencia una tendencia de incremento permitiendo diferenciar el tratamiento con mayor sustitución frente al tratamiento testigo.

Tabla 17. Prueba de Kruskal-Wallis+ Dunn para fibra.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	11.377 ± 0.093	Kruskal-Wallis + Dunn
T1	AB	12.983 ± 0.161	Kruskal-Wallis + Dunn
T2	AB	14.383 ± 0.275	Kruskal-Wallis + Dunn
T3	AB	15.613 ± 0.11	Kruskal-Wallis + Dunn
T4	B	17.4 ± 0.7	Kruskal-Wallis + Dunn

En la tabla 18 se puede observar que si existen diferencias significativas en la variable de fibra entre los tratamientos evaluados entre al menos dos de los tratamientos.

Tabla 18. Prueba de Kruskal-Wallis para fibra.

Prueba	Chi cuadrado	Df	Valor-p
Kruskal-Wallis	13,5	4	0,009

La figura 9 muestra un diagrama de cajas y bigote en función a los tratamientos evaluados, las letras distintas (A, B) indican diferencias significativas con la prueba de Dunn ($p < 0,05$).




Figura 9. Diagrama de caja y bigote para fibra.

- Humedad

Como se muestra en la tabla 19 el contenido de humedad presentó diferencias entre los tratamientos evaluados. Los tratamientos T1, T2 y T3 comparten letras indicando que no presentan significativas con los grupos A ni B.

Tabla 19. Prueba de Kruskal-Wallis + Dunn para humedad.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	3.06 ± 0.01	Kruskal-Wallis + Dunn
T1	AB	3.57 ± 0.04	Kruskal-Wallis + Dunn
T2	AB	4.12 ± 0.01	Kruskal-Wallis + Dunn
T3	AB	4.48 ± 0.01	Kruskal-Wallis + Dunn
T4	B	4.88 ± 0.01	Kruskal-Wallis + Dunn

En la tabla 20 se evidencia diferentes significativas entre los tratamientos para humedad por su p valor menor.

Tabla 20. Prueba de Kruskal-Wallis para humedad.

Prueba	Chi cuadrado	Df	Valor-p
Kruskal-Wallis	13,5	4	0,009

En la figura 10 se puede observar que comparten la misma letra, pero no difieren estadísticamente entre sí y una tendencia creciente entre los tratamientos evaluados.




Figura 10. Diagrama de caja y bigote para humedad.

- Proteína

La tabla 21 muestra que el contenido de proteína presente en los tratamientos se observó diferencias significativas con letras diferentes indicando que la formulación utilizada tuvo influencia en esta variable.

Tabla 21. Prueba de ANOVA+Tukey para proteína.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	E	12.513 ± 0.015	ANOVA + Tukey
T1	D	19.867 ± 0.042	ANOVA + Tukey
T2	C	26.987 ± 0.057	ANOVA + Tukey
T3	B	30.387 ± 0.031	ANOVA + Tukey
T4	A	34.623 ± 0.025	ANOVA + Tukey

En la tabla 22 se evidencia que existen diferencias significativas, por lo tanto, se rechaza la hipótesis nula.

Tabla 22. Prueba ANOVA para proteína.

Df	Sum	Mean	Valor-F	Valor-p
4	923,2	230,8	170557	4,05x10 ⁻²⁴
10	0,0	0,0		

El diagrama de caja y bigote que se presenta en la figura 11 indica que existen diferencias significativas, las cuales están representadas por letras distintas ($p < 0,05$).




Figura 11. Diagrama de caja y bigote para proteína.

4.1.1.2. Caracterización textural de las galletas

- Dureza

En la tabla 23 se puede observar que la dureza de las galletas en los tratamientos obtuvo diferencias significativas donde el tratamiento T2 presentó mayor dureza y T4 menor fuerza.

Tabla 23. Prueba de ANOVA + Tukey para dureza.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	B	563.667 ± 41.861	ANOVA + Tukey
T1	B	544 ± 34.871	ANOVA + Tukey
T2	A	1506 ± 61.612	ANOVA + Tukey
T3	B	493.333 ± 32.393	ANOVA + Tukey
T4	C	249 ± 25.159	ANOVA + Tukey

Como se observa en la tabla 24 presenta diferencias altamente significativas entre los tratamientos para la variable dureza.

Tabla 24. Prueba de ANOVA para dureza.

Df	Sum	Mean	Valor-F	Valor-p
4	280357	700892	414,8	$4,60 \times 10^{-11}$
10	1689,3	1689,3		

La figura 12 muestra una distribución de los valores de dureza, al incrementar la harina modificó significativamente la propiedad textural de dureza en las galletas, se evidencio que el tratamiento T2 tiene un valor alto mientras que el tratamiento T4 un valor más bajo, siendo así que la sustitución parcial de amaranto por chocho influye en la estructura de las galletas.




Figura 12. Diagrama de caja y bigote para dureza.

- Fracturabilidad

En la tabla 25, se evidencia una pérdida de firmeza en el tratamiento T4 mientras que los otros tratamientos alcanzaron un valor alto.

Tabla 25. Prueba de ANOVA + Tukey para fracturabilidad.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	B	563.667 ± 41.861	ANOVA + Tukey
T1	B	544 ± 34.871	ANOVA + Tukey
T2	A	1506 ± 61.612	ANOVA + Tukey
T3	B	493.333 ± 32.393	ANOVA + Tukey
T4	C	249 ± 25.159	ANOVA + Tukey

Como se observa en la tabla 26 presenta diferencias altamente significativas entre los tratamientos para la variable fracturabilidad siendo similares a la tabla 24 de dureza.

Tabla 26. Prueba de ANOVA para fracturabilidad.

Df	Sum	Mean	Valor-F	Valor-p
4	280357	700892	414,8	4,60x10 ⁻¹¹
10	1689,3	1689,3		

En la figura 13 muestra una distribución de los valores de fracturabilidad, al incrementar la harina de *lupinus mutabilis* modificó significativamente la propiedad textural en las galletas, se evidencio que el tratamiento T2 tiene un valor alto mientras que el tratamiento T4 un valor más bajo, siendo así que la sustitución parcial de amaranto por chocho influye en la estructura de las galletas.




Figura 13. Diagrama de caja y bigote para fracturabilidad.

- Cohesividad

La tabla 27 presenta diferencias significativas en la variable de cohesividad donde el tratamiento T1 y T2 tiene la misma letra siendo así de valores similares.

Tabla 27. Prueba de ANOVA + Tukey para cohesividad.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	0.58 ± 0.036	ANOVA + Tukey
T1	B	0.483 ± 0.04	ANOVA + Tukey
T2	D	0.06 ± 0	ANOVA + Tukey
T3	C	0.393 ± 0.023	ANOVA + Tukey
T4	B	0.473 ± 0.015	ANOVA + Tukey

Como se observa en la tabla 28 demuestra que los tratamientos tienen un efecto significativo en la variable de cohesividad valor de p es menor a 0,05.

Tabla 28. Prueba de ANOVA para cohesividad.

Df	Sum	Mean	Valor-F	Valor-p
4	0,48104	0,12026	162,5	$4,72 \times 10^{-9}$
10	0,0074	0,00074		

En la figura 14 muestra la propiedad textural de cohesividad en las galletas, donde el tratamiento T0 tiene un valor alto y el T2 un valor bajo, indicando que la sustitución parcial de amaranto por chocho influye en esta característica.




Figura 14. Diagrama de caja y bigote para cohesividad.

- Masticabilidad

La tabla 29 muestra la variable de masticabilidad, donde se muestra valores significativos.

Tabla 29. Prueba de Kruskal-Wallis + Dunn para masticabilidad.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	8.333 ± 0.208	Kruskal-Wallis + Dunn
T1	AB	6.767 ± 1.106	Kruskal-Wallis + Dunn
T2	B	1.533 ± 0.058	Kruskal-Wallis + Dunn
T3	AB	4.867 ± 0.252	Kruskal-Wallis + Dunn
T4	AB	2.8 ± 0.173	Kruskal-Wallis + Dunn

En la tabla 30 se refleja los resultados de la variable de masticabilidad donde el valor de p es menor que 0,005. Esto indica que se rechaza la hipótesis nula.

Tabla 30. Prueba de Kruskal-Wallis para masticabilidad.

Prueba	Chi cuadrado	Df	Valor-p
Kruskal-Wallis	13,5	4	0,008

En la figura 15 se puede observar que presento los valores más altos el tratamiento T0 mientras que el tratamiento T2 obtuvo menor valor, lo que indica que la sustitución parcial en las formulaciones influye en las características texturales de las galletas.




Figura 15. Diagrama de caja y bigote para masticabilidad.

- Trabajo realizado

La tabla 31 muestra los valores de la variable de trabajo realizado para cada uno de los tratamientos con diferencias significativas ($p < 0,05$).

Tabla 31. Prueba Kruskal-Wallis + Dunn para trabajo realizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	AB	10.7 ± 1.127	Kruskal-Wallis + Dunn
T1	AB	12.1 ± 0.265	Kruskal-Wallis + Dunn
T2	A	24.167 ± 5.671	Kruskal-Wallis + Dunn
T3	AB	11.3 ± 0.4	Kruskal-Wallis + Dunn
T4	B	5.8 ± 0.2	Kruskal-Wallis + Dunn

En la tabla 32 se puede observar que el valor p es menor que ($p < 0,05$), se rechaza la hipótesis. Demostrando que las sustituciones de harinas si influyeron en esta variable.

Tabla 32. Prueba de Kruskal-Wallis para trabajo realizado.

Prueba	Chicadrado	Df	p-valor
Kruskal-Wallis	12,8	4	0,01

La figura 16 muestra un diagrama de caja y bigote, presento valores altos y bajos, demostrando así que la sustitución parcial de las formulaciones influye sobre el comportamiento físico y estructural del producto final.




Figura 16. Diagrama de caja y bigote para trabajo realizado.

4.1.1.3. Caracterización sensorial de las galletas

El análisis sensorial de las galletas se realizó mediante un panel de 61 catadores no entrenados, evaluando los atributos sensoriales, utilizando una escala hedónica de 6 puntos. Dada la naturaleza ordinal de los datos y el diseño con catadores como bloque, se aplicó la prueba no paramétrica de Friedman; cuando esta evidenció diferencias estadísticamente significativas, se realizó la comparación pareada mediante la prueba de Wilcoxon con ajuste de Bonferroni. A continuación, se presentan los resultados obtenidos para cada uno de los atributos evaluados en los tratamientos T0 a T4.

- Color

En la tabla 33 se observa que el tratamiento T0 obtuvo la calificación más baja (Q1: 4, Q3: 5) y se diferenció significativamente de T3, que alcanzó el valor más alto. Sin embargo, T1, T2 y T4 no mostraron diferencias claras frente a ninguno de los dos extremos, porque comparten letra con ambos. Llama la atención que T4, pese a tener la mayor proporción de chocho, no se ubicó junto a T3, lo que sugiere que el color no varía de forma proporcional al nivel de sustitución, sino que responde a otros factores

propios de cada formulación, como el tostado o el procesamiento previo de las harinas.

Tabla 33. Atributo de color en galleta.

Tratamiento	Q1	Q3	Letra
T0	4	5	A
T1	4	6	AB
T2	4	6	AB
T3	4	6	B
T4	4	6	AB

- Olor

En la tabla 34 se observa que este atributo no presentó diferencias significativas entre ningún tratamiento, porque todos comparten la misma letra. Los rangos de calificación se mantuvieron estrechos y consistentes (entre 3 y 6), lo cual indica que ni el amaranto ni el chocho aportan un aroma lo suficientemente marcado como para modificar la percepción del panel, incluso en el tratamiento con mayor sustitución.

Tabla 34. Atributo de Olor en galleta.

Tratamiento	Q1	Q3	Letra
T0	3	6	A
T1	4	5	A
T2	4	5	A
T3	4	6	A
T4	4	6	A

- Sabor

En la tabla 35 se observa que T0 se diferenció significativamente de T4, mientras que los tratamientos intermedios (T1, T2, T3) no se distinguieron de ninguno de los dos extremos. Esto sugiere que, a mayor proporción de chocho el sabor se va modificando de forma progresiva, probablemente por el aporte de compuestos propios de la leguminosa.

Tabla 35. Atributo de sabor en galleta.

Tratamiento	Q1	Q3	Letra
T0	4	6	A
T1	4	6	AB
T	4	6	AB
T3	4	6	AB
T4	4	6	B

- Crujencia

En la tabla 36 se observa que el tratamiento T2 presentó la calificación más baja y T4 la más alta, diferenciándose significativamente entre sí; no obstante, T0 y T1, que tienen menos o nada de chocho, quedaron en el grupo intermedio junto con T3. Esto rompe con la idea de un efecto lineal: la diferencia parece explicarse más por un comportamiento particular del tratamiento T2 que por un aumento gradual asociado a la sustitución.

Tabla 36. Atributo de crujeancia en galleta.

Tratamiento	Q1	Q3	Letra
T0	2	6	AB
T1	3	5	AB
T2	2	5	A
T3	3	6	AB
T4	4	6	B

- Textura quebradiza

Los resultados de la tabla 37 presentan un patrón más ordenado: T0 y T1 comparten los valores más bajos, T4 el más alto, y T2-T3 se ubican en un punto intermedio, siguiendo exactamente la secuencia de sustitución. Esto permite afirmar con mayor solidez que la fragilidad de la galleta aumenta conforme se incorpora más harina de chocho, posiblemente debido a su mayor contenido de fibra y menor capacidad de retención estructural frente al almidón del amaranto.

Tabla 37. Atributo de textura quebradiza en galleta.

Tratamiento	Q1	Q3	Letra
T0	3	5	A
T1	3	5	A
T2	3	6	AB
T3	4	6	AB
T4	4	6	B

- Dureza

Como se observa en la tabla 38, ningún tratamiento se diferenció de otro en este atributo, puesto que todos comparten letra. Este resultado es interesante porque contrasta con la dureza medida por el texturómetro, donde sí hubo diferencias marcadas entre tratamientos; en otras palabras, aunque instrumentalmente la galleta cambia de firmeza, el panel no logró percibir esa diferencia con la misma claridad.

Tabla 38. Atributo de dureza en galleta.

Tratamiento	Q1	Q3	Letra
T0	3	6	A
T1	3	5	A
T2	3	6	A
T3	3	6	A
T4	4	6	A


- Aceptabilidad

La tabla 39 confirma que todos los tratamientos se comportaron de manera equivalente, sin diferencias significativas entre ellos. Esto es un resultado favorable para la investigación, porque demuestra que, independientemente del nivel de sustitución evaluado, el producto se mantiene igual de aceptado por los consumidores.

Tabla 39. Atributo de aceptabilidad en galleta.

Tratamiento	Q1	Q3	Letra
T0	3	6	A
T1	4	6	A
T2	3	6	A
T3	3	6	A
T4	4	6	A

En la figura 17 con respecto a la aceptabilidad se puede observar que la adicción de harina de *lupinos mutabilis* no altera significativamente, los tratamientos obtuvieron respuestas similares.

**Figura 17.** Diagrama de caja y bigote para aceptabilidad.

En la figura 18 se observa la evaluación sensorial de sabor no muestra diferencias significativas. La incorporación de harina de *lupinos mutabilis* modifica la percepción de sabor siendo así que no solo influye en las propiedades instrumentales si no también en la del consumidor.




Figura 18. Diagrama de caja y bigote para sabor.

Se puede observar en la figura 19 la evaluación sensorial de crujencia no muestra diferencias significativas. La incorporación de harina de *lupinos mutabilis* modifica la percepción de sabor siendo así que no solo influye en las propiedades instrumentales si no también en la del consumidor.




Figura 19. Diagrama de caja y bigote para crujencia.

En la figura 20 se puede observar diferentes significativas entre los tratamientos para el atributo de textura quebradiza. La adición de harina de *lupinos mutabilis* altera la percepción de su textura al romperse, lo que significa que no solo afecta las propiedades instrumentales, sino también las del consumidor.




Figura 20. Diagrama de caja y bigote para textura quebradiza.

En la figura 21 para el atributo de dureza no muestra diferencias significativas, al momento de utilizar las sustituciones de la harina *lupinos mutabilis* no influye en los niveles de enriquecimiento del producto final manteniendo una percepción homogénea.




Figura 21. Diagrama de caja y bigote para dureza.

4.1.2. Desarrollo del modelo de optimización

4.1.2.1. Análisis multivariado: PCA, MFA y heatmap

Como se muestra en la tabla 40 y 41 en análisis de los componentes principales permitió explicar que el 88,6% se mide mediante dos componentes PC1 con el 64,5% y PC2 con el 24,1% el primero determina las propiedades fisicoquímicas y sensoriales, el segundo refleja análisis de textura, también se observa las dimensiones de las variables. Mientras que en la tabla 42 presenta las dimensiones de los tratamientos con valores altos y bajos.

Tabla 40. Análisis PCA

Componente	%Varianza	% Acumulado
Comp1	64,5	64,5
Comp2	24,1	88,6

Tabla 41. PCA de Variables

Dim.1	Dim.2	Dim.3	Dim.4	Variable
0,6063	0,9335	37,4035	34,1897	Acidez
7,0499	0,3390	0,9921	1,4909	Almidón
7,2431	0,1967	0,5471	0,0003	Carbohidratos totales
5,9627	0,2797	7,5152	7,2585	Cenizas
7,1419	0,3660	0,0595	1,6281	Extracto etéreo
7,3611	0,0186	0,0932	0,0357	Fibra
7,3049	0,0563	0,4150	0,1064	Humedad
7,1754	0,2873	0,8311	0,0060	Proteína
0,2540	18,7549	1,0413	0,0890	Dureza
0,2540	18,7549	1,0413	0,0890	Fracturabilidad
0,5342	18,3450	0,0015	0,0131	Cohesividad
4,3924	7,3027	1,8775	0,7111	Masticabilidad
0,3512	18,8351	0,0052	0,0076	Trabajo realizado
4,4514	1,2328	17,1300	7,5979	Color sensorial
6,3357	0,7855	1,5020	9,7872	Olor sensorial
5,9941	0,0584	0,6747	21,8843	Sabor sensorial
3,2460	7,7635	6,6901	7,6222	Crujencia sensorial
7,3381	0,0800	0,0991	0,0251	Textura quebradiza sensorial
6,2116	0,3939	7,7321	1,8593	Dureza sensorial
5,5771	0,7025	11,7995	2,5215	Aceptabilidad sensorial
5,2149	4,5136	2,5490	3,0772	Aroma

Tabla 42. PCA de tratamientos

Dim.1	Dim.2	Dim.3	Dim.4	Tratamiento
-5,1655	-1,5013	1,1577	0,7711	T0
-2,6841	-0,6265	-1,1304	-1,4363	T1
0,3436	4,3544	0,6200	-0,0253	T2
2,0851	-0,3409	-1,8711	1,0810	T3
5,4210	-1,8857	1,2238	-0,3906	T4

En las tablas 43 y 44 se encuentran las dimensiones por grupo y tratamiento tanto texturales, fisicoquímicas y sensoriales con valores bajos de menos de 1 hasta máximo de 2, esta aproximación permitió identificar la relación conjunta entre composición,

estructura instrumental y percepción sensorial, tabla 45 se encuentran todas las variables realizadas con sus dimensiones.

Tabla 43. MFA de grupos

Dim.1	Dim.2	Grupo
0,9673	0,0352	Fisicoquímicas
0,1869	0,9937	Texturales
0,9762	0,0747	Sensoriales

Tabla 44. MFA de tratamientos

Dim.1	Dim.2	Tratamiento
-1,9835	-0,8190	T0
-0,9985	-0,3341	T1
-0,0900	2,0425	T2
0,8309	-0,1552	T3
2,2410	-0,7342	T4

Tabla 45. MFA de variables

Dim.1	Dim.2	Variable
-0,3055	0,1743	Acidez
-0,9631	-0,2040	Almidón
-0,9799	-0,1763	Carbohidratos totales
-0,8904	-0,1892	Cenizas
0,9687	0,2107	Extracto etéreo
0,9982	0,0480	Fibra
0,9874	0,1301	Humedad
0,9738	0,1965	Proteína
-0,2627	0,9571	Dureza
-0,2627	0,9571	Fracturabilidad
-0,1919	-0,9808	Cohesividad
-0,7211	-0,6701	Masticabilidad
-0,2946	0,9551	Trabajo realizado
0,7985	-0,1900	Color sensorial
0,9369	-0,1326	Olor sensorial
0,8989	0,1314	Sabor sensorial
0,7067	-0,5722	Crujencia sensorial
0,9989	0,0161	Textura quebradiza sensorial
0,9229	-0,0658	Dureza sensorial
0,8782	-0,1160	Aceptabilidad sensorial

En la figura 22 se puede observar la relación entre los diferentes tratamientos separándose según sus propiedades fisicoquímicas, texturales y sensoriales.




Figura 22. Biplot tratamientos y variables.

En la figura 23 se puede observar una correlación positiva entres los bloques evaluados como carbohidratos y almidón también parámetros fisicoquímicos como dureza y fracturabilidad.




Figura 23. Matriz de correlación.

En la figura 24 muestra el análisis multifactorial donde permitió estructurar las variables evaluadas según su naturaleza fisicoquímica, textural y sensorial.




Figura 24. Círculo de correlación de variables.

En la figura 25 se detalla la contribución de bloques para cuantificar el peso e influencia de los grupos sobre la variabilidad total explicada por el modelo multivariado.




Figura 25. Contribución de bloques.

4.1.2.2. Modelo PLS y selección de variables

El análisis mediante la regresión de mínimos cuadrados parciales (PLS) se aplicó con el objetivo de identificar las variables fisicoquímicas con mayor capacidad

expectativa sobre las propiedades texturales. La selección del número óptimo de componentes se realizó mediante la validación cruzada, minimizando el error cuadrático medio de predicción (RMSECV).

- Métricas de desempeño del modelo PLS

El desempeño del modelo predictivo PLS fue evaluado a partir de tres indicadores estadísticos fundamentales: el coeficiente de determinación (R^2), la raíz del error cuadrático medio (RMSE) y el error absoluto medio (MAE). En las tablas 46 y 47 se presentan los resultados obtenidos para cada variable respuesta evaluada.

Tabla 46. Métricas de desempeño del modelo PLS para atributos texturales instrumentales.

Variable respuesta	RMSE	MAE	R^2
Dureza	426,2635	338,2950	0,0278
Fracturabilidad	426,2635	338,2950	0,0278
Cohesividad	0,1721	0,1322	0,0760
Masticabilidad	1,5217	1,2111	0,6266
Trabajo realizado	5,9580	4,6174	0,0424

El modelo PLS mostró una capacidad predictiva limitada para los atributos texturales instrumentales. Las variables dureza, fracturabilidad, cohesividad y trabajo realizado presentaron valores de R^2 inferiores a 0,08, evidenciando que las relaciones entre la formulación y la respuesta mecánica del producto son de naturaleza no lineal y no pueden ser capturadas por un modelo lineal multivariante. Únicamente la masticabilidad alcanzó un R^2 de 0,6266, reflejando un ajuste moderado. Por esta razón, se procedió al uso de un modelo de red neuronal profunda con mayor capacidad de generalización.

En la siguiente tabla se observa las métricas de desempeño del modelo PLS para los atributos sensoriales.

Tabla 47. Métricas de desempeño del modelo PLS para atributos sensoriales.

Variable respuesta	RMSE	MAE	R^2
Color	0,1446	0,1367	0,5807
Olor	0,0596	0,0502	0,7527
Sabor	0,0974	0,0728	0,8821
Crujencia	0,1770	0,1587	0,4079
Textura quebradiza	0,0453	0,0403	0,9803
Dureza	0,0713	0,0617	0,8348
Aceptabilidad	0,0651	0,0587	0,7542

A diferencia de los parámetros texturales instrumentales, el modelo PLS mostró una capacidad predictiva aceptable para los atributos sensoriales. La variable textura

quebradiza presentó el mejor ajuste con $R^2 = 0,9803$, lo que indica que el modelo explica casi la totalidad de su variabilidad a partir de los predictores fisicoquímicos seleccionados. Los atributos sabor ($R^2 = 0,8821$), dureza ($R^2 = 0,8348$), olor ($R^2 = 0,7527$) y aceptabilidad ($R^2 = 0,7542$) alcanzaron valores superiores a 0,70, evidenciando un ajuste satisfactorio. Por su parte, el color ($R^2 = 0,581$) y crujencia ($R^2 = 0,4079$) presentaron ajustes moderados, lo que sugiere que parte de su variabilidad no queda explicada por la composición fisicoquímica únicamente. En todos los casos los valores de RMSE y MAE resultaron bajos, confirmando que los errores de predicción son limitados y estadísticamente aceptables para datos de naturaleza ordinal.

- Selección de variables relevantes mediante VIP

La importancia de cada variable fisicoquímica como predictora fue cuantificada a través del índice VIP. Se estableció un umbral $VIP \geq 1$ como criterio de relevancia, debido a que influyen de manera significativa en la predicción de variables respuesta.

En la Tabla 48 se presentan los valores VIP obtenidos para cada predictor

Tabla 48. Valores VIP de variables fisicoquímicas en el modelo PLS.

Variable predictora	VIP	Selección
Fibra	1,7000	Variable importante
Acidez	1,3775	Variable importante
Humedad	1,0973	Variable importante
Cenizas	0,7871	Menor contribución
Carbohidratos totales	0,7610	Menor contribución
Proteína	0,6217	Menor contribución
Almidón	0,5181	Menor contribución
Extracto etéreo	0,3932	Menor contribución

El análisis de importancia de variables mediante el índice VIP identificó que solo tres variables superaron el umbral $VIP \geq 1$: fibra (1,700), acidez (1,3775) y humedad (1,0973). Su relevancia se explica porque la incorporación de harina de *Lupinus mutabilis* modifica directamente estos parámetros, los cuales determinan la estructura de la miga y la percepción sensorial del producto. Las cinco variables restantes presentaron VIP inferior a la unidad y fueron excluidas como predictoras principales del modelo.

A continuación, en la figura 26 presenta valores VIP de cada propiedad fisicoquímica evaluada al modelo PLS.




Figura 26. Importancia de variables predictoras según VIP.

Como se observa en la Figura 26 únicamente fibra, acidez y humedad superan el umbral de relevancia ($VIP = 1$), siendo la fibra la variable de mayor contribución al modelo ($VIP = 1,700$), seguida de la acidez ($VIP = 1,378$) y la humedad ($VIP = 1,097$). Las cinco variables restantes no alcanzaron dicho umbral, por lo que fueron excluidas como predictoras principales. Este resultado es coherente con la formulación evaluada, dado que la incorporación de harina de *Lupinus mutabilis* modifica directamente el contenido de fibra y acidez del producto, parámetros que condicionan tanto su estructura mecánica como su percepción sensorial.

4.1.2.3. Red neuronal predictiva

Dado que el modelo PLS presentó limitaciones en la predicción de las variables texturales instrumentales, se diseñó e implementó un modelo de red neuronal profunda; a diferencia del enfoque lineal anterior, este modelo permitió estimar con mayor exactitud la complejidad de las interacciones entre el porcentaje de sustitución con harina de *Lupinus mutabilis* y las respuestas del producto. Para ello, el modelo fue entrenado, validado y evaluado en el entorno de programación R, utilizando los registros experimentales obtenidos para los diferentes tratamientos formulados.

- Métricas de desempeño del modelo neuronal

El ajuste del modelo neuronal fue evaluado mediante los mismos indicadores estadísticos empleados en el PLS: R^2 , RMSE y MAE.

En la Tabla 48 se presenta los resultados para la totalidad de las variables respuesta evaluadas, tanto texturales instrumentales como sensoriales.

Tabla 49. Métricas de desempeño del modelo de red neuronal para las variables texturales instrumentales.

Variable	RMSE	MAE	R^2
Dureza	42,9406	33,5517	0,9908
Fracturabilidad	42,1709	32,6200	0,9911
Cohesividad	0,0238	0,0195	0,9833
Masticabilidad	0,4514	0,2983	0,9687
Trabajo realizado	2,1407	1,1340	0,8902

Los resultados demuestran que el modelo de red neuronal superó ampliamente al PLS en la predicción de los atributos texturales instrumentales. En las variables de dureza y fracturabilidad, que en el modelo PLS presentaban $R^2 \approx 0,028$, alcanzaron valores de R^2 de 0,9908 y 0,9911 respectivamente, evidenciando que la red neuronal capturó con precisión las relaciones no lineales entre el porcentaje de sustitución con harina de *Lupinus mutabilis* y la respuesta mecánica del producto. De manera similar, cohesividad ($R^2 = 0,9833$) y masticabilidad ($R^2 = 0,9687$) presentaron coeficientes de determinación muy elevados con errores absolutos medios reducidos. El trabajo realizado, con $R^2 = 0,8902$, constituyó la única variable con un ajuste ligeramente inferior, aunque estadísticamente aceptable. La proximidad entre los valores observados y predichos en los gráficos correspondientes confirma la ausencia de sesgo sistemático en el modelo para este grupo de variables.

De manera complementaria, en la tabla 50 se presenta las métricas de desempeño del modelo neuronal para los atributos sensoriales.

Tabla 50. Métricas de desempeño del modelo de red neuronal para los atributos sensoriales.

Variable	RMSE	MAE	R^2
Color	0,0172	0,0169	0,9951
Olor	0,0075	0,0072	0,9961
Sabor	0,0122	0,0110	0,9986
Crujencia	0,0057	0,0048	0,9996
Textura quebradiza	0,0326	0,0285	0,9898
Dureza	0,0136	0,0128	0,9943
Aceptabilidad	0,0104	0,0097	0,9942

En cuanto a los atributos sensoriales, los resultados fueron igualmente destacados. La crujencia sensorial alcanzó el mejor ajuste del modelo en su conjunto ($R^2 = 0,9996$), seguida del sabor ($R^2 = 0,9986$), el olor ($R^2 = 0,9961$), el color ($R^2 = 0,9951$), la dureza sensorial ($R^2 = 0,9943$) y la aceptabilidad sensorial ($R^2 = 0,9942$). La textura quebradiza, con $R^2 = 0,9898$, mantuvo igualmente un ajuste excelente. Estos resultados son especialmente relevantes dado el carácter subjetivo y ordinal de las evaluaciones sensoriales, y demuestran que la red neuronal reprodujo con alta fidelidad la percepción del panel de degustación en función de la formulación evaluada.

- Comparación de valores observados y predichos en atributos texturales

La validación del modelo se realizó comparando directamente los valores experimentales con los estimados por la red neuronal para cada tratamiento y variable respuesta. Cuando los valores predichos se aproximan a los observados, se confirma que el modelo aprendió correctamente la tendencia de los datos dentro del rango experimental evaluado. Los resultados se presentan a continuación de forma diferenciada para los atributos texturales instrumentales.

En la Tabla 51 se presentan los valores observados y en la Tabla 52 los valores predichos por la red neuronal en los atributos texturales instrumentales.

Tabla 51. Valores observados de los atributos texturales instrumentales por tratamiento.

Tratamiento	Lupinus	Dureza	Fracturabilidad	Cohesividad	Masticabilidad	Trabajo realizado
T0	0	540	540	0,59	8,1	11,3
T0	0	539	539	0,61	8,5	9,4
T0	0	612	612	0,54	8,4	11,4
T1	10	504	504	0,44	5,6	12,2
T1	10	560	560	0,52	7,8	12,3
T1	10	568	568	0,49	6,9	11,8
T2	20	1562	1562	0,06	1,6	18,8
T2	20	1516	1516	0,06	1,5	23,6
T2	20	1440	1440	0,06	1,5	30,1
T3	30	514	514	0,38	4,6	11,3
T3	30	510	510	0,38	5,1	10,9
T3	30	456	456	0,42	4,9	11,7
T4	40	220	220	0,49	2,9	5,6
T4	40	262	262	0,46	2,6	5,8
T4	40	265	265	0,47	2,9	6

Tabla 52.Valores predichos de los atributos texturales instrumentales por tratamiento.

Tratamiento	Lupinus	Dureza	Fracturabilidad	Cohesividad	Masticabilidad	Trabajo realizado
T0	0	544,1627	543,0428	0,5825	8,4047	10,4890
T0	0	544,1627	543,0428	0,5825	8,4047	10,4890
T0	0	544,1627	543,0428	0,5825	8,4047	10,4890
T1	10	577,7054	578,7454	0,4737	6,6119	12,5159
T1	10	577,7054	578,7454	0,4737	6,6119	12,5159
T1	10	577,7054	578,7454	0,4737	6,6119	12,5159
T2	20	1474,9409	1477,9184	0,0729	1,7001	23,7619
T2	20	1474,9409	1477,9184	0,0729	1,7001	23,7619
T2	20	1474,9409	1477,9184	0,0729	1,7001	23,7619
T3	30	522,8729	519,4896	0,3835	4,6681	11,5443
T3	30	522,8729	519,4896	0,3835	4,6681	11,5443
T3	30	522,8729	519,4896	0,3835	4,6681	11,5443
T4	40	233,6813	236,5302	0,4760	2,9163	5,7544
T4	40	233,6813	236,5302	0,4760	2,9163	5,7544
T4	40	233,6813	236,5302	0,4760	2,9163	5,7544

La comparación entre los valores observados y predichos evidencia una elevada concordancia en todos los tratamientos. El tratamiento T2 (20 % de *Lupinus mutabilis*) presentó los valores más extremos del experimento, con dureza observada entre 1440 y 1562 g frente a un predicho de 1474,94 g, siendo además el trabajo realizado la variable con mayor dispersión entre réplicas (18,8; 23,6; 30,1) frente a un predicho de 23,76. Los tratamientos T0, T1, T3 y T4 mostraron una proximidad estrecha entre valores observados y predichos en todas las variables, sin evidencia de sesgo sistemático, lo que confirma que el modelo estimó correctamente el comportamiento textural instrumental en función del porcentaje de sustitución.

- **Comparación de valores observados y predichos en atributos sensoriales**

La validación del modelo se realizó comparando directamente los valores experimentales con los estimados por la red neuronal para cada tratamiento y variable respuesta. Los resultados se presentan a continuación de forma diferenciada para los atributos sensoriales.

Tabla 53. Valores observados de los atributos sensoriales por tratamiento.

Tratamiento	Lupinus	Color	Olor	Sabor	Crujencia	Textura quebradiza	Dureza	Aceptabilidad
T0	0	4,3443	4,4098	4,3279	4,1803	4,0164	4,2623	4,4262
T0	0	4,3443	4,4098	4,3279	4,1803	4,0164	4,2623	4,4262
T0	0	4,3443	4,4098	4,3279	4,1803	4,0164	4,2623	4,4262
T1	10	4,7869	4,4262	4,8525	3,9508	4,2131	4,1967	4,3443
T1	10	4,7869	4,4262	4,8525	3,9508	4,2131	4,1967	4,3443
T1	10	4,7869	4,4262	4,8525	3,9508	4,2131	4,1967	4,3443
T2	20	4,5574	4,4918	4,8689	3,9508	4,4426	4,3934	4,4918
T2	20	4,5574	4,4918	4,8689	3,9508	4,4426	4,3934	4,4918
T2	20	4,5574	4,4918	4,8689	3,9508	4,4426	4,3934	4,4918
T3	30	4,9180	4,6721	4,8689	4,2459	4,6066	4,4262	4,5082
T3	30	4,9180	4,6721	4,8689	4,2459	4,6066	4,4262	4,5082
T3	30	4,9180	4,6721	4,8689	4,2459	4,6066	4,4262	4,5082
T4	40	4,9180	4,6885	5,2131	4,5738	4,9508	4,7049	4,7377
T4	40	4,9180	4,6885	5,2131	4,5738	4,9508	4,7049	4,7377
T4	40	4,9180	4,6885	5,2131	4,5738	4,9508	4,7049	4,7377

Tabla 54. Valores predichos de los atributos sensoriales por tratamiento.

Tratamiento	Lupinus	Color	Olor	Sabor	Crujencia	Textura quebradiza	Dureza	Aceptabilidad
T0	0	4,3560	4,4138	4,3386	4,1729	4,0304	4,2555	4,4208
T0	0	4,3560	4,4138	4,3386	4,1729	4,0304	4,2555	4,4208
T0	0	4,3560	4,4138	4,3386	4,1729	4,0304	4,2555	4,4208
T1	10	4,7674	4,4197	4,8356	3,9596	4,2007	4,2099	4,3545
T1	10	4,7674	4,4197	4,8356	3,9596	4,2007	4,2099	4,3545
T1	10	4,7674	4,4197	4,8356	3,9596	4,2007	4,2099	4,3545
T2	20	4,5729	4,4991	4,8704	3,9515	4,4128	4,3762	4,4789
T2	20	4,5729	4,4991	4,8704	3,9515	4,4128	4,3762	4,4789
T2	20	4,5729	4,4991	4,8704	3,9515	4,4128	4,3762	4,4789
T3	30	4,8965	4,6609	4,8837	4,2485	4,6631	4,4449	4,5225
T3	30	4,8965	4,6609	4,8837	4,2485	4,6631	4,4449	4,5225
T3	30	4,8965	4,6609	4,8837	4,2485	4,6631	4,4449	4,5225
T4	40	4,9341	4,6953	5,2023	4,5691	4,9213	4,6970	4,7319
T4	40	4,9341	4,6953	5,2023	4,5691	4,9213	4,6970	4,7319
T4	40	4,9341	4,6953	5,2023	4,5691	4,9213	4,6970	4,7319

En los atributos sensoriales, la concordancia entre valores observados y predichos fue alta en todos los tratamientos, con diferencias mínimas ($\leq 0,03$ puntos). El sabor sensorial mostró una tendencia creciente desde T0 (4,3279 observado) hasta T4 (5,2131 observado), reproducida con precisión por el modelo (4,3386 y 5,2023 respectivamente), confirmando que la red neuronal capturó con alta precisión la percepción sensorial del panel de degustación en función del porcentaje de sustitución con harina de *Lupinus mutabilis*.

En la Figura 27 presenta el gráfico de dispersión observado vs. predicho para la dureza instrumental.




Figura 27. Observado vs predicho: dureza.

Como se observa en la figura, los puntos se distribuyen a lo largo de la línea diagonal en todo el rango evaluado, desde valores cercanos a 220 g hasta valores superiores a 1500 g. La alineación de los puntos sobre la diagonal confirma que el modelo estimó con precisión la dureza en todos los tratamientos, sin evidencia de sesgo sistemático.

En la Figura 28 muestra el gráfico de dispersión observado vs. predicho para la fracturabilidad.




Figura 28. Observado vs predicho: fracturabilidad.

El comportamiento observado es prácticamente idéntico al de la dureza, lo cual es coherente dado que ambas variables presentaron valores similares en las tablas de observados y predichos. Los puntos siguen la diagonal de manera consistente en todo el rango, evidenciando que el modelo capturó adecuadamente la respuesta de esta variable ante los diferentes niveles de sustitución.

La Figura 29 presenta el gráfico de dispersión observado vs. predicho para la masticabilidad.




Figura 29. Observado vs predicho: masticabilidad.

A diferencia de dureza y fracturabilidad, los puntos presentan una dispersión ligeramente mayor respecto a la diagonal, particularmente en los valores intermedios del rango evaluado. No obstante, la tendencia general sigue la línea de referencia, lo que indica que el modelo estimó correctamente la dirección del cambio en la masticabilidad en función del porcentaje de sustitución. Esta dispersión es consistente con el R^2 de 0,9687 reportado para esta variable.

La Figura 30 presenta el gráfico de dispersión observado vs. predicho para el sabor sensorial.




Figura 30. Observado vs predicho: sabor sensorial.

Los puntos se distribuyen muy próximos a la diagonal en todo el rango evaluado (aproximadamente 4,33 a 5,21), con una dispersión mínima. Este comportamiento refleja que el modelo reprodujo con alta precisión la progresión del sabor conforme aumenta el porcentaje de sustitución con harina de *Lupinus mutabilis*, resultado coherente con el R^2 de 0,9986 obtenido para esta variable.

La Figura 31 presenta el gráfico de dispersión observado vs. predicho para la crujencia sensorial.




Figura 31. Observado vs predicho: crujencia sensorial.

De todas las figuras presentadas, esta es la que muestra la mayor proximidad entre valores observados y predichos. Los puntos se superponen prácticamente sobre la diagonal a lo largo de todo el rango (3,96 a 4,57), sin ninguna desviación visible. Este resultado es consistente con el R^2 de 0,9996, el valor más alto obtenido en el modelo neuronal, lo que confirma que la crujencia sensorial fue la variable mejor predicha por la red neuronal.

La Figura 32 presenta el gráfico de dispersión observado vs. predicho para la aceptabilidad sensorial.




Figura 32. Observado vs predicho: aceptabilidad sensorial.

Los puntos siguen la diagonal de forma consistente dentro del rango evaluado (4,36 a 4,74), aunque con una dispersión ligeramente mayor que la observada en crujencia y sabor. Esta variabilidad residual es esperable dado el carácter subjetivo de la aceptabilidad global, que integra la percepción conjunta de múltiples atributos. En todo caso, la tendencia general es correctamente estimada por el modelo, lo que valida su capacidad predictiva para esta variable.

Una vez validado el modelo de red neuronal, se procedió a realizar la optimización multicriterio de la formulación mediante la función de deseabilidad global. Esta estrategia permite identificar, dentro del espacio experimental evaluado (0–40 % de sustitución con harina de *Lupinus mutabilis*, el punto de formulación que maximiza simultáneamente el conjunto de respuestas sensoriales, texturales e instrumentales de interés, sin priorizar ninguna variable sobre las demás.

La curva de deseabilidad global en función del porcentaje continuo de sustitución exhibe un máximo claramente definido dentro del rango evaluado. Según el análisis, la máxima deseabilidad global se alcanza con un 16,81 % de harina de *Lupinus mutabilis* y un 83,19 % de harina de amaranto. A mayor o menor porcentaje de sustitución respecto a este punto, la deseabilidad global disminuye, lo que indica que formulaciones con proporciones extremas comprometen el equilibrio entre los distintos atributos del producto.




Figura 33. Curva de deseabilidad global continua en función del porcentaje de sustitución con harina de *Lupinus mutabilis*.

La figura muestra la función de deseabilidad global en función del porcentaje continuo de sustitución con harina de *Lupinus mutabilis* dentro del rango experimental evaluado (0–40%). La curva presenta un máximo en el 16,81% de sustitución, valor indicado por la línea punteada vertical. Este punto representa la formulación que mejor equilibra las propiedades texturales, instrumentales y sensoriales evaluadas. El valor de deseabilidad alcanzado (0,163) refleja la dificultad inherente de optimizar simultáneamente múltiples respuestas con comportamientos heterogéneos, sin que esto indique deficiencia del modelo.

Tabla 55. Formulación óptima continúa estimada mediante función de deseabilidad global.

Lupinus	Amaranto	Deseabilidad global	Valores predichos
16,8141282	83,18587175	0,16318645	83,19

Como se observa en la tabla 55, la optimización multicriterio mediante función de deseabilidad global permitió identificar una formulación óptima continua dentro del rango experimental evaluado. El modelo estimó que la máxima deseabilidad se alcanza con 16,81 % de harina de *Lupinus mutabilis* y 83,19 % de harina de amaranto. Esta formulación representa el mejor equilibrio predictivo entre aceptabilidad sensorial, sabor, crujencia, textura quebradiza, color, olor, cohesividad, dureza instrumental y fracturabilidad.

En conclusión, los análisis estadísticos, multivariados y predictivos realizados en este estudio demostraron que la sustitución parcial de harina de amaranto por harina de *Lupinus mutabilis* modifica de manera significativa la composición fisicoquímica, la textura instrumental y la percepción sensorial de las galletas sin gluten enriquecidas con nanopartículas de carbonato de calcio. Esta evidencia, obtenida de forma sistemática a través de metodologías complementarias, permite establecer una visión integral del comportamiento del producto en función del nivel de sustitución formulado.

4.1.3. Validación del modelo optimizado

4.1.3.1. Caracterización fisicoquímica de las harinas

- Acidez

En la tabla 56 la prueba de Kruskal-Wallis demuestra diferencias significativas entre los tratamientos para la variable de acidez ($p < 0,005$). Mientras que para la prueba de comparación múltiple de Duun se pudo observar que el tratamiento optimizado (T5) presento mayor acidez y T2 menor valor.

Tabla 56. Prueba de Kruskal-Wallis + Dunn para acidez en el tratamiento optimizado

Tratamiento	Letra	Resultado	Prueba aplicada
T0	AB	0.14 ± 0.00	Kruskal-Wallis + Dunn
T1	AB	0.14 ± 0.00	Kruskal-Wallis + Dunn
T2	A	0.13 ± 0.00	Kruskal-Wallis + Dunn
T3	AB	0.14 ± 0.00	Kruskal-Wallis + Dunn
T4	AB	0.14 ± 0.00	Kruskal-Wallis + Dunn
T5	B	0.15 ± 0.00	Kruskal-Wallis + Dunn

En la figura 34 se evidencia diferencias significativas entre los tratamientos con la prueba de Kruskal-Wallis en comparación de Dunn. El tratamiento T2 identificado con la letra (a) presenta menor acidez mientras que el tratamiento optimizado T5 con la letra (b) registra mayor acidez. Los tratamientos T0, T1, T3 y T4 identificadas con las letras (ab) presentaron valores intermedios y no difieren significativamente.




Figura 34. Diagrama y caja de bigote de acidez- tratamiento optimizado.

- Almidón

En la tabla de 57 se muestra diferencias significativas entre los tratamientos (Kruskal-Wallis) donde el tratamiento T0 presenta mayor valor seguido de T1, mientras que T5 registra menor valor. La prueba de Kruskal-Wallis + Dunn indica diferencias entre los tratamientos observando una disminución en el contenido de almidón conforme cambia la formulación.

Tabla 57. Prueba de Kruskal-Wallis + Dunn para almidón en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba aplicada
T0	A	171.33 ± 15.47	Kruskal-Wallis + Dunn
T1	A	159.90 ± 0.80	Kruskal-Wallis + Dunn
T2	AB	138.19 ± 1.61	Kruskal-Wallis + Dunn
T3	AB	131.02 ± 4.24	Kruskal-Wallis + Dunn
T4	AB	123.23 ± 2.10	Kruskal-Wallis + Dunn
T5	B	80.70 ± 0.20	Kruskal-Wallis + Dunn

En la figura 35 se puede observar que el contenido de almidón disminuye desde el tratamiento T0 hasta T5. Los tratamientos T0 y T1 identificados con la letra (a) presentan valores altos, los otros tratamientos identificados con las letras (ab) se

registran con valores intermedios no demuestran diferencias significativas mientras que T5 con la letra (b) tiene menor valor de almidón.




Figura 35. Diagrama y caja de bigote de almidón- tratamiento optimizado.

- Carbohidratos

En la tabla de 58 se muestra diferencias significativas entre los tratamientos (ANOVA-Tukey) donde el tratamiento T0 presento mayor valor, mientras que T3 registro menor valor, los tratamientos T1, T2, T4 y T5 presentan valores intermedios, demostrando que la formulación influye significativamente en la variable de carbohidratos.

Tabla 58. Prueba de ANOVA + Tukey para carbohidratos totales en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	65.45 ± 0.32	ANOVA + Tukey
T1	C	56.25 ± 0.25	ANOVA + Tukey
T2	D	46.17 ± 0.33	ANOVA + Tukey
T3	E	41.05 ± 0.72	ANOVA + Tukey
T4	F	35.04 ± 0.44	ANOVA + Tukey
T5	B	63.45 ± 0.10	ANOVA + Tukey

En la figura 36 se observa el análisis de ANOVA+Tukey aplicado a la variable de carbohidratos totales se muestra diferencias significativas entre los tratamientos ($p < 0,05$). El tratamiento T0 con la letra (a) presenta un valor alto seguido de los tratamientos T1, T2, T3, T5, mientras que el tratamiento T4 con letra (f) registro un valor bajo.




Figura 36. Diagrama y caja de bigote de carbohidratos totales- tratamiento optimizado.

- Cenizas

La tabla 59 evidencia que existe diferencias significativas entre los tratamientos ($p < 0,05$). El tratamiento T0 registro el mayor contenido en cenizas mientras que el tratamiento T4 obtuvo menor valor. Mediante la prueba ANOVA+Tukey indican que la composición de las formulaciones modifica significativamente el contenido de esta variable.

Tabla 59. Prueba de ANOVA+Tukey para ceniza en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	3.77 ± 0.02	ANOVA + Tukey
T1	B	2.39 ± 0.08	ANOVA + Tukey
T2	B	2.30 ± 0.03	ANOVA + Tukey
T3	C	1.89 ± 0.03	ANOVA + Tukey
T4	D	1.68 ± 0.02	ANOVA + Tukey
T5	B	2.31 ± 0.01	ANOVA + Tukey

En la figura 37 se muestra el análisis de ANOVA+Tukey donde el tratamiento T0 con letra (a) presenta mayor contenido, los tratamientos T1, T2 y T5 comparten la letra (b) manteniendo valores intermedios, mientras que los tratamientos T4 con letra (d) y T3 (c) registraron menor contenido.




Figura 37. Diagrama y caja de bigote de cenizas -tratamiento optimizado.

- Extracto etéreo

La tabla 60 presenta que existe diferencias significativas entre los tratamientos evaluados aplicando la prueba de ANOVA+Tukey, donde los tratamientos T2, T3 y T4 mantienen valores similares, mientras que los tratamientos T0, T1 y T5 registraron valores bajos.

Tabla 60. Prueba ANOVA+Tukey para extracto etéreo en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	B	7.59 ± 0.27	ANOVA + Tukey
T1	B	7.69 ± 0.19	ANOVA + Tukey
T2	A	8.18 ± 0.03	ANOVA + Tukey
T3	A	8.30 ± 0.03	ANOVA + Tukey
T4	A	8.61 ± 0.17	ANOVA + Tukey
T5	B	7.61 ± 0.10	ANOVA + Tukey

En la figura 38 se observa diferencias significativas con el análisis de ANOVA y la prueba de comparación de Tukey, los tratamientos T2, T3 y T4 comparten la letra (a) con valores similares, mientras que los tratamientos T1, T0 y T5 con la letra (b) comparten el grupo con menor contenido de esta variable.




Figura 38. Diagrama y caja de bigote de extracto etéreo- tratamiento optimizado.

- Fibra

En la tabla 61 se muestra el contenido de fibra con diferencias significativas entre los tratamientos evaluados, la prueba de Kruskal-Wallis y Dunn observo un incremento de esta variable en los tratamientos con mayor incorporación indicando un buen aporte de fibra.

Tabla 61. Prueba de Kruskal-Wallis + Dunn para fibra en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	11.42 ± 0.14	Kruskal-Wallis + Dunn
T1	AB	12.75 ± 0.20	Kruskal-Wallis + Dunn
T2	AB	14.63 ± 0.30	Kruskal-Wallis + Dunn
T3	AB	15.80 ± 0.74	Kruskal-Wallis + Dunn
T4	B	17.11 ± 0.64	Kruskal-Wallis + Dunn
T5	AB	12.14 ± 0.01	Kruskal-Wallis + Dunn

En la figura 39 se puede observar que el tratamiento T4 con la letra (b) muestra mayor contenido de fibra diferenciándose significativamente del tratamiento T0 con letra (a) con un valor bajo, mientras que los tratamientos T1, T2, T3 y T5 comparten la misma letra (ab) no presentan diferencias significativas.




Figura 39. Diagrama y caja de bigote de fibra- tratamiento optimizado.

- Humedad

En la tabla 62 se puede observar que los tratamientos evaluados tienen diferencias significativas (ANOVA+Tukey) cada uno de ellos permaneciendo dentro de rangos adecuados para harinas.

Tabla 62. Prueba de ANOVA+Tukey para humedad en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	F	3.06 ± 0.01	ANOVA + Tukey
T1	E	3.61 ± 0.03	ANOVA + Tukey
T2	C	4.12 ± 0.02	ANOVA + Tukey
T3	B	4.49 ± 0.01	ANOVA + Tukey
T4	A	4.88 ± 0.01	ANOVA + Tukey
T5	D	3.97 ± 0.01	ANOVA + Tukey

En la figura 40 se observa diferencias significativas entre los tratamientos, el T4 con la letra (a) obtuvo valor alto mientras que los demás tratamientos registraron valores casi similares y el T0 con letra (f) valor bajo en contenido ($p<0,05$).




Figura 40. Diagrama y caja de bigote de humedad -tratamiento optimizado.

- Proteína

En la tabla 63 se muestra que el contenido de proteína tiene diferencias significativas entre los tratamientos evaluados (ANOVA+Tukey).

Tabla 63. Prueba de ANOVA+Tukey para proteína en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	F	12.51 ± 0.03	ANOVA + Tukey
T1	D	19.82 ± 0.05	ANOVA + Tukey
T2	C	26.99 ± 0.04	ANOVA + Tukey
T3	B	30.37 ± 0.04	ANOVA + Tukey
T4	A	34.64 ± 0.01	ANOVA + Tukey
T5	E	12.83 ± 0.01	ANOVA + Tukey

En la figura 41 se presenta diferencias significativas, el tratamiento T4 con letra (a) muestra valor alto, mientras que el T0 con letra (f) y T5 con letra (e) tiene menor valor de contenido proteico.




Figura 41. Diagrama y caja de bigote de proteína- tratamiento optimizado.

4.1.3.1. Caracterización textural de las galletas

- Dureza

En la tabla 64 se muestra el análisis de ANOVA+Tukey donde el tratamiento T2 presenta mayor dureza, mientras que los demás tratamientos mantienen valores intermedios, los tratamientos T4 y T5 registraron un valor menor.

Tabla 64. Prueba de ANOVA+Tukey para dureza en el tratamiento optimizado.			
Tratamiento	Letra	Resultado	Prueba Aplicada
T0	B	563.67 ± 41.86	ANOVA + Tukey
T1	B	544.00 ± 34.87	ANOVA + Tukey
T2	A	1506.00 ± 61.61	ANOVA + Tukey
T3	B	493.33 ± 32.39	ANOVA + Tukey
T4	C	249.00 ± 25.16	ANOVA + Tukey
T5	C	325.00 ± 58.51	ANOVA + Tukey

En la figura 42 se observa mediante la prueba de ANOVA+Tukey que el tratamiento T2 con letra (a) tiene mayor contenido de fuerza, mientras que los tratamientos T0, T1 y T3 comparten la misma letra (b) manteniendo valores intermedios, T4 y T5 con letras iguales (c) registro un valor menor de dureza indicando que la composición de la formulación afecta a esta variable.




Figura 42. Diagrama y caja de bigote de dureza-tratamiento optimizado.

- Fracturabilidad

En la tabla 65 se observa el análisis de ANOVA+Tukey para fracturabilidad comparten los mismos valores similares que la tabla 61.

Tabla 65. Prueba de ANOVA+Tukey para fracturabilidad en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	B	563.67 ± 41.86	ANOVA + Tukey
T1	B	544.00 ± 34.87	ANOVA + Tukey
T2	A	1506.00 ± 61.61	ANOVA + Tukey
T3	B	493.33 ± 32.39	ANOVA + Tukey
T4	C	249.00 ± 25.16	ANOVA + Tukey
T5	C	325.00 ± 58.51	ANOVA + Tukey

En la figura 43 se muestra diferencias significativas para la variable de fracturabilidad con valores similares de la tabla 61 siendo así que afecta la composición de las formulaciones para esta variable.




Figura 43. Diagrama y caja de bigotes de fracturabilidad-tratamiento optimizado.

- Cohesividad

En la tabla 66 se observa diferencias significativas mediante la prueba de (ANOVA+Tukey), el tratamiento T0 presenta mayor cohesividad, mientras que los otros tratamientos tienen valores similares (T1-T5).

Tabla 66. Prueba ANOVA+Tukey para cohesividad en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	0.58 ± 0.04	ANOVA + Tukey
T1	AB	0.48 ± 0.04	ANOVA + Tukey
T2	C	0.06 ± 0.00	ANOVA + Tukey
T3	B	0.39 ± 0.02	ANOVA + Tukey
T4	AB	0.47 ± 0.02	ANOVA + Tukey
T5	B	0.44 ± 0.10	ANOVA + Tukey

En la figura 44 se muestra el análisis de ANOVA+Tukey, el tratamiento T0 con la letra (a) presenta mayor valor, T1 y T4 comparten la misma letra (ab) con valores similares también los tratamientos T3 y T5 con la letra (b), mientras que T2 con letra (c) registro menor valor.




Figura 44. Diagrama y caja de bigote de cohesividad-tratamiento optimizado.

- Masticabilidad

En la tabla 67 se presenta el análisis de Kruskal-Wallis + Dunn con diferencias significativas entre los tratamientos evaluados para esta variable.

Tabla 67. Prueba Kruskal-Wallis + Dunn para masticabilidad en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	A	8.33 ± 0.21	Kruskal-Wallis + Dunn
T1	AB	6.77 ± 1.11	Kruskal-Wallis + Dunn
T2	B	1.53 ± 0.06	Kruskal-Wallis + Dunn
T3	AB	4.87 ± 0.25	Kruskal-Wallis + Dunn
T4	AB	2.80 ± 0.17	Kruskal-Wallis + Dunn
T5	AB	3.68 ± 0.24	Kruskal-Wallis + Dunn

En la figura 45 se observa que el tratamiento T0 con la letra (a) presenta mayor valor y T2 con la letra (b) menor valor, mientras que los otros tratamientos comparten la misma letra (ab) con valores intermedios.




Figura 45. Diagrama y caja de bigote de masticabilidad-tratamiento optimizado.

- Trabajo realizado

Como se observa en la tabla 68 el análisis de Kruskal-Wallis + Dunn muestra diferencias significativas para la variable de trabajo optimizado.

Tabla 68. Prueba de Kruskal-Wallis + Dunn para trabajo realizado en el tratamiento optimizado.

Tratamiento	Letra	Resultado	Prueba Aplicada
T0	AB	10.70 ± 1.13	Kruskal-Wallis + Dunn
T1	AB	12.10 ± 0.26	Kruskal-Wallis + Dunn
T2	A	24.17 ± 5.67	Kruskal-Wallis + Dunn
T3	AB	11.30 ± 0.40	Kruskal-Wallis + Dunn
T4	B	5.80 ± 0.20	Kruskal-Wallis + Dunn
T5	AB	9.34 ± 3.93	Kruskal-Wallis + Dunn

Con la comparación de los tratamientos, se obtiene la figura 46 donde se muestra un diagrama de caja y bigote. Muestra diferencias significativas donde T2 presento mayor valor con letra(a), mientras que los tratamientos T0, T1, T3 y T5 comparten la misma letra (ab) y T4 con letra (b) registro menor valor esto indica que la composición si afecta significativamente a esta variable.




Figura 46. Diagrama y caja de bigote de trabajo realizado-tratamiento optimizado.

4.1.3.2. Caracterización sensorial de las galletas

- Color

Como se observa en la tabla 69 se aplicó una prueba de Friedman para el atributo de color en los tratamientos evaluados no presento diferencias estadísticas comparten la misma letra.

Tabla 69. Atributo de color para galletas en el tratamiento optimizado.

Tratamiento	Q1	Q3	Letra
T0	4	5	A
T1	4	6	A
T2	4	5	A
T3	4	6	A
T4	4	6	A
T5	4	6	A

En la figura 47 se muestra los resultados del análisis estadístico con la prueba de Friedman para el atributo de color en la evaluación sensorial, no existen diferencias significativas entre los tratamientos evaluados.




Figura 47. Diagrama y caja de bigote de Friedman para color-tratamiento optimizado.

- Sabor

En la tabla 70 se observa el análisis de Friedman para el atributo de sabor, no muestra estadísticas significativas en los tratamientos evaluados, obteniendo valores iguales y comparten la misma letra.

Tabla 70. Atributo de sabor para galletas en el tratamiento optimizado.

Tratamiento	Q1	Q3	Letra
T0	4	6	A
T1	4	6	A
T2	4	6	A
T3	4	6	A
T4	4	6	A
T5	4	6	A

En la figura 48 se muestra los resultados del análisis estadístico de la prueba Friedman para el atributo de sabor de las galletas, todos comparten la misma letra (a) presentando un nivel aceptable y comparable.




Figura 48. Diagrama y caja de bigote para sabor-tratamiento optimizado.

- Olor

La tabla 71 indica la prueba estadística de Friedman para el atributo de olor no presenta diferencias significativas entre los tratamientos, comparten la misma letra.

Tabla 71. Atributo de olor para galletas en el tratamiento optimizado.

Tratamiento	Q1	Q3	Letra
T0	4	5	A
T1	4	6	A
T2	3	5	A
T3	4	6	A
T4	4	6	A
T5	4	6	A

En la figura 49 se muestran los resultados del análisis estadístico con la prueba de Friedman para el atributo de olor. Se observó que no existen diferencias estadísticamente significativas entre los tratamientos comparten la misma letra (a), cualquier modificación realizada a los tratamientos no altera el atributo del olor.




Figura 49. Diagrama y caja de bigote para olor-tratamiento optimizado.

- Crujencia

Como se observa en la tabla 72 se realizó una prueba de Friedman y post-hoc, para el atributo de crujencia, presento diferencias estadísticamente significativas entre algunos tratamientos.

Tabla 72. Atributo de crujencia para galletas en el tratamiento optimizado.

Tratamiento	Q1	Q3	Letra
T0	4	6	A
T1	3	5	B
T2	3	5	AB
T3	3	5	AB
T4	4	6	AB
T5	2	4	B

En la figura 50 se muestran los resultados del análisis estadístico de Friedman y post-hoc para el atributo de crujencia de las galletas, se mostró que los tratamientos T1, T2, T3 y T5 tiene menor preferencia a diferencias de los tratamientos T0 y T4 que tienen valores iguales.




Figura 50. Diagrama y caja de bigote para crujencia-tratamiento optimizado.

- Dureza

En la tabla 73 se observa el análisis de Friedman no presenta diferencias estadísticamente significativas comparten la misma letra.

Tabla 73. Atributo de dureza para galletas en el tratamiento optimizado.

Tratamiento	Q1	Q3	Letra
T0	4	6	A
T1	3	5	A
T2	4	6	A
T3	3	6	A
T4	4	6	A
T5	3	5	A

En la figura 51 se muestra los resultados del análisis estadístico con la prueba de Friedman para el atributo de dureza en galletas, no existe diferencias significativas entre los tratamientos se les designa la misma letra (a), los tratamientos T0, T2 y T4 tienen valores altos, mientras que T1, T3 y T5 registraron valores bajos.




Figura 51. Diagrama y caja de bigote para dureza-tratamiento optimizado.

- Aceptabilidad

En la tabla 74 se muestra el análisis estadístico de Friedman para el atributo de aceptabilidad no presento diferencias estadísticamente significativas entre los tratamientos evaluados.

Tabla 74. Atributo de aceptabilidad para galletas en el tratamiento optimizado.

Tratamiento	Q1	Q3	Letra
T0	4	6	A
T1	3	6	A
T2	4	6	A
T3	4	6	A
T4	4	6	A
T5	4	6	A

En la figura 52 se muestra los resultados del análisis estadístico con la prueba de Friedman para el atributo de aceptabilidad de galletas. Donde los tratamientos T0, T2, T3, T4 y T5 no indican diferencia estadísticamente significativa todos comparten la misma letra (a), evidenciado una alta aceptación general de las formulaciones evaluadas.




Figura 52. Diagrama y caja de bigote para aceptabilidad-tratamiento optimizado.

- Textura quebradiza

En la tabla 75 se observa la prueba de Friedman y post-hoc para el atributo de textura quebradiza, presento diferencias estadísticamente significativas en los tratamientos.

Tabla 75. Atributo textura para galletas en el tratamiento optimizado.

Tratamiento	Q1	Q3	Letra
T0	4	5	A
T1	3	5	A
T2	3	5	A
T3	3	6	A
T4	4	6	A
T5	3	5	A

En la figura 53 se muestra los resultados del análisis estadístico con la prueba de Friedman para el atributo de textura quebradiza de galletas. Presenta diferencias estadísticamente significativas entre los tratamientos comparten la misma letra (a), evidenciando una aceptación similar en todas las formulaciones evaluadas.




Figura 53. Diagrama y caja de bigote para textura quebradiza-tratamiento optimizado.

4.2. DISCUSIÓN

4.2.1. Caracterización de los tratamientos formulados

4.2.1.1. Caracterización fisicoquímica de las harinas

La acidez presentó diferencias significativas en todos los tratamientos, registró valores de $0,13 \pm 0,06\%$ a $0,14 \pm 0,01\%$, estos datos se encuentran dentro del límite máximo permitido de $0,2\%$ determinado para harinas que se emplean en pastelería y galletería, de acuerdo con la NTE INEN 616:2015 acerca de los requerimientos de la harina de trigo. Este comportamiento se debe a la naturaleza química que caracteriza a ambas materias primas en su estado seco, puesto que la incorporación progresiva de harina de *Lupinus mutabilis* a las mezclas no modificó su contenido ácido. De igual manera, Utreras y Rodríguez (2025), obtuvieron valores de acidez comparables en la fase previa de la investigación, sin encontrar diferencias significativas de este parámetro en mezclas de harinas andinas sin gluten.

Los resultados obtenidos de almidón presentaron una disminución progresiva y estadísticamente significativa conforme aumenta la proporción de harina de

Lupinus mutabilis. Esto ocurre debido a que el amaranto es un pseudocereal cuya composición está dominada por el almidón, mientras que el chocho es una leguminosa cuya fracción mayoritaria corresponde a proteínas y lípidos (Herrero, 2022; Torres, 2023). En consecuencia, esta caída de almidón se reflejó también en los carbohidratos totales, que mostraron diferencias significativas en todos los tratamientos, con una reducción sostenida desde $65,17 \pm 0,405\%$ a $34,60 \pm 0,72\%$. Es decir, esta tendencia es coherente con la disminución paralela del almidón y refleja la sustitución progresiva de una harina de mayor aporte glucídico, el amaranto por ser una leguminosa de perfil nutricional distinto. Utreras y Rodríguez (2025), observaron la misma tendencia decreciente en la fase previa de la investigación, lo que valida la coherencia del comportamiento entre ambas fases.

Por otra parte, las cenizas mostraron un comportamiento menos lineal: el tratamiento T1 presentó mayor contenido con un valor de $2.40 \pm 0.02\%$, mientras que el tratamiento T4 presentó menor valor $1.69 \pm 0.01\%$, estas diferencias dependen de la variación en la composición de las formulaciones de las harinas utilizadas. Según la Normativa INEN 2646 (2012), el límite permitido es del 3,0%, haciendo referencia a la calidad del grano. Investigaciones previas reportaron contenido de ceniza de 2,75%, tal como se muestra en el estudio de Tipantuña (2024), en la caracterización nutricional y funcional de la harina precocida de amaranto, así como un 2,5% reportado por Aguilar (2019), en un estudio de la determinación del contenido nutricional en harinas de chocho como fuente de carbohidratos y minerales.

El extracto etéreo mostró diferencias significativas entre los tratamientos, presentó valores de $7,7 \pm 0,05\%$ a $8,51 \pm 0,03\%$; esta tendencia al alza en el contenido de grasa tiene que ver con la proporción de harina de chocho en la fórmula. En cuanto a la parte normativa, los valores obtenidos están dentro del rango para las harinas; según el Codex Alimentarius y Norma Técnica Ecuatoriana INEN 616 (2006), indican un rango máximo de grasa del 2% para harinas refinadas de trigo; sin embargo, para harinas que proceden de pseudocereales o leguminosas no se establece un límite específico.

Los resultados obtenidos para el contenido de fibra mostraron diferencias significativas entre los tratamientos, registrando valores de $17,4 \pm 0,7\%$ a $11,37 \pm 0,09\%$. Este comportamiento guarda coherencia, puesto que el chocho presenta mayor contenido de fibra en comparación con el amaranto. En la normativa Ecuatoriana INEN 616 (2006), no determina requerimientos mínimos o máximos que deban cumplir

las harinas de origen vegetal. Sin embargo, un estudio realizado por Espinoza (2025), obtuvo valores similares en el contenido de fibra a base de harina de trigo sarraceno con adición de harina de amaranto y chocho alcanzando valores de 11,22% y 18,69%.

En la humedad se observaron diferencias significativas entre los tratamientos, donde T4 presentó el mayor valor con $4,88 \pm 0,01\%$, mientras que el testigo registró el menor valor con $3,06 \pm 0,01\%$. Este porcentaje de humedad tiende a aumentar al incrementar la harina de chocho en cada formulación, lo cual influye en el contenido final. Resultados similares fueron reportados por Jhoel et al., (2023), al momento de sustituir parcialmente harina de trigo por harina de chocho en la elaboración de galletas obtuvo valores de humedad entre 2,93% y 4,83%, rango cercano en el presente estudio, lo que confirma que la incorporación de esta leguminosa tiende a incrementar el contenido de humedad del producto final. En este sentido, la Norma Técnica Ecuatoriana INEN 2085 (2005) establece que las galletas deben tener un contenido de humedad menor al 10%.

Finalmente, en la proteína se evidencia que los tratamientos tienen un alto porcentaje de diferencias significativas, con una tendencia ascendente desde T0 hasta T4, registrando un rango de $12,51 \pm 0,01\%$ a $34,62 \pm 0,02\%$, evidenciando el aporte proteico progresivo de la harina de chocho en la mezcla. Todos los tratamientos cumplieron con el requerimiento mínimo establecido por la Norma Técnica Ecuatoriana INEN 616 (2006) y el Codex Stan 152 (1985), los cuales exigen un contenido proteico no menor a 7,0 % en harinas de uso alimentario.

4.2.1.2 Caracterización textural de las galletas

La dureza muestra diferencias significativas entre los tratamientos, registrando valores de $1506,00 \pm 61,61\text{g}$ a $249,00 \pm 25,16\text{g}$. Estos resultados se deben a la alta absorción de agua y al menor contenido de gluten presentes en las galletas. Al incorporar harinas no tradicionales, se modifica la matriz del producto, ocasionando variaciones en la firmeza según las proporciones utilizadas en cada formulación (Sabanis, 2021).

Se observaron diferencias significativas en la fracturabilidad entre los tratamientos, presentando un comportamiento similar al de la dureza, porque ambos parámetros se evalúan en el punto de máxima fuerza aplicada. Esto puede deberse a la proporción de ingredientes utilizados en las formulaciones, lo cual pudo influir en los resultados de los parámetros evaluados, tal como lo reportan Yanalá y otros (2024),

quienes encontraron que las galletas con harina de lupino presentaron mayor dureza y fracturabilidad.

En cuanto a la cohesividad, se encontraron diferencias significativas entre los tratamientos, con valores que oscilaron entre $0,58 \pm 0,04$ y $0,39 \pm 0,02$. A medida que aumentaron las sustituciones de harina, se observó una disminución en la cohesividad, relacionada con la capacidad de la matriz para mantenerse unida. Esto coincide con estudios en harinas de *Lupinus mutabilis*, donde el mayor contenido de proteína y fibra genera cambios similares en este parámetro (Cueva, 2018).

Los resultados de masticabilidad mostraron diferencias significativas en los tratamientos, con valores de $8,33 \pm 0,21$ mJ y $1,53 \pm 0,06$ mJ. Se observó una reducción en la energía de masticabilidad, lo cual ocurre cuando el alimento presenta sustituciones en su formulación. Asimismo, Bawa y otros (2023), demostraron que la sustitución parcial de harina de trigo por 20% y 40 % de harina de plátano o cocoyam genera cambios en la energía requerida para la masticabilidad, debido a las variaciones en las formulaciones de la galleta.

El trabajo realizado presento diferencias significativas entre los tratamientos, con valores de $2,17 \pm 5,67$ mJ y $5,80 \pm 0,20$ mJ. Estos datos se relacionan con la dureza y la fracturabilidad, puesto que ambos parámetros se obtienen a partir de la curva de fuerza-deformación característica de la galleta (Castro et al., 2016).

4.2.1.3 Caracterización sensorial de las galletas

Los resultados de la evaluación sensorial mostraron que, para el atributo color, el tratamiento T0 obtuvo la calificación más baja, diferenciándose significativamente de T3, mientras que T1, T2 y T4 se ubicaron en un rango intermedio. Este comportamiento puede atribuirse al efecto de la sustitución de harina de chocho en la formulación. En este sentido, Mera y otros (2023), reportaron que el tratamiento con mayor porcentaje de sustitución de harina de chocho presentó una mejor valoración del color, lo cual fue atribuido no solo al nivel de sustitución, sino también al proceso de tostado y al tratamiento previo aplicado a la harina, factores que favorecieron el desarrollo de una coloración más aceptable para los evaluadores.

En el atributo olor no se observaron diferencias significativas entre los tratamientos, lo que indica que los diferentes porcentajes de sustitución de harina de amaranto y harina de chocho no modificaron de manera perceptible la intensidad aromática de las galletas para los panelistas. Este resultado contrasta con lo reportado por Angulo

y Silvana (2020), quienes encontraron que la incorporación de harina de chocho mejoró la aceptación del olor en las galletas.

En el atributo sabor, los tratamientos no presentaron diferencias significativas, evidenciando una aceptación similar entre las formulaciones evaluadas. Estos resultados indican que los diferentes niveles de sustitución de harina de trigo por harina de chocho no influyeron significativamente en la percepción del sabor de las galletas (Escobar et al., 2024).

El atributo de crujencia presentó diferencias estadísticamente significativas entre los tratamientos evaluados. Donde T1, T2, T3 y T5 obtuvieron una menor aceptación en comparación con T0 y T4. Estos hallazgos coinciden con lo reportado por Chauhan y otros (2016), quienes señalaron que el incremento de harina de amaranto en la formulación de galletas modificó sus propiedades texturales, reduciendo la fuerza de fractura y la percepción de crocancia del producto.

En el atributo de textura quebradiza presentó diferencias significativas en los tratamientos. Los resultados evidenciaron que la fragilidad de las galletas aumentó conforme se incrementó el nivel de sustitución con harina de chocho. Este comportamiento fue observado por Jayasena y Nasar (2011), quienes reportaron un mayor porcentaje de harina de chocho en la formulación de galletas, incrementando su fragilidad y facilitando la fractura durante la evaluación.

A diferencia de los resultados obtenidos mediante el análisis instrumental de dureza, la evaluación sensorial no evidenció diferencias estadísticamente significativas entre los tratamientos. En este sentido, Bourne (2021) señala que la relación entre las mediciones instrumentales y la percepción sensorial depende de la capacidad del panel para detectar cambios en la textura, por lo que pequeñas variaciones registradas por los instrumentos pueden no ser perceptibles durante la evaluación.

En el atributo de aceptabilidad general, los tratamientos no presentaron diferencias estadísticamente significativas. Estos resultados indican que los diferentes niveles de sustitución de harina de amaranto con chocho no afectaron la aceptación global de las galletas. Estudios realizados por Plustea y otros (2024), reportaron que las formulaciones con niveles moderados de harina de chocho mantuvieron una buena aceptabilidad sensorial, sin comprometer la aceptación global del producto cuando se emplean proporciones adecuadas.

4.2.2. Desarrollo del modelo de optimización

4.2.2.1. Análisis multivariado, modelamiento PLS y red neuronal predictiva

El análisis multivariado y el modelamiento predictivo se desarrollaron en etapas progresivas, partiendo del análisis de componentes principales (PCA) y el análisis factorial múltiple (MFA) como herramientas exploratorias, para luego avanzar hacia modelos con capacidad predictiva cuantitativa mediante regresión de mínimos cuadrados parciales (PLS) y finalmente una red neuronal profunda.

El PCA permitió reducir la dimensionalidad del conjunto de datos y explicar el 88,6% de la variabilidad total mediante dos componentes principales: PC1 con 64,5% y PC2 con 24,1%. El primer componente estuvo dominado por las variables fisicoquímicas y sensoriales, mientras que el segundo reflejó principalmente las propiedades texturales instrumentales, lo que sugiere que estos dos bloques de variables responden a fuentes de variación distintas dentro del sistema estudiado. En el biplot de tratamientos y variables, los tratamientos se separaron progresivamente a lo largo de PC1 en función del nivel de sustitución, con T0 en el extremo negativo y T4 en el positivo, evidenciando que el porcentaje de incorporación de harina de *Lupinus mutabilis* es el principal factor que estructura la variabilidad del conjunto de datos. Hassoun y otros (2023), señalan que el PCA es una herramienta fundamental en el análisis de sistemas alimentarios complejos, puesto que permite identificar las variables de mayor peso en la diferenciación entre formulaciones antes de proceder al modelamiento predictivo.

El MFA, por su parte, permitió estructurar las variables según su naturaleza fisicoquímica, textural y sensorial, confirmando que los tres bloques contribuyen de manera diferenciada a la variabilidad total. El bloque fisicoquímico y el sensorial presentaron una contribución predominante en la dimensión 1 (Dim.1 = 0,967 y 0,976, respectivamente), mientras que el bloque textural dominó la dimensión 2 (Dim.2 = 0,994), resultado coherente con lo observado en el PCA. La matriz de correlación complementó este análisis al evidenciar correlaciones positivas entre variables fisicoquímicas como carbohidratos y almidón, así como entre parámetros texturales como dureza y fracturabilidad, confirmando la interdependencia entre estas variables dentro de la formulación. Dumin (2025) indica que el MFA es especialmente útil cuando se trabaja con bloques de variables de naturaleza heterogénea, puesto

que pondera la contribución de cada grupo de manera equitativa, evitando que un bloque con mayor número de variables domine el análisis.

El modelo PLS permitió identificar las variables fisicoquímicas con mayor capacidad predictiva sobre las propiedades texturales y sensoriales del producto, seleccionando el número óptimo de componentes mediante validación cruzada (RMSECV). El análisis VIP identificó a la fibra, la acidez y la humedad como los únicos predictores relevantes ($VIP \geq 1$), lo cual concuerda con la formulación evaluada, dado que la incorporación de harina de *Lupinus mutabilis* modifica directamente estos parámetros. El desempeño del modelo fue heterogéneo: para los atributos sensoriales el ajuste fue aceptable (R^2 entre 0,408 y 0,980), mientras que para los atributos texturales instrumentales fue deficiente ($R^2 < 0,08$ en la mayoría de casos), evidenciando relaciones no lineales entre la formulación y la respuesta mecánica. Este comportamiento coincide con lo reportado por Dumin (2025), quien atribuye este tipo de limitaciones a las interacciones no proporcionales entre ingredientes en sistemas alimentarios complejos, lo que respalda el uso de modelos con mayor capacidad de generalización, como las redes neuronales aplicadas posteriormente en este estudio.

Se implementó un modelo de red neuronal profunda entrenado con los registros de los cinco niveles de sustitución evaluados (0 al 40% de harina de *Lupinus mutabilis*), utilizando los parámetros fisicoquímicos de las harinas como predictores y los atributos texturales instrumentales y sensoriales como variables respuesta. Los resultados demostraron que la red neuronal superó ampliamente al PLS en todas las variables: la dureza y la fracturabilidad, con $R^2 \approx 0,028$ en el PLS, alcanzaron 0,9908 y 0,9911 respectivamente, evidenciando que el modelo capturó con precisión las relaciones no lineales entre el porcentaje de sustitución y la respuesta mecánica. La cohesividad ($R^2 = 0,9833$) y la masticabilidad ($R^2 = 0,9687$) también presentaron ajustes muy elevados, mientras que el trabajo realizado ($R^2 = 0,8902$) fue el único con un desempeño ligeramente inferior. Para los atributos sensoriales, el ajuste fue igualmente destacado (R^2 entre 0,9942 y 0,9996), resultado relevante dado el carácter subjetivo de este tipo de evaluaciones. Estos resultados coinciden con lo reportado por Hassoun y otros (2024), quienes señalan que los modelos de deep learning capturan patrones complejos que los modelos lineales no logran modelar, y con Dumin (2025), quien destaca que la superioridad de las redes neuronales frente al PLS es evidente en sistemas de harinas compuestas con interacción sinérgica

durante el horneado. Con base en estas métricas, el modelo, junto con la función de deseabilidad global aplicada sobre sus predicciones, señala que el nivel de sustitución óptimo corresponde a 16,81% de harina de *Lupinus mutabilis* y 83,19% de harina de amaranto, combinación que definió a T5 como la formulación de mejor equilibrio entre las propiedades texturales y sensoriales evaluadas.

4.2.3. Validación del modelo optimizado

4.2.3.1. Caracterización fisicoquímica de las harinas

Una vez identificada la formulación óptima mediante la función de deseabilidad global, se procedió a su caracterización fisicoquímica como tratamiento T5, con el propósito de verificar que sus propiedades proximales fueran coherentes con el porcentaje de sustitución establecido (16,81% de harina de *Lupinus mutabilis* y 83,19% de harina de amaranto). Los valores obtenidos para T5 se ubicaron dentro del rango comprendido entre T1 y T2.

En la acidez T5 registró el valor más alto entre todos los tratamientos evaluados ($0,15 \pm 0,01\%$), diferenciándose significativamente de T2, que presentó el valor más bajo ($0,13 \pm 0,01\%$), mientras que T1 mantuvo un valor de $0,14 \pm 0,01\%$. Este comportamiento puede atribuirse a las características propias de la composición del amaranto, que en proporciones mayoritarias aporta compuestos que pueden incrementar ligeramente la acidez de la mezcla. Dado que T5 contiene 83,19% de harina de amaranto, la predominancia de esta materia prima podría explicar que su acidez supere incluso a la de T1 y T2. Este resultado concuerda con lo señalado por Morillo (2017), quien indica que la acidez en mezclas de harinas está determinada principalmente por la naturaleza química de los componentes mayoritarios de la formulación.

Los resultados obtenidos en almidón T5 registró el valor más bajo de almidón del conjunto ($80,70 \pm 0,20\%$), diferenciándose significativamente de T0 y T1, los tratamientos con mayores aportes amiláceos, y ubicándose en un nivel más cercano a T2. Herrero (2022), señala que el almidón en harinas compuestas depende no solo de la proporción de cada materia prima, sino también de las interacciones entre sus fracciones durante el procesamiento, lo que explicaría este comportamiento en T5. Esta reducción no representa necesariamente una desventaja nutricional, puesto que Torres (2023), indica que un menor contenido de almidón se asocia con un menor

índice glicémico, característica valorada en alimentos funcionales sin gluten destinados a poblaciones con requerimientos nutricionales específicos.

En los carbohidratos T5 obtuvo $63,45 \pm 0,10$ %, el segundo valor más alto del conjunto después de T0. Este resultado es coherente con su alta proporción de harina de amaranto (83,19%), principal fuente de carbohidratos de la mezcla. Herrero (2022), describe que las harinas de pseudocereales como el amaranto son naturalmente ricas en esta fracción, lo que explica que formulaciones con mayor proporción de amaranto mantengan valores elevados de carbohidratos totales.

En lo que respecta a las cenizas, T5 compartió grupo estadístico con T1 y T2 ($2,31 \pm 0,01\%$), lo que indica un contenido mineral intermedio consistente con su proporción de amaranto. Soriano y otros (2019), destacan el aporte mineral de esta especie, lo que explica que formulaciones con mayor proporción de amaranto mantengan valores de cenizas relativamente más elevados que los tratamientos con mayor sustitución de chocho.

El extracto etéreo, T5 registró $7,61 \pm 0,10$ %, agrupándose estadísticamente con T0 y T1, los de menor contenido lipídico. Este valor es coherente con su bajo porcentaje de chocho, tal como lo señalan Llerena (2022) y Lemache (2025), quienes coinciden en que la harina de *Lupinus mutabilis* es una de las principales fuentes de lípidos insaturados en este tipo de mezclas, de modo que formulaciones con menor proporción de chocho presentan naturalmente un menor aporte graso.

En fibra T5 obtuvo $12,14 \pm 0,01\%$, valor que no difirió significativamente ni de T0 ni de los tratamientos intermedios (T1 y T2), confirmando que su nivel de sustitución no fue suficiente para generar un incremento estadísticamente distinguible respecto al testigo. Sin embargo, Calizaya y otros (2023), señalan que incluso incrementos moderados en el contenido de fibra dietética tienen relevancia funcional, por lo que el aporte de T5 sigue siendo nutricionalmente válido en el contexto de un producto sin gluten.

La humedad en T5 se obtuvieron valores de $3,97 \pm 0,01\%$, ubicándose en una posición intermedia entre T1 y T2, diferenciándose significativamente de todos los demás tratamientos. Este valor se mantiene dentro de los parámetros técnicamente aceptables para harinas de panificación según lo establecido por (Tecnal, 2024), garantizando la estabilidad microbiológica y la aptitud tecnológica del producto.

El contenido de proteína de T5 fue de $12,83 \pm 0,01$ %, el segundo valor más bajo después de T0, lo que refleja su baja proporción de harina de chocho. Sin embargo, Llerena (2022), señala que incluso pequeñas incorporaciones de *Lupinus mutabilis* contribuyen a mejorar el perfil aminoacídico del producto final, dado el alto valor biológico de sus proteínas. Estos resultados evidencian que la caracterización fisicoquímica del tratamiento optimizado T5 presenta coherencia con su nivel de sustitución. La formulación desarrollada logra un equilibrio adecuado entre el aporte nutricional de la harina de chocho y las propiedades tecnológicas de la harina de amaranto, la cual constituye la base predominante de la mezcla, favoreciendo características funcionales y de calidad en el producto final.

4.2.3.2. Caracterización textural de las galletas

La dureza no mostró diferencias significativas entre T0, T1 y T3, mientras que T2 registró el valor más alto ($1506,00 \pm 61,61$ g) y T4 el más bajo ($249,00 \pm 25,16$ g), diferencias atribuibles a la mayor absorción de agua y al menor contenido de gluten que aportan las harinas no tradicionales (Sabanis y Tzia, 2021). T5 obtuvo $325,00 \pm 58,51$ g, ubicándose junto a T4 en el grupo de menor dureza, lo que indica una firmeza más aceptable para el consumidor.

La fracturabilidad tampoco mostró diferencias significativas entre T0, T1 y T3, mientras que T2 presentó el valor más alto y T4 el más bajo, comportamiento relacionado con la resistencia de la galleta según el porcentaje de sustitución de amaranto por chocho. T5 presentó una fracturabilidad intermedia frente a T2, lo que sugiere una textura más agradable al consumo. De acuerdo con González y otros (2023), afirma que la dureza en las galletas se genera por la desnaturalización de las proteínas presentes en la harina, al generar un cambio estructural en la pérdida de humedad y la alta temperatura.

La cohesividad, por su parte, alcanzó su valor más alto en T0 ($0,58 \pm 0,04$) y el más bajo en T2 ($0,39 \pm 0,02$), sin diferencias entre T1 y T4, disminución que se explica por el mayor contenido de proteína y fibra que introduce el chocho, componentes que reducen la capacidad de la matriz para mantenerse unida. Con $0,44 \pm 0,10$, T5 se ubicó en una posición intermedia junto con T3, lo que indica que su menor proporción de chocho (16,81%) limitó este efecto sin eliminarlo por completo. Este resultado es coherente con lo reportado por Miranda y otros (2023), quienes al incorporar 20% de

avena molida en galletas observaron una reducción similar de la cohesividad asociada al mayor aporte de fibra.

En masticabilidad, T0 registró el valor más alto ($8,33 \pm 0,21$ mJ) y T2 el más bajo ($1,53 \pm 0,06$ mJ), sin diferencias entre T1, T3 y T4, lo que indica que la energía necesaria para masticar el producto disminuye conforme se compromete su cohesión interna. T5 obtuvo $3,68 \pm 0,24$ mJ, un valor intermedio que sugiere que su formulación logró conservar suficiente cohesión como para requerir un esfuerzo masticatorio moderado, sin llegar a la fragilidad de T2. Hashimoto y otros (2023), encontraron una relación equivalente entre la composición de harinas compuestas y la masticabilidad, lo que refuerza la interpretación de este resultado.

El trabajo realizado fue más alto en T2 ($24,17 \pm 5,67$ mJ) y más bajo en T4 ($5,80 \pm 0,20$ mJ), sin diferencias entre T0, T1 y T3, patrón directamente vinculado a la dureza y la fracturabilidad de cada tratamiento, puesto que estos parámetros se integran en la curva de deformación de la galleta. T5 cerró con $9,34 \pm 3,93$ mJ, valor intermedio que confirma que su combinación de proteína y fibra, aunque moderada, fue suficiente para incrementar la energía de deformación por encima de T4 sin alcanzar la rigidez de T2. Cabagnols y otros (2025), atribuyen justamente a estos dos componentes el efecto sobre la estructura requerida durante el trabajo de deformación, tal como se refleja en los resultados obtenidos.

4.2.3.3. Caracterización sensorial de las galletas

Los resultados de la evaluación sensorial mostraron que el atributo de color, T5 no muestra diferencias significativas entre los tratamientos, lo que confirma que la formulación optimizada no altera perceptiblemente la tonalidad del producto respecto a las demás formulaciones evaluadas. Este resultado es coherente con lo señalado por Chauhan y otros (2016), quienes reportan estabilidad en la percepción del color frente a la sustitución de harinas.

En el atributo de sabor, T5 obtiene valores similares a los tratamientos evaluados tampoco se identificaron diferencias significativas. Esto indica que no afectó la formulación optimizada en la percepción de sabor. Este resultado favorable es consistente con lo discutido por Sindhuja y otros (2019), respecto a la estabilidad sensorial de productos horneados en concentraciones moderadas.

En cuanto al atributo olor, el tratamiento optimizado no presentó diferencias significativas respecto a los tratamientos T1, T3 y T4, registraron valores similares. Estos

resultados indican que el olor del tratamiento T5 fue percibido favorablemente por los panelistas, alcanzando un nivel de aceptación comparable al de los tratamientos mencionados. Este comportamiento coincide con lo reportado por Campués y Pérez (2025), en la fase exploratoria de su estudio, donde se evidenció una aceptación similar.

En el atributo de crujencia T5 tiene diferencias significativas no comparten valores con los tratamientos, presento el punto de mayor deseabilidad global, no obtuvo la mejor puntuación específicamente en crujencia, lo que es consistente con la naturaleza multicriterio de la optimización: la función de deseabilidad no prioriza un solo atributo, sino que busca el mejor equilibrio conjunto entre todas las respuestas evaluadas. Obeta y otros (2020), señalan que es común que formulaciones optimizadas mediante metodologías multicriterio no maximicen individualmente cada atributo sensorial, sino que representen el mejor compromiso global entre las variables de interés.

Los resultados sensoriales de la formulación optimizada confirman que la textura quebradiza constituye una alternativa sensorialmente viable, al mantener niveles de aceptación global, sabor y color comparables con los demás tratamientos. En la investigación realizada por Guiné (2022), menciona que las propiedades mecánicas de los alimentos dependen de cómo se mezclan y procesan los ingredientes durante la fabricación, influyen directamente en la textura del producto y en la estabilidad de sus características texturales a lo largo de su vida útil.

El atributo de dureza sensorial de T5 registro valores similares a T1, no presentó diferencias estadísticamente significativas entre los tratamientos. Los resultados obtenidos sugieren que la formulación optimizada mantuvo una dureza equilibrada en comparación con los tratamientos, confirmando la estabilidad de este atributo observada también en la fase exploratoria, tal como lo señalan Rahman y otros (2021), respecto a las diferencias entre percepción sensorial y medición mecánica instrumental.

Para el atributo de aceptabilidad general, T5 obtuvo valores iguales a los tratamientos evaluados. Este resultado confirma que la formulación optimizada logró mantener un nivel de aceptabilidad comparable al resto de tratamientos, validando sensorialmente la selección realizada mediante la función de deseabilidad global. Este hallazgo es coherente con lo reportado por Campués y Pérez (2025), en

el estudio paralelo del mismo proyecto, donde tampoco se evidenciaron diferencias significativas relevantes en la aceptabilidad general de las formulaciones con distintos niveles de sustitución de amaranto con chocho.

V. CONCLUSIONES Y RECOMENDACIONES

5.1. CONCLUSIONES

- La evaluación fisicoquímica de las formulaciones de harina permitió identificar diferencias claras entre tratamientos. En primer lugar, el tratamiento T4 con 40% de harina de *Lupinus mutabilis*, fue el más destacado nutricionalmente, porque alcanzó el mayor contenido de proteína ($34,62 \pm 0,03$ g/100g) muy por encima de $12,51 \pm 0,02$ g/100g registrados en T0, así como los valores más altos de fibra ($17,40 \pm 0,70$ g/100g) y extracto etéreo ($8,51 \pm 0,04$ %). A medida que aumentó el porcentaje de chocho en la mezcla, los carbohidratos totales, el almidón y las cenizas disminuyeron de forma progresiva, por lo que T0 se mantuvo como el tratamiento con los valores más altos en estas tres variables, con $65,17 \pm 0,40$ % de carbohidratos, $173,03 \pm 7,12$ g/100g de almidón y $3,76 \pm 0,02$ % de cenizas. La humedad, por su parte, aumentó de $3,06 \pm 0,01$ % en T0 a $4,88 \pm 0,01$ % en T4, manteniéndose en todos los casos dentro de los rangos adecuados para harinas destinadas a consumo humano. En cambio, la acidez no presentó diferencias relevantes, con valores entre 0,13 y 0,14% en todos los tratamientos. En definitiva, T4 resultó el tratamiento fisicoquímicamente más favorable en términos de aporte proteico y fibroso, mientras que T0 conservó la mayor reserva de carbohidratos y minerales.
- El análisis de la influencia de la incorporación progresiva de harina de chocho en la sustitución de la harina de amaranto evidenció que cada nivel de sustitución generó un perfil textural y sensorial diferenciado. En primer lugar, el tratamiento T2 presentó la mayor dureza y fracturabilidad de todo el estudio ($1506,00 \pm 61,61$ g), un valor que se alejó notablemente del resto de tratamientos, mientras que T4 registró la menor dureza ($249,00 \pm 25,16$ g), es decir, la galleta más blanda del grupo. De igual forma, T0 se mantuvo como el tratamiento con mayor cohesividad ($0,58 \pm 0,04$) y masticabilidad ($8,33 \pm 0,21$), atributos que fueron disminuyendo a medida que se incrementó el porcentaje de chocho, salvo por el comportamiento particular de T2. En la parte sensorial, T4 se destacó como el mejor tratamiento en sabor y crujencia, diferenciándose

significativamente de T0 en ambos atributos, así como en textura quebradiza, donde también alcanzó la calificación más alta. Sin embargo, en color, olor, dureza y aceptabilidad general no se registraron diferencias significativas entre tratamientos, por lo que ningún tratamiento sobresalió por encima de otro en estos aspectos. En consecuencia, T4 se consolidó como el tratamiento con mejor desempeño sensorial global, aunque T0 conservó las mejores propiedades estructurales en términos de cohesión y masticabilidad.

- El diseño e implementación de los modelos predictivos se realizó en dos etapas complementarias. En primer lugar, se aplicó un modelo de regresión de mínimos cuadrados parciales (PLS) con validación cruzada y selección de variables mediante el índice VIP, que identificó a la fibra (VIP = 1,700), la acidez (VIP = 1,378) y la humedad (VIP = 1,097) como los predictores fisicoquímicos más relevantes. No obstante, el modelo PLS mostró limitaciones evidentes para los atributos texturales, con coeficientes de determinación inferiores a 0,08 para dureza, fracturabilidad, cohesividad y trabajo realizado, lo que evidenció la naturaleza no lineal de estas relaciones. Ante ello, se implementó un modelo de red neuronal profunda (deep learning) entrenado con los registros experimentales de los cinco niveles de sustitución evaluados (0%, 10%, 20%, 30% y 40% de harina de *Lupinus mutabilis*), utilizando como variables predictoras los parámetros fisicoquímicos de las harinas y como variables respuesta los atributos texturales y sensoriales de las galletas. El modelo implementado superó ampliamente al PLS, alcanzando valores de R^2 superiores a 0,98 en las variables evaluadas: la crujencia sensorial obtuvo el mejor ajuste ($R^2 = 0,9996$), seguida del sabor ($R^2 = 0,9986$), el olor ($R^2 = 0,9961$), la dureza ($R^2 = 0,9908$) y la fracturabilidad ($R^2 = 0,9911$), con errores absolutos medios reducidos en todos los casos, lo que confirmó la capacidad del modelo para capturar con alta fidelidad las relaciones no lineales entre formulación y propiedades del producto.
- La validación del modelo neuronal confirmó su capacidad para reproducir con precisión el comportamiento de todas las variables respuesta, sin evidencia de sesgo en ningún tratamiento. A partir de este modelo, la optimización multicriterio mediante la función de deseabilidad global permitió identificar la formulación óptima, correspondiente al tratamiento T5. En cuanto a su composición fisicoquímica, este tratamiento se destacó por presentar la

mayor acidez de todo el conjunto de tratamientos y el menor contenido de almidón, mientras que en humedad, fibra y extracto etéreo se ubicó dentro del rango esperado para su nivel de sustitución. En la evaluación sensorial, T5 mantuvo la aceptabilidad del producto, puesto que el color, el olor, la dureza sensorial y la aceptabilidad general no se diferenciaron del control, y únicamente la crujencia mostró una diferencia significativa frente al resto de tratamientos, lo que evidencia que la formulación optimizada no compromete la percepción del consumidor. Así mismo, en la textura, T5 presentó un comportamiento más favorable, debido a que logró valores intermedios de dureza, cohesividad y masticabilidad que se traducen en una galleta firme, manejable y agradable al mordisco. A diferencia de T2, que resultó demasiado rígido y duro para una experiencia de consumo óptima, y de T4, que por su baja cohesión y fragilidad no garantizó la integridad estructural del producto, T5 encontró el punto de equilibrio entre ambos, ofreciendo un análisis de perfil de textura más favorable para el consumidor. En resumen, T5 validó el enfoque metodológico basado en deep learning y optimización multicriterio para el desarrollo de galletas sin gluten con materias primas andinas.

5.2. RECOMENDACIONES

- Ampliar el conjunto de datos experimentales mediante el incremento del número de tratamientos y réplicas, con el fin de mejorar la capacidad de generalización del modelo neuronal. Contar con una base de datos más extensa permitiría entrenar diseños más complejos y evaluar el comportamiento del modelo en rangos de sustitución no contemplados en la presente investigación, reduciendo el riesgo de sobreajuste.
- Incorporar variables de proceso como predictores adicionales del modelo, como, por ejemplo: temperatura y tiempo de horneado, humedad relativa del ambiente y granulometría de las nanopartículas, dado que estos factores inciden directamente sobre las propiedades finales del producto y su inclusión podría incrementar la precisión y el alcance predictivo del modelo desarrollado.
- Profundizar en el estudio del atributo de crujencia mediante técnicas sensoriales más detalladas, como el análisis descriptivo cuantitativo o pruebas de preferencia dirigida, con el objetivo de comprender mejor por qué este parámetro mostró menor preferencia en la formulación optimizada T5 y

determinar si ajustes en la concentración de nanopartículas o en el perfil granulométrico de las harinas pueden mejorar su percepción sin comprometer los demás atributos.

- Llevar a cabo estudios de vida útil y estabilidad del producto optimizado bajo distintas condiciones de almacenamiento, con el fin de determinar su período de aptitud para el consumo y establecer las condiciones óptimas de conservación. Esta información es indispensable para cualquier proceso de escalado o comercialización del producto desarrollado.
- Avanzar hacia la integración del modelo predictivo con sistemas digitales de control de proceso en línea, en el marco de la Industria 4.0 alimentaria. Esta articulación permitiría utilizar las predicciones del modelo en tiempo real para ajustar parámetros de formulación y proceso, garantizando la consistencia de la calidad del producto de manera automatizada y abriendo la posibilidad de transferir esta metodología a otros alimentos funcionales enriquecidos con minerales a escala nanométrica.

VI. REFERENCIAS BIBLIOGRÁFICAS

- Aguilar, Adolfo. 2019. «Determinación del contenido nutricional en harinas de chocho (*Lupinus mutabilis*), gandul (*Cajanus cajan*) y zarandaja (*Labland purpureus*) como fuentes de carbohidratos y minerales». <http://repositorio.uta.edu.ec/handle/123456789/29422>.
- Aguirre, Mora, Andrade, Fredes, Gaminao, Rojas, Reyes, y Parada. 2025. «Aporte nutricional de alimentos procesados sin gluten de alto consumo en personas con enfermedad celíaca». <http://www.alanrevista.org/ediciones/2025/2/art-1/>.
- Akram, Sajeela, Aqsa Chatha, Juweria Abid, Umar Farooq, y Abdul Momin Rizwan Ahmad. 2025. «Development and Quality Assessment of Gluten-Free Cookies Using Rice Flour and Date Fruit». *Frontiers in Nutrition* 12. doi:10.3389/fnut.2025.1645063.
- Alkalbani, Nadia, Leen Shahin, Hiba Benzeghiba, Reyad S. Obaid, Tareq M. Osaili, Leila Cheikh Ismail, Ghayah Al qassimi, Maha Rauf, Khawla Abdulrahim, Afra Almashgouni, Fatima Ashuweihi, y Dana AL-Fuqaha. 2026. «Artificial intelligence in functional food innovation: Bioactive enhancement and formulation optimization: A quasi-systematic review». *Food Chemistry: X* 34:103628. doi:10.1016/j.fochx.2026.103628.
- Al-Sarayreh, Mahmoud, Mariza Gomes Reis, Alistair Carr, y Marlon Martins dos Reis. 2023. «Inverse design and AI/Deep generative networks in food design: A comprehensive review». *Trends in Food Science & Technology* 138:215-28. doi:10.1016/j.tifs.2023.06.005.
- Aname. 2024. «Uso Correcto del TPA». <https://www.analisisdetextura.com/soporte-analisis-de-textura/formacion/uso-correcto-del-tpa>.
- Angulo y Silvana. 2020. «Formulación, caracterización bromatológica y organoléptica de galletas de harina de amaranto (*Amaranthus hypochondriacus*) y chocho (*Lupinus mutabilis* sweet) variedad andino iniap 451 enriquecidas con omega 3 y omega 6 en mujeres en etapa de gestación». <https://repositorio.puce.edu.ec/handle/123456789/24843>.
- Arrighi, Leonardo, Ingrid Alves de Moraes, Marco Zulich, Michele Simonato, Douglas Fernandes Barbin, y Sylvio Barbon Junior. 2026. «Explainable Artificial Intelligence Techniques for Interpretation of Food Models: a Review». *Artificial Intelligence Review*. doi:10.1007/s10462-026-11553-2.

- Bawa, Dzigbor, Gobe, y Opoku. 2023. «(PDF) Nutritional, Sensory, and Microbial Quality of Cookies Produced by Partial Replacement of Wheat Flour with Plantain (*Musa paradisiaca*) and Cocoyam (*Colocasia esculenta*) Flours». *ResearchGate*. doi:10.1155/2023/6762289.
- Bock, Jayne, y Arnaud Dubat. 2019. *El Profiler Mixolab Buenas Prácticas en las industrias de molienda y panificación y errores a evitar*.
- Bourne. 2021. «Correlation Between Physical Measurements and Sensory Assessments of Texture and Viscosity». en *ResearchGate*.
- Buzzdev. 2021. «Mercado de Productos Libres de Gluten Alcanzará 8.300 Millones de USD Para 2025». <https://procomer.com/mercado-de-productos-libres-de-gluten-alcanzara-8-300-millones-de-usd-para-2025/>.
- Cabagnols, Solène, Óscar Acosta-Montoya, y Pilar Fallas-Rodríguez. 2025. «Influence of cricket powder content and placebo effect on consumers' acceptance of sweet biscuits*». *Agronomía Mesoamericana* 36. <https://www.redalyc.org/journal/437/43780398049/>.
- Calizaya-Mamani, Ulises Gonzalo, Alejandrina Honorata Sotelo-Méndez, Gabriela Cristina Chire-Fajardo, Ulises Gonzalo Calizaya-Mamani, Alejandrina Honorata Sotelo-Méndez, y Gabriela Cristina Chire-Fajardo. 2023. «La fibra dietaria, importante componente fisicoquímico: un caso peruano». *Tecnología Química* 43(3):676-701.
- Campués Cholca, Pamela Lisbeth, y Jamilet Pérez Vozmediano. 2025. «Evaluación de galletas elaboradas con harinas de chocho (*Lupinus mutabilis*) y amaranto (*Amaranthus spp.*) con nanopartículas de carbonato de calcio». <https://repositorio.upec.edu.ec/handle/123456789/3024>.
- Carrillo Pisco, María Laura. 2020. «"Evaluación de la calidad bromatológica y sensorial de galletas con sustitución parcial de harina trigo (*Triticum spp*) por amaranto (*Amaranthis spp*)"».» <https://repositorio.uteq.edu.ec/handle/43000/5243>.
- Castro, Verdugo, Miranda, y Reodríguez. 2016. «DETERMINACION DE PARAMETROS TEXTURALES DE GALLETAS *Departamento de Ciencia de Los Alimentos y - Free Download PDF». <https://silo.tips/download/determinacion-de-parametros-texturales-de-galletas-e-castro-m-verdugo-m-miranda>.
- Cayambe. 2023. «Elaboración de galletas con harina de chocho y quinua, endulzadas con miel de abeja.» <https://dspace.esPOCH.edu.ec/items/e258253e-5690-4c30-8f15-b0a83e6844f4>.
- Chauhan, Arti, D. C. Saxena, y Sukhcharn Singh. 2016. «Physical, textural, and sensory characteristics of wheat and amaranth flour blend cookies» editado por F. Yildiz. *Cogent Food & Agriculture* 2(1):1125773. doi:10.1080/23311932.2015.1125773.

- Chavez. 2023. «Directrices ISO 4121: Análisis Sensorial | PDF | Organización internacional para la estandarización». <https://es.scribd.com/document/693598993/EX-UNE-ISO-4121-2006>.
- Chen, Yang, Honglin Zhu, Yihang Feng, Yi Wang, Xinhao Wang, Weimin Zhang, y Yangchao Luo. 2026. «Rheological Analysis in Food Processing: Factors, Applications, and Future Outlooks with Machine Learning Integration». *RSC Advances* 16(6):5040-63. doi:10.1039/D5RA07499A.
- Chicco, Davide, Matthijs J. Warrens, y Giuseppe Jurman. 2021. «The Coefficient of Determination R-Squared Is More Informative than SMAPE, MAE, MAPE, MSE and RMSE in Regression Analysis Evaluation». *PeerJ Computer Science* 7:e623. doi:10.7717/peerj-cs.623.
- Chile. 2020. «Amaranto: el alimento del futuro ante la mega sequía y el cambio climático». <https://www.pressenza.com/es/2020/09/amaranto-el-alimento-del-futuro-ante-la-mega-sequia-y-el-cambio-climatico/>.
- Clariana, Inés. 2020. «La Significación de la Textura». *En blanco: revista de arquitectura* 12(28):9-11.
- Clinic, Del personal de Mayo. 2025. «Alimentación sin gluten». <https://www.mayoclinic.org/es/healthy-lifestyle/nutrition-and-healthy-eating/in-depth/gluten-free-diet/art-20048530>.
- Colaborad, Oficina de Prensa y. 2024. «La textura en los alimentos: una delicia sensorial». <https://www.ciad.mx/la-textura-en-los-alimentos-una-delicia-sensorial/>.
- Cordis. 2022. «La seguridad de los nanomateriales para la salud y el medio ambiente». <https://cordis.europa.eu/article/id/90472-health-and-environmental-safety-of-nanomaterials/es>.
- Couto, Cristina, y Agostinho Almeida. 2022. «Metallic Nanoparticles in the Food Sector: A Mini-Review». *Foods* 11(3):402. doi:10.3390/foods11030402.
- Cristinaot. 2025. «Control de Calidad en Galletas: Sabor, Textura y Normativas | Bastak». <https://www.bastak.com/es/blog/quality-control-in-cookies-assurance-of-flavor-and-standard>.
- Cueva, Rodrigo. 2018. «Evaluación de la sustitución parcial de la harina de trigo con harina de lupino (*Lupinus mutabilis* Sweet) para la elaboración de pan». <https://www.dspace.uce.edu.ec/entities/publication/www.dspace.uce.edu.ec>.
- Dadhaneeya, Harsh, Prabhat K. Nema, y Vinkel Kumar Arora. 2023. «Internet of Things in food processing and its potential in Industry 4.0 era: A review». *Trends in Food Science & Technology* 139:104109. doi:10.1016/j.tifs.2023.07.006.

- Ding, Haohan, Haoke Hou, Long Wang, Xiaohui Cui, Wei Yu, y David I. Wilson. 2025. «Application of Convolutional Neural Networks and Recurrent Neural Networks in Food Safety». *Foods* 14(2):247. doi:10.3390/foods14020247.
- Elyashar, Aviad, Abigail Paradise Vit, Guy Sebbag, Alex Khaytin, y Avi Zakai. 2025. «Automated Gluten Detection in Bread Images Using Convolutional Neural Networks». *Applied Sciences* 15(4):1737. doi:10.3390/app15041737.
- Escobar, Karol Yannela Revilla, María Laura Carillo Pisco, Jhonnatan Aldas Morejon, Jonathan Arguello Cedeño, Carlos Julio Tubay Bermudez, y Roy Barre Zambrano. 2024. «Efecto de la incorporación parcial de harina de amaranto (*Amaranthus* spp) y chocolate en las características bromatológicas y sensoriales de galletas: Effect of partial incorporation of amaranth (*Amaranthus* spp) flour and chocolate on bromatological and sensory characteristics of cookies». *TECNOCENCIA Chihuahua* 18(2):e1484-e1484. doi:10.54167/tch.v18i2.1484.
- Espinosa Manfugás, Julia. 2007. «Evaluación Sensorial de los Alimentos». https://www.academia.edu/39491587/Evaluaci%C3%B3n_Sensorial_de_los_Alimentos.
- Espinoza, Dayana. 2025. «Diseño de una mezcla alimenticia a base de harina de trigo sarraceno con adición de harina de amaranto y chocho para la elaboración de pasteles nutricionales.» <https://dspace.esPOCH.edu.ec/items/cc77c11c-70d8-46bb-b9a1-d09dd6e2804b>.
- Farrell, Robert E. 2010. «Chapter 21 - High-Throughput Analysis of Gene Expression». Pp. 499-513 en *RNA Methodologies (Fourth Edition)*. San Diego: Academic Press.
- Fdez-Vidal, Xosé R., Nerea Fernández-Canto, María Ángeles Romero-Rodríguez, Ana María Ramos-Cabrer, Santiago Pereira-Lorenzo, y Matilde Lombardero-Fernández. 2024. «Neural networks allow the automatic verification of the type of flour, analysing the starch granule morphology, to ensure the protected geographical indication 'Galician Bread'». *Food Control* 158:110198. doi:10.1016/j.foodcont.2023.110198.
- Fernández. 2023. «Tipos de Deep Learning: Todo lo que debes saben». <https://www.tokioschool.com/noticias/tipos-deep-learning/>.
- Fuentes, Sigfredo. 2022. «Implementation of Artificial Intelligence in Food Science, Food Quality, and Consumer Preference Assessment». *Foods* 11(9):1192. doi:10.3390/foods11091192.
- García Guillermina. 2023. «Nanotecnología En Alimentos, Te Contamos Qué Es - THE FOOD TECH - Medio de Noticias Líder En La Industria de Alimentos y Bebidas - The Food Tech». <https://thefoodtech.com/packaging-y-procesamiento/nanotecnologia-en-alimentos-te-contamos-que-es/>.
- Ge, Xinyu, Yongjie Zhou, Qing Li, Yuqing Tan, Yongkang Luo, y Hui Hong. 2025. «Machine Learning for Food Flavor Prediction and Regulation: Models, Data

- Integration, and Future Perspectives». *Journal of Advanced Research* S209012322500815X. doi:10.1016/j.jare.2025.10.018.
- Ghosh. 2025. «Nanotechnology in food application: an introduction». Pp. 1-31 en *Advancements in Nanotechnology for Food and Packaging*. Elsevier.
- Giménez, Martín. 2025. «¿Qué es un texturómetro y para qué se utiliza en el laboratorio? - Ilión Analítica». <https://ilion.com.uy/notas-de-aplicacion/que-es-un-texturometro-y-para-que-se-utiliza-en-el-laboratorio/>.
- González, Ibeth, Ruth Mary Benavides-Guevara, Brenda K. Jurado, Melissa Marulanda, y Carlos M. Zuluaga-Domínguez. 2023. «Propiedades fisicoquímicas, texturales y sensoriales en galletas elaboradas con trigo, avena y quinua». *Ingeniería y competitividad* 25(2). <https://www.redalyc.org/journal/2913/291376231003/html/>.
- Grados Torrez, Ricardo Enrique. 2023. «Evaluación del aporte nutricional del amaranto (*amaranthus caudatus linnaeus*), quinua (*chenopodium quinoa willd*) y tarwi (*lupinus mutabilis sweet*) en el desayuno». *Revista CON-CIENCIA* 5(2):15-28.
- Grueso. 2024. «La composición de los alimentos». https://rfec.com/index.php/es/smartweb/universo_ciclista/articulo/rfec/17-La-composicion-de-los-alimentos.
- Guiné, Raquel P. F. 2022. «Textural Properties of Bakery Products: A Review of Instrumental and Sensory Evaluation Studies». *Applied Sciences* 12(17):8628. doi:10.3390/app12178628.
- Guiné, Raquel P. F., y Sofia G. Florença. 2024. «Development and Characterisation of Functional Bakery Products». *Physchem* 4(3):234-57. doi:10.3390/physchem4030017.
- Haenlein, Michael, y Andreas Kaplan. 2019. «A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence». *California Management Review* 61(4):5-14. doi:10.1177/0008125619864925.
- Haohan Ding, Jiawei Tian, Wei Yu, David I. Wilson, Brent R. Young, Xiaohui Cui, Xing Xin, Zhenyu Wang, y Wei Li. 2023. «The Application of Artificial Intelligence and Big Data in the Food Industry». <https://www.mdpi.com/2304-8158/12/24/4511>.
- Hashimoto, Jorge Minoru, Fernanda de Oliveira Gomes, Jurandy do Nascimento Silva, y Kaesel Jackson Damasceno E Silva. 2023. «Characteristics of Biscuits Containing Different Proportions of Whole Mung Bean, Wheat and Rice Brown Flours». *Food Science and Technology International* 29(8):818-30. doi:10.1177/10820132221121172.
- Hassan, Hussein F., Lydia Mourad, Narjes Khatib, Ranim Assi, Shaymaa Akil, Sami El Khatib, y Rasha Hteit. 2024. «Perceptions towards gluten free products among consumers: A narrative review». *Applied Food Research* 4(2):100441. doi:10.1016/j.afres.2024.100441.

- Hassoun, Abdo, Iman Dankar, Zuhaib Bhat, y Yamine Bouzembrak. 2024. «RETRACTED: Unveiling the Relationship between Food Unit Operations and Food Industry 4.0: A Short Review». *Heliyon* 10(20):e39388. doi:10.1016/j.heliyon.2024.e39388.
- Hassoun, Abdo, Sandeep Jagtap, Hana Trollman, Guillermo Garcia-Garcia, Nour Alhaj Abdullah, Gulden Goksen, Farah Bader, Fatih Ozogul, Francisco J. Barba, Janna Cropotova, Paulo E. S. Munekata, y José M. Lorenzo. 2023. «Food Processing 4.0: Current and Future Developments Spurred by the Fourth Industrial Revolution». *Food Control* 145:109507. doi:10.1016/j.foodcont.2022.109507.
- Hernández. 2023. «¿Qué es el 'deep learning' y cómo beneficia nuestro día a día?». <https://www.bbva.com/es/innovacion/que-es-el-deep-learning-y-como-beneficia-nuestro-dia-a-dia/>.
- Hidalgo. 2025. «(PDF) Enfermedad Celíaca En Ecuador: Algunas Cifras Clave Para El Desarrollo de Alimentos Libres de Gluten». https://www.researchgate.net/publication/399118893_Enfermedad_celiaca_en_Ecuador_algunas_cifras_clave_para_el_desarrollo_de_alimentos_libres_de_gluten.
- Hidrolab. 2022. «¿En qué consiste el análisis sensorial de alimentos?». <https://www.hidrolab.com/blog/en-que-consiste-el-analisis-sensorial-de-alimentos/>.
- Huey, Samantha L., Arini Bhargava, Valerie M. Friesen, Elsa M. Konieczynski, Jesse T. Krisher, Mduduzi N. N. Mbuya, Neel H. Mehta, Eva Monterrosa, Annette M. Nyangaresi, y Saurabh Mehta. 2024a. «Sensory acceptability of biofortified foods and food products: a systematic review». *Nutrition Reviews* 82(7):892-912. doi:10.1093/nutrit/nuad100.
- Hunter. 2022. «Effect Color Has on Food Perception, Flavor and Quality». <https://www.hunterlab.com/en/blog/effect-color-has-on-food-perception-flavor-and-quality/>.
- Hussain, Malik A., Md Imran H. Khan, y Azharul Karim. 2026. «Machine Learning in Transforming the Food Industry». *Foods* 15(1):90. doi:10.3390/foods15010090.
- Igual, Marta, y Javier Martínez-Monzó. 2022. «Physicochemical Properties and Structure Changes of Food Products during Processing». *Foods* 11(15):2365. doi:10.3390/foods11152365.
- Jayasena, V., y S. m. Nasar. 2011. «Effect of Lupin Flour Incorporation on the Physical Characteristics of Dough and Biscuits». *Quality Assurance and Safety of Crops & Foods* 3(3):140-47. doi:10.1111/j.1757-837X.2011.00100.x.
- Jeon, Sungmin, Dayeon Lee, Geunhyuk Yang, Hyukjin Kwon, Minhyo Kim, y Suyong Lee. 2022. «Unravelling the physicochemical features of US wheat flours over the past two decades by machine learning analysis». *LWT* 169:114036. doi:10.1016/j.lwt.2022.114036.

- Jhoel, Victor, Jennifer Ivana Benavides Panchana, Andrea Cortez Espinoza, Jhonnatan Placido Aldas Morejon, y Karol Yannela Revilla Escobar. 2023. «Sustitución parcial de la harina de trigo (*Triticum aestivum* L.) por harina de chocho (*Lupinus mutabilis*) en la elaboración de galletas». *Revista Colombiana de Investigaciones Agroindustriales* 10(2):23-33.
- Jo, Du Min, Seo Jin Han, Seok Chun Ko, Kyung Woo Kim, Dongwoo Yang, Ji Yul Kim, Gun Woo Oh, Grace Choi, Sung Lee, Nazia Tabassum, Young Mog Kim, y Fazlurrahman Khan. 2025. «Application of artificial intelligence in the advancement of sensory evaluation of food products». *Trends in Food Science & Technology* 165:105283. doi:10.1016/j.tifs.2025.105283.
- Jo, Du-Min, Seo-Jin Han, Seok-Chun Ko, Kyung Woo Kim, Dongwoo Yang, Ji-Yul Kim, Gun-Woo Oh, Grace Choi, Dae-Sung Lee, Nazia Tabassum, Young-Mog Kim, y Fazlurrahman Khan. 2025. «Application of artificial intelligence in the advancement of sensory evaluation of food products». *Trends in Food Science & Technology* 165:105283. doi:10.1016/j.tifs.2025.105283.
- Jolliffe, Ian T., y Jorge Cadima. 2016. «Principal component analysis: a review and recent developments». *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences* 374(2065):20150202. doi:10.1098/rsta.2015.0202.
- Keller. 2025. «Rheology vs. Texture: Understanding the Differences and Their Importance». <https://www.stablemicrosystems.com/blog/2025/rheology-vs-texture-understanding-the-differences-and-their-importance/>.
- Kilci, Oya, Yusuf Eryesil, y Murat Koklu. 2025. «Classification of Biscuit Quality With Deep Learning Algorithms». *Journal of Food Science* 90(7):e70379. doi:10.1111/1750-3841.70379.
- Koyuncu, Gulcan. 2025. «Sensory Analysis Methods and Quality Characteristics of Foods». en *Sensory Analysis in Food Science - Integration of Emo-Sensory Studies, Sensory Tests, and Artificial Intelligence*. IntechOpen.
- Lage, Maria, Jesús Simal-Lozano, y G. SALGADO GÓMEZ. 1983. «Determinación de almidón en alimentos».
- Learn. 2025. «R2 Score & Mean Square Error (MSE) Explained». <https://www.bmc.com/blogs/mean-squared-error-r2-and-variance-in-regression-analysis/>.
- LeCun, Yann, Yoshua Bengio, y Geoffrey Hinton. 2015. «Deep Learning». *Nature* 521(7553):436-44. doi:10.1038/nature14539.
- Lee, Dongju, Hyemin Jeon, Yoonseo Kim, y Youngseung Lee. 2025. «Integrating Cutting-Edge Technologies in Food Sensory and Consumer Science: Applications and Future Directions». *Foods* 14(24):4169. doi:10.3390/foods14244169.

- Lemache. 2025. «Propiedades funcionales de la mezcla de harina de chocho y maíz fortificado». <https://dspace.esPOCH.edu.ec/items/24681f9c-cff2-4e7c-bd28-e09265f738c2>.
- Liakos, Konstantinos G., Vassilis Athanasiadis, Eleni Bozinou, y Stavros I. Lalas. 2025. «Machine Learning for Quality Control in the Food Industry: A Review». *Foods* 14(19):3424. doi:10.3390/foods14193424.
- Liao, Bin, Yiming Wang, Xiang Li, Yongqiang Cheng, Guohua Zhao, y Yun Zhou. 2026. «Deep Learning-Based Image Recognition for Food Science and Technology: End-to-End Workflows and Domain-Specific Solutions». *Comprehensive Reviews in Food Science and Food Safety* 25(1):e70388. doi:10.1111/1541-4337.70388.
- Llerena, Luis. 2022. «Beneficios del chocho para mejorar la nutrición». *Qualitas Revista Científica* 24(24):066-075. doi:10.55867/qual24.05.
- Lončar, Biljana, Lato Pezo, Violeta Knežević, Milica Nićetin, Jelena Filipović, Marko Petković, y Vladimir Filipović. 2024. «Mejora de las formulaciones de galletas con melocotón deshidratado combinado: un enfoque de aprendizaje automático para la evaluación y optimización de la calidad tecnológica.» <https://www.mdpi.com/2304-8158/13/5/782>.
- Lonos. 2025. «Funcionamiento y estructura de las Recurrent Neural Networks». <https://www.ionos.com/es-us/digitalguide/paginas-web/desarrollo-web/recurrent-neural-network/>.
- Lopéz. 2019. «Application of Deep Learning in Food: A Review». *Comprehensive Reviews in Food Science and Food Safety* 18(6):1793-1811. doi:10.1111/1541-4337.12492.
- Marimuthu Murugesan, Prakash Pandurangan, Anitha Murugesan, Halan Senthilkumar, Krishnamurthy K. Hegde, Sheela Thangaraj, y Meivelu Moovendhan. 2026. «Artificial intelligence in bread making: Applications in quality control, formulation and sensory prediction». *Food Chemistry: X* 34:103654. doi:10.1016/j.fochx.2026.103654.
- Martín Herrero, Ana. 2022. «Propiedades físicas, funcionales y químicas de harina obtenida a partir de semillas de amaranto». <https://riunet.upv.es/handle/10251/185390>.
- Martínez, Norma Soler, Octelina Castillo Ruíz, Guadalupe Rodríguez Castillejos, Adriana Perales-Torres, Ana Luisa González Pérez, Norma Soler Martínez, Octelina Castillo Ruíz, Guadalupe Rodríguez Castillejos, Adriana Perales-Torres, y Ana Luisa González Pérez. 2023. «Análisis proximal, de textura y aceptación de las galletas de trigo, sorgo y frijol». *Archivos Latinoamericanos de Nutrición* 67(3):227-34.
- Melange. 2025. «Aplicaciones para la industria de la Alimentación y la Panadería». <https://www.vmimixing.com/es/artesanos-industrias-panaderia-pasteleria-snacking/aplicaciones-industria-alimentacion-panaderia/>.

- Melikoglu, Mehmet. 2026. «Instrumental-analytical integration in food sensory evaluation: Current trends and future horizons». *Microchemical Journal* 221:116942. doi:10.1016/j.microc.2026.116942.
- Mello, Livia Silva Simões, Eveline Lopes Almeida, y Lauro Melo. 2019. «Discrimination of Sensory Attributes by Trained Assessors and Consumers in Semi-Sweet Hard Dough Biscuits and Their Drivers of Liking and Disliking». *Food Research International* 122:599-609. doi:10.1016/j.foodres.2019.01.031.
- Mera, Victor, Jennifer Panchana, Andrea Espinoza, Jhonnatan Aldas Morejon, y Karol Revilla Escobar. 2023. «Sustitución parcial de la harina de trigo (*Triticum aestivum* L.) por harina de chocho (*Lupinus mutabilis*) en la elaboración de galletas». *Revista Colombiana de Investigaciones Agroindustriales* 10:23-33. doi:10.23850/24220582.5736.
- Mihafu, Fabian Dominicus, Joseph Yohane Issa, y Moses Witness Kamiyango. 2019. «Implication of Sensory Evaluation and Quality Assessment in Food Product Development: A Review». *Current Research in Nutrition and Food Science Journal* 8(3):690-702. doi:10.12944/CRNFSJ.8.3.03.
- Millán, M^a Jesús Rosado. 2018. «La finalidad de la metodología cuantitativa». <https://isdfundacion.org/2018/11/01/finalidad-metodologia-cuantitativa/>.
- Miranda, José Gabriel, Paul Baruk Zamudio-Flores, Miguel Espino-Díaz, Juan Manuel Tirado-Gallegos, J. Rodolfo Rendón-Villalobos, Francisco Hernández-Centeno, María Hernández-González, Haydee Yajaira Lopez-De la Peña, Gilber Vela-Gutiérrez, René Salgado-Delgado, y Adalberto Ortega-Ortega. 2023. «Efecto de la adición de almidón resistente tipo 3 de avena en las propiedades viscoelásticas de la masa y su influencia sobre la calidad de galletas». *Biotecnia* 25(2):30-43.
- Mita. 2025. «Desafíos en la elaboración de productos para celíacos». <https://uniparmafauba.agro.uba.ar/desafios-en-la-elaboracion-de-productos-para-celiacos/>.
- Montiel. 2023. «Evaluación Físicoquímica del Pan | PDF | Panes | Calidad (comercial)». <https://es.scribd.com/document/257051520/Pruebas-Fisicoquimicas-Para-La-Evaluacion-de-La-Calidad-Del-Pan>.
- Mora, Pau Bramon. 2022. «Detectar defectos en productos de alimentación, control de calidad con Deep Learning». <https://www.id-vision.com/post/detectar-defectos-en-productos-de-alimentación-control-de-calidad-con-deep-learning-1?lang=ca>.
- Morillo, Henry. 2017. «Propiedades físicas y químicas». <https://disolucioncalcita.wixsite.com/topicocalcita/single-post/2017/02/09/propiedades-físicas-y-químicas>.
- Muelas. 2026. «Te contamos qué es el "machine learning" y cómo funciona». <https://www.bbva.com/es/innovacion/machine-learning-que-es-y-como-funciona/>.

- Obeta, N. A., G. C. Azike, y I. S. Asogwa. 2020. «Nutritional composition, physical characteristics, and sensory attributes of wheat based biscuits enriched with bullet pear (*Canarium schweinfurthii*) fruit pulp». *Journal of Food Science and Technology* 57(3):832-39. doi:10.1007/s13197-019-04114-9.
- Ojeda, Gonzalo Adrián, Adriana María Arias Gorman, Sonia Cecilia Sgroppo, Gonzalo Adrián Ojeda, Adriana María Arias Gorman, y Sonia Cecilia Sgroppo. 2019. «Nanotecnología y su aplicación en alimentos». *Mundo nano. Revista interdisciplinaria en nanociencias y nanotecnología* 12(23):0-0. doi:10.22201/ceiich.24485691e.2019.23.67747.
- Oliveira Mallia, Jefferson, Russell Galea, Rajat Nag, Enda Cummins, Ruben Gatt, y Vasilis Valdramidis. 2022. «Nanoparticle Food Applications and Their Toxicity: Current Trends and Needs in Risk Assessment Strategies». *Journal of Food Protection* 85(2):355-72. doi:10.4315/JFP-21-184.
- Oz, Emel, y Fatih Oz. 2025. «Artificial Intelligence-Enabled Ingredient Substitution in Food Systems: A Review and Conceptual Framework for Sensory, Functional, Nutritional, and Cultural Optimization». *Foods* 14(22):3919. doi:10.3390/foods14223919.
- Pandian, Shanthababu. 2022. «K-Fold Cross Validation Technique and its Essentials». <https://www.analyticsvidhya.com/blog/2022/02/k-fold-cross-validation-technique-and-its-essentials/>.
- Párraga Bateoja, Allisson Eliana. 2023. «Elaboración de galletas con sustitución parcial de harina de trigo por harina de fréjol de palo y fréjol castilla». <https://repositorio.puce.edu.ec/handle/123456789/36055>.
- Parreño García, Yadira Teresa, y Edwin Lenin Feijoo Zozoranga. 2025. «Elaboración de una galleta a partir de la mezcla de harinas de granos andinos del Ecuador quinua (*Chenopodium quinoa*) y amaranto (*Amaranthus*)». bachelorThesis, Riobamba.
- Plustea, Loredana, Sylvestre Dossa, Christine Dragomir, Ileana Cocan, Monica Negrea, Diana Obistioiu, Mariana-Atena Poiana, Daniela Voica, Adina Berbecea, y Ersilia Alexa. 2024. «Comparative Study of the Nutritional, Phytochemical, Sensory Characteristics and Glycemic Response of Cookies Enriched with Lupin Sprout Flour and Lupin Green Sprout». *Foods* 13(5):656. doi:10.3390/foods13050656.
- Portal Food Tech. 2022. «Nanopartículas en la industria de alimentos». <https://www.industriaalimentaria.org/blog/contenido/nanopartículas-en-la-industria-de-alimentos>.
- Rahman, Mohammad Shafiur, Zahir Humaid Al Attabi, Nasser Al Habsi, y Mohammed Al Khusaibi. 2021. «Measurement of Instrumental Texture Profile Analysis (TPA) of Foods | Springer Nature Link». https://link.springer.com/chapter/10.1007/978-3-030-68636-9_17.

- Rashvand, Mahdi, Giuliana Paterna, Sabina Laveglia, Hongwei Zhang, Alex Shenfield, Tania Gioia, Giuseppe Altieri, Giovanni Carlo Di Renzo, y Francesco Genovese. 2025. «Quality detection of common beans flour using hyperspectral imaging technology: Potential of machine learning and deep learning». *Journal of Food Composition and Analysis* 142:107424. doi:10.1016/j.jfca.2025.107424.
- Rina, Jinhui, Shuaiqi Ji, Guoyang Pan, Xinyu Tao, Feiyu An, Qu Liu, y Junrui Wu. 2026. «Machine learning combined with sensory evaluation and multi-sensor technology to evaluate the overall quality of commercial soybean paste in China». *Journal of Future Foods* 6(4):554-64. doi:10.1016/j.jfutfo.2025.04.015.
- Rodríguez-González, Ibeth, Ruth Mary Benavides-Guevara, Brenda K. Jurado, Melissa Marulanda, y Carlos M. Zuluaga-Domínguez. 2023. «Propiedades físicoquímicas, texturales y sensoriales en galletas elaboradas con trigo, avena y quinua». *Ingeniería y competitividad* 25(2). <https://www.redalyc.org/journal/2913/291376231003/html/>.
- Rojas Diaz, Sofia, Kimberly Arias Amador, y Carlos Villalobos Montenegro. 2021. «Enfermedad Celiaca: revisión». *Revista Ciencia y Salud Integrando Conocimientos* 5(1). doi:10.34192/cienciaysalud.v5i1.233.
- Ruiz Capillas, Claudia, y Ana M. Herrero. 2021. «Sensory Analysis and Consumer Research in New Product Development». *Foods* 10(3):582. doi:10.3390/foods10030582.
- Rumelhart, David E., Geoffrey E. Hinton, y Ronald J. Williams. 1986. «Learning Representations by Back-Propagating Errors». *Nature* 323(6088):533-36. doi:10.1038/323533a0.
- Sabanis, Tzia. 2021. «(PDF) Development of fibre-enriched gluten-free bread: A response surface methodology study». *ResearchGate*. doi:10.1080/09637480902721196.
- Sanchez, Francisco Demetrio Sosa. 2022. «DESARROLLO DE GALLETAS DE PSEUDOCEREALES ECUATORIANOS PARBOLIZADOS».
- Sarmiento Ramos, José Luis. 2020. «Aplicaciones de las redes neuronales y el deep learning». *Revista UIS Ingenierías* 19(4):1-18.
- Shilpa. 2025. «Hidratos de carbono, proteínas y grasas - Trastornos nutricionales». <https://www.msmanuals.com/es/hogar/trastornos-nutricionales/introducción-a-la-nutrición/hidratos-de-carbono-proteínas-y-grasas>.
- Silva, Izabeli Batista Girarducci da, Marciane Magnani, Erick Almeida Esmerino, Elson Rogerio Tavares Filho, Adriano Gomes Cruz, y Tatiana Colombo Pimentel. 2025. «Preferred Attribute Elicitation (PAE) in the Sensory Descriptive Analysis of Foods: A Deep Comprehensive Review of the Method Steps, Application, Challenges, and Trends». <https://ift.onlinelibrary.wiley.com/doi/10.1111/1541-4337.70197>.

- Silva Paz, Reynaldo J., Roxana R. Silva-Lizárraga, Nicodemo C. Jamanca-Gonzales, y Amparo Eccoña-Sota. 2024. «Evaluation of the Physicochemical and Sensory Characteristics of Gluten-Free Cookies». *Frontiers in Nutrition* 10. doi:10.3389/fnut.2023.1304117.
- Sindhuja, A., M. L. Sudha, y A. Rahim. 2019. «Effect of Incorporation of Amaranth Flour on the Quality of Cookies». *European Food Research and Technology* 221(5):597-601. doi:10.1007/s00217-005-0039-5.
- Soriano-García, Manuel, Isabel Saraid Aguirre-Díaz, Manuel Soriano-García, y Isabel Saraid Aguirre-Díaz. 2019. «Nutritional Functional Value and Therapeutic Utilization of Amaranth». en *Nutritional Value of Amaranth*. IntechOpen.
- Sreekumar, Divya. 2024. «What is Experimental Research Design? Definition, Types, and Examples | Researcher.Life». <https://researcher.life/blog/article/what-is-experimental-research-design-definition-examples-types/>.
- Suarez. 2023. «RPubs - CHAPTER 7 Análisis de factores múltiples». <https://rpubs.com/Alvarofelipes/1041897>.
- Suárez, Juanita Trejos, Lina Valeria Cuadrado Pardo, Josueph Esteban Tabares, Sandra Garzón, Alejandro Bryon, y Zaida Alarcón. 2025. «Modelos Predictivos Para La Seguridad Alimentaria En América Latina: Una Revisión de Alcance». <https://www.alanrevista.org/ediciones/2025/2/art-6>.
- Tavishi. 2023. «Part-1 Evaluation Metrics for Regression Problems in Machine Learning». <https://medium.com/@tavishi.1402/part-1-performance-metrics-in-machine-learning-27cd9264e398>.
- Tecnal. 2024. «- Contenido de humedad vs. actividad de agua: Entiende las diferencias en los alimentos». https://tecnal.com.br/es/blog/441_contenido_de_humedad_vs_actividad_de_agua_entende_las_diferencias_en_los_alimentos.
- Temple, Norman J. 2022. «A rational definition for functional foods: A perspective». *Frontiers in Nutrition* 9:957516. doi:10.3389/fnut.2022.957516.
- Tipantuña, Kevin Fabián. 2024. «Caracterización nutricional y funcional de la harina precocida de amaranto (amaranthus zelenaya sosulka).» Ecuador: Latacunga: Universidad Técnica de Cotopaxi (UTC).
- Tokio. 2023. «Tipos de Deep Learning: Todo lo que debes saben». <https://www.tokioschool.com/noticias/tipos-deep-learning/>.
- Torres, Sitio. 2023. «Ash and Moisture Determination for Food Analysis | Moisture, Ash Analysis». <https://www.precisa.com/application-note-ash-and-moisture-determination-using-prepash-340-series-for-food-analysis/>.
- Toscas, P. J., F. D. Shaw, y S. L. Beilken. 1999. «Partial least squares (PLS) regression for the analysis of instrument measurements and sensory quality data of food». *Meat Science* 52(2):173-78. doi:10.1016/S0309-1740(98)00165-X.

VII. ANEXOS

Anexo 1. Certificado del abstract por parte de idiomas



UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI
FOREIGN AND NATIVE LANGUAGES CENTER

ABSTRACT- EVALUATION SHEET				
NAME: Mayerli Lisbeth Jimenez Chavez, Adriana Patricia Reyes Tonguino DATE: August 5 th , 2026 Topic: "Modelamiento predictivo mediante deep learning de las características sensoriales y texturales de galletas enriquecidas con nanopartículas de carbonato de calcio y su relación con las propiedades fisicoquímicas".				
MARKS AWARDED		QUANTITATIVE AND QUALITATIVE		
VOCABULARY AND WORD USE	Use new learnt vocabulary and precise words related to the topic	Use a little new vocabulary and some appropriate words related to the topic	Use basic vocabulary and simplistic words related to the topic	Limited vocabulary and inadequate words related to the topic
	EXCELLENT: 2 ☐	GOOD: 1,5 ☐	AVERAGE: 1 ☐	LIMITED: 0,5 ☐
WRITING COHESION	Clear and logical progression of ideas and supporting paragraphs.	Adequate progression of ideas and supporting paragraphs.	Some progression of ideas and supporting paragraphs.	Inadequate ideas and supporting paragraphs.
De	EXCELLENT: 2 ☐	GOOD: 1,5 ☐	AVERAGE: 1 ☐	LIMITED: 0,5 ☐
ARGUMENT	The message has been communicated very well and identify the type of text	The message has been communicated appropriately and identify the type of text	Some of the message has been communicated and the type of text is little confusing	The message hasn't been communicated and the type of text is inadequate
	EXCELLENT: 2 ☐	GOOD: 1,5 ☐	AVERAGE: 1 ☐	LIMITED: 0,5 ☐
CREATIVITY	Outstanding flow of ideas and events	Good flow of ideas and events	Average flow of ideas and events	Poor flow of ideas and events
	EXCELLENT: 2 ☐	GOOD: 1,5 ☐	AVERAGE: 1 ☐	LIMITED: 0,5 ☐
SCIENTIFIC SUSTAINABILITY	Reasonable, specific and supportable opinion or thesis statement	Minor errors when supporting the thesis statement	Some errors when supporting the thesis statement	Lots of errors when supporting the thesis statement
	EXCELLENT: 2 ☐	GOOD: 1,5 ☐	AVERAGE: 1 ☐	LIMITED: 0,5 ☐
TOTAL/AVERAGE 9 - 10: EXCELLENT 7 - 8,9: GOOD 5 - 6,9: AVERAGE 0 - 4,9: LIMITED		TOTAL 9		



**UNIVERSIDAD POLITÉCNICA ESTATAL DEL
CARCHI- FOREIGN AND NATIVE LANGUAGES
CENTER**

**Informe sobre el Abstract de Artículo Científico
o Investigación.**

Autor: Mayerli Lisbeth Jimenez Chavez, Adriana Patricia Reyes Tonguino

Fecha de entrega del informe: 5 de agosto de 2026

El presente informe validará la traducción del idioma español al inglés si alcanza un porcentaje de: 9 – 10 Excelente.

Si la traducción no está dentro de los parámetros de 9 – 10, el autor deberá realizar las observaciones presentadas en el ABSTRACT, para su posterior presentación y aprobación.

Observaciones:

Después de realizar la revisión del presente abstract, éste presenta una apropiada traducción sobre el tema planteado en el idioma inglés. Según la rúbrica de evaluación de la traducción en inglés, ésta alcanza un valor de 9; por lo cual se valida dicho trabajo.

Atentamente



MSc. Martha Viveros
RESPONSABLE CIDEN

Anexo 2. Análisis fisicoquímico de las harinas de amaranto con chocho



Figura 54. Preparación de ácidos para los análisis fisicoquímicos




Figura 55. Tamizar la harina para obtener una muestra más fina




Figura 56. Peso del crisol para determinar humedad



Figura 57. Determinación de cenizas por incineración



Figura 58. Determinación de acidez en la muestra



Figura 59. Determinación de fibra- Método weende



Figura 60. Determinación de almidón en harinas



Figura 61. Determinación de grasa por el método de Soxhlet



Figura 62. Proceso de digestión y destilación para proteína

Anexo 3. Análisis textural en galletas




Figura 63. Análisis de TPA en galletas



Figura 64. Análisis de textura en los tratamientos

Anexo 4. Análisis sensorial de galletas




Figura 65. Elaboración de galletas



Figura 66. Cata sensorial de las galletas

Anexo 5. Normativa INEN 2085: 2005 para galletas



INSTITUTO ECUATORIANO DE NORMALIZACIÓN

Quito - Ecuador

NORMA TÉCNICA ECUATORIANA

NTE INEN 2 085:2005
Primera revisión

GALLETAS. REQUISITOS.

Primera Edición

COOKIES. SPECIFICATIONS.

First Edition

DESCRIPTORES: Productos alimenticios, productos a base de harina, productos de pastelería, galletas, requisitos.
AL 02.08-420
CDU: 664.665
CIIU: 3117
ICS: 67.060.00

**Norma Técnica
Ecuatoriana
Obligatoria**

**GALLETAS.
REQUISITOS.**

**NTE INEN
2 085:2005
Primera revisión
2005-05**

Instituto Ecuatoriano de Normalización, INEN - Casilla 17-01-3999 - Baquerizo 454 y Ave. 6 de Diciembre - Quito-Ecuador - Prohibida la reproducción

1. OBJETO

1.1 Esta norma tiene por objeto establecer los requisitos que deben cumplir los diferentes tipos de galletas.

2. DEFINICIÓN

2.1 Galletas. Son productos obtenidos mediante el horneado apropiado de las figuras formadas por el amasado de derivados del trigo u otras farináceas con otros ingredientes aptos para el consumo humano.

2.1.1 Galletas simples. Son aquellas definidas en 2.1 sin ningún agregado posterior al horneado.

2.1.2 Galletas Saladas. Aquellas definidas en 2.1 que tienen connotación salada.

2.1.3 Galletas Dulces. Aquellas definidas en 2.1 que tienen connotación dulce.

2.1.4 Galletas Wafer. Producto obtenido a partir del horneado de una masa líquida (oblea) adicionada un relleno para formar un sánduche.

2.1.5 Galletas con relleno. Aquellas definidas en 2.1 a las que se añade relleno.

2.1.6 Galletas revestidas o recubiertas. Aquellas definidas en 2.1 que exteriormente presentan un revestimiento o baño. Pueden ser simples o rellenas.

2.1.7 Galletas bajas en calorías. Es el producto definido en 2.1 al cual se le ha reducido su contenido calórico en por lo menos un 35 % comparado con el alimento normal correspondiente.

2.2 Leudantes. Son microorganismos, enzimas y sustancias químicas que acondicionan la masa para su horneado.

2.3 Agentes de tratamiento de harinas. Son sustancias que se añaden a la harina para mejorar la calidad de cocción o el color de la misma; como agente de tratamiento de harina se considera a: los blanqueadores, acondicionadores de masa y mejoradores de harina.

3. CLASIFICACIÓN

3.1 Las Galletas se clasifican en los siguientes tipos:

3.1.1 Tipo I Galletas saladas

3.1.2 Tipo II Galletas dulces

3.1.3 Tipo III Galletas wafer

3.1.4 Tipo IV Galletas con relleno

3.1.5 Tipo V Galletas revestidas o recubiertas

(Continúa)

DESCRIPTORES: Productos alimenticios, productos a base de harina, productos de pastelería, galletas, requisitos.

4. DISPOSICIONES GENERALES

4.1 Las galletas se deben elaborar en condiciones sanitarias apropiadas, observándose buenas prácticas de fabricación y a partir de materias primas sanas, limpias, exentas de impurezas y en perfecto estado de conservación.

4.2 La harina de trigo empleada en la elaboración de galletas debe cumplir con los requisitos de la NTE INEN 616.

4.3 A las galletas se les puede adicionar productos tales como: azúcares naturales, sal, productos lácteos y sus derivados, lecitina, huevos, frutas, pasta o masa de cacao, grasa, aceites, levadura y cualquier otro ingrediente apto para consumo humano.

5. REQUISITOS

5.1 Requisitos Específicos

5.1.1 Requisitos Bromatológicos. Las galletas deberán cumplir con los requisitos especificados en la tabla 1.

TABLA 1.

Requisitos	Min	Max	Método de ensayo
pH en solución acuosa al 10%	5,5	9,5	NTE INEN 526
Proteína % (%N x 5,7)	3,0	--	NTE INEN 519
Humedad %	--	10,0	NTE INEN 518

5.1.2 Requisitos Microbiológicos

5.1.2.1 Las galletas simples deben cumplir con los requisitos microbiológicos de la tabla 2.

TABLA 2.

Requisito	n	m	M	c	Método de ensayo
R.E.P. ufc/g	3	$1,0 \times 10^3$	$1,0 \times 10^4$	1	NTE INEN 1529-5
Mohos y levaduras upc/g	3	$1,0 \times 10^2$	$2,0 \times 10^2$	1	NTE INEN 1529-10

5.1.2.2 Las galletas con relleno y las recubiertas deben cumplir con los requisitos microbiológicos de la tabla 3.

TABLA 3. Requisitos microbiológicos para galletas con relleno y para galletas recubiertas

Requisito	n	m	M	c	Método de ensayo
R.E.P. ufc/g	3	$1,0 \times 10^4$	$3,0 \times 10^4$	1	NTE INEN 1529-5
Mohos y levaduras upc/g	3	$2,0 \times 10^2$	$5,0 \times 10^2$	1	NTE INEN 1529-10
Estafilococos aureus					
Coagulasa positiva ufc/g	3	$< 1,0 \times 10^2$	--	0	NTE INEN 1529-14
Coliformes totales ufc/g	3	$< 1,0 \times 10^2$	$1,0 \times 10^2$	1	NTE INEN 1529-7
Coliformes fecales ufc/g 3	3	ausencia	--	0	NTE INEN 1529-8

En donde:

- n número de unidades de muestra
- m nivel de aceptación
- M nivel de rechazo
- c número de unidades entre m y M

(Continúa)

5.1.3 Aditivos

5.1.3.1 A las galletas se les puede adicionar aditivos tales como: saborizantes, emulsificantes, acentuadores de sabor, leudantes, humectantes, agentes de tratamiento de las harinas, antioxidantes y colorantes naturales en las cantidades permitidas de conformidad con la NTE INEN 2 074 y en otras disposiciones legales vigentes.

5.1.3.2 Se permite la adición del Dióxido de azufre y sus sales (metabisulfito, bisulfito, sulfito de sodio y potasio) como agentes de tratamiento de las harinas, conservantes o antioxidantes, en una cantidad máxima de 200 mg/kg, expresado como dióxido de azufre.

5.1.3.3 Para los rellenos de las galletas wafer y de las galletas con relleno, se permite el uso de colorantes artificiales que consten en las listas positivas de aditivos alimentarios para consumo humano según NTE INEN 2 074.

5.1.4 Contaminantes

5.1.4.1 El límite máximo de contaminantes, para las galletas en sus diferentes tipos, son los indicados en la tabla 4.

TABLA 4. Contaminantes

Metales pesados	Límite máximo
Arsénico, como As, mg/kg	1,0
Plomo, como Pb, mg/kg	2,0

6. INSPECCIÓN**6.1 Muestreo**

6.1.1 Se efectúa de acuerdo con lo indicado en la NTE INEN 476

6.2 Aceptación o Rechazo

6.2.1 Si la muestra ensayada no cumple con uno o más de los requisitos indicados en esta norma, se repetirán los ensayos en la muestra testigo reservada para tales efectos. Cualquier resultado no satisfactorio en este segundo caso, será motivo para rechazar el lote.

7. ENVASADO Y EMBALADO

7.1 Las galletas se deben envolver y empacar en material adecuado que no altere el producto y asegure su higiene y buena conservación.

7.2 La calidad de todos los materiales que conforman el envase, como por ejemplo: tinta, pegamento, cartones, etc.; deben ser grado alimentario.

8. ROTULADO

8.1 El rotulado debe cumplir con lo indicado en la NTE INEN 1 334-1 y 1 334-2. Además debe constar la forma de conservación del producto.

(Continúa)

APENDICE Z

Z.1 DOCUMENTOS NORMATIVOS A CONSULTAR

Norma Técnica Ecuatoriana NTE INEN 476:1980	<i>Productos empaquetados o envasados. Método de muestreo al azar</i>
Norma Técnica Ecuatoriana NTE INEN 518:1981	<i>Harinas de origen vegetal. Determinación de la pérdida por calentamiento</i>
Norma Técnica Ecuatoriana NTE INEN 519:1981	<i>Harinas de origen vegetal. Determinación de la proteína</i>
Norma Técnica Ecuatoriana NTE INEN 526:1981	<i>Harinas de origen vegetal. Determinación del ión Hidrógeno</i>
Norma Técnica Ecuatoriana NTE INEN 616:1992	<i>Harina de Trigo. Requisitos</i>
Norma Técnica Ecuatoriana NTE INEN 1 334-1:2000	<i>Rotulado de productos alimenticios para consumo humano. Parte 1. Requisitos</i>
Norma Técnica Ecuatoriana NTE INEN 1 334-2:2000	<i>Rotulado de productos alimenticios para consumo humano. Parte 2. Rotulado nutricional. Requisitos</i>
Norma Técnica Ecuatoriana NTE INEN 1 529-5:1990	<i>Control microbiológico de los alimentos. Determinación del número de microorganismos Aerobios mesófilos REP</i>
Norma Técnica Ecuatoriana NTE INEN 1 529-7:1990	<i>Control microbiológico de los alimentos. Determinación de microorganismos coliformes por la técnica del recuento de colonias</i>
Norma Técnica Ecuatoriana NTE INEN 1 529-8:1990	<i>Control microbiológico de los alimentos. Determinación de coliformes fecales y escherichia Coli</i>
Norma Técnica Ecuatoriana NTE INEN 1 529-10:1998	<i>Control microbiológico de los alimentos. Determinación del número de Mohos y levaduras viables</i>
Norma Técnica Ecuatoriana NTE INEN 1 529-14:1998	<i>Control microbiológico de los alimentos. Determinación del número de staphylococcus aureus</i>
Norma Técnica Ecuatoriana NTE INEN 2 074:1996	<i>Aditivos alimentarios permitidos para consumo humano. Listas positivas. Requisitos</i>

Z.2 BASES DE ESTUDIO

Instituto Colombiano de Norma Técnicas ICONTEC. Norma Técnica Colombiana NTC 1241. *Productos de molinería. Galletas* (quinta revisión), Bogotá 1996

Instituto Centroamericano de Investigación y Tecnología Industrial ICAITI. Norma centroamericana 34 191:87, Guatemala 1987

Comisión Panamericana de Normas Técnicas COPANT. Norma Panamericana 1451, Lima 1983

Norma Venezolana COVENIN 1483-83 Caracas 1983

American Institute of Baking. *Cooking Chemistry and Technology*. Kansas 1989.

Anexo 6. Ficha de evaluación sensorial para galletas

 UPEC Universidad Politécnica Estatal del Carchi	UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI FACULTAD DE INDUSTRIAS AGROPECUARIAS Y CIENCIAS AMBIENTALES CARRERA DE ALIMENTOS FICHA DE EVALUACIÓN SENSORIAL	 POLITÉCNICA DEL CARCHI EDUCAMOS PARA TRANSFORMAR EL MUNDO																																																															
Producto: Galletas tipo cookies a base de harina de amaranto y harina de chocho con nanopartículas de carbonato de calcio																																																																	
Edad: 24	Sexo: Femenino	Fecha: 06-03-2026																																																															
Objetivo: Determinar el grado de aceptación en los atributos, color, olor, sabor, Crocancia, friabilidad, dureza y aceptación de 5 muestras de galletas con diferentes porcentajes de harinas.																																																																	
Definición: ▪ Color: Evaluar la intensidad de color, homogeneidad y atractivo visual. ▪ Aroma: Evaluar si el olor es agradable, típico de galletas. ▪ Olor: Evaluar si el aroma es agradable, típico de galletas. ▪ Sabor: Evaluar la dulzura, salinidad y presencia de sabores no deseados. ▪ Crocancia: Evaluar la sensación quebradiza que percibe al masticar las galletas. ▪ Friabilidad: Evaluar con que facilidad se desmorona la galleta en el paladar. ▪ Dureza: Evaluar la fuerza que se necesita para romper la galleta. ▪ Aceptabilidad: Evaluar todos los aspectos de manera general.																																																																	
Instrucciones: ▪ Frente a usted se presenta (5) cinco muestras de galletas. Deguste cada una de ellas de izquierda a derecha e indique su nivel de agrado de acuerdo con el puntaje de la escala indicada abajo, en el código correspondiente a cada una de las muestras. ▪ El rango para calificar es:																																																																	
<table border="1" style="width: 100%; border-collapse: collapse;"> <tr> <th style="width: 50%;">Puntaje</th> <th style="width: 50%;">Categoría</th> </tr> <tr> <td>1</td> <td>Me disgusta mucho</td> </tr> <tr> <td>2</td> <td>Me disgusta</td> </tr> <tr> <td>3</td> <td>Me disgusta ligeramente</td> </tr> <tr> <td>4</td> <td>Ni me gusta ni me disgusta</td> </tr> <tr> <td>5</td> <td>Me gusta ligeramente</td> </tr> <tr> <td>6</td> <td>Me gusta</td> </tr> <tr> <td>7</td> <td>Me gusta mucho</td> </tr> </table>			Puntaje	Categoría	1	Me disgusta mucho	2	Me disgusta	3	Me disgusta ligeramente	4	Ni me gusta ni me disgusta	5	Me gusta ligeramente	6	Me gusta	7	Me gusta mucho																																															
Puntaje	Categoría																																																																
1	Me disgusta mucho																																																																
2	Me disgusta																																																																
3	Me disgusta ligeramente																																																																
4	Ni me gusta ni me disgusta																																																																
5	Me gusta ligeramente																																																																
6	Me gusta																																																																
7	Me gusta mucho																																																																
A continuación, se presenta la tabla de calificación para cada tratamiento:																																																																	
<table border="1" style="width: 100%; border-collapse: collapse;"> <tr> <th colspan="9">Calificación para cada atributo</th> </tr> <tr> <th>Código</th> <th>Color</th> <th>Aroma</th> <th>Olor</th> <th>Sabor</th> <th>Crocancia</th> <th>Friabilidad</th> <th>Dureza</th> <th>Aceptabilidad</th> </tr> <tr> <td>742</td> <td>6</td> <td>6</td> <td>6</td> <td>5</td> <td>4</td> <td>5</td> <td>4</td> <td>5</td> </tr> <tr> <td>115</td> <td>6</td> <td>6</td> <td>6</td> <td>6</td> <td>6</td> <td>5</td> <td>5</td> <td>6</td> </tr> <tr> <td>2453</td> <td>7</td> <td>7</td> <td>7</td> <td>6</td> <td>5</td> <td>5</td> <td>5</td> <td>6</td> </tr> <tr> <td>3538</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> </tr> <tr> <td>4501</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> <td>7</td> </tr> </table>			Calificación para cada atributo									Código	Color	Aroma	Olor	Sabor	Crocancia	Friabilidad	Dureza	Aceptabilidad	742	6	6	6	5	4	5	4	5	115	6	6	6	6	6	5	5	6	2453	7	7	7	6	5	5	5	6	3538	7	7	7	7	7	7	7	7	4501	7	7	7	7	7	7	7	7
Calificación para cada atributo																																																																	
Código	Color	Aroma	Olor	Sabor	Crocancia	Friabilidad	Dureza	Aceptabilidad																																																									
742	6	6	6	5	4	5	4	5																																																									
115	6	6	6	6	6	5	5	6																																																									
2453	7	7	7	6	5	5	5	6																																																									
3538	7	7	7	7	7	7	7	7																																																									
4501	7	7	7	7	7	7	7	7																																																									
Observaciones: 																																																																	