



UNIVERSIDAD NACIONAL DEL ALTIPLANO
FACULTAD DE CIENCIAS AGRARIAS
ESCUELA PROFESIONAL DE INGENIERÍA AGROINDUSTRIAL



**MONITORIZACIÓN DEL PROCESO DE FERMENTACIÓN DE LA
LECHE MEDIANTE TÉCNICAS ÓPTICAS *CONTACTLESS*:
VISIÓN POR COMPUTADOR Y TERMOGRAFÍA**

TESIS

PRESENTADA POR:

Bach. ANA ERICA PARI CURO

Bach. JHON TACURI MAYHUA

PARA OPTAR EL TÍTULO PROFESIONAL DE:

INGENIERO AGROINDUSTRIAL

PUNO-PERÚ

2024



Bach. ANA ERICA PARI CURO Bach. JHON TACURI ... MONITORIZACIÓN DEL PROCESO DE FERMENTACIÓN DE LA LECHE MEDIANTE TÉCNICAS ÓPTICAS CONTACTLESS: VISIÓN

Universidad Nacional del Altiplano

Detalles del documento

Identificador de la entrega
trn:oid::8254:415396936

284 Páginas

Fecha de entrega
12 dic 2024, 7:38 a.m. GMT-5

56,407 Palabras

Fecha de descarga
12 dic 2024, 7:44 a.m. GMT-5

300,330 Caracteres

Nombre de archivo
TESIS_FINAL_(COMPRESO) FinalIIIIII.pdf

Tamaño de archivo
3.9 MB





13% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Coincidencias menores (menos de 15 palabras)

Fuentes principales

- 12% Fuentes de Internet
- 9% Publicaciones
- 11% Trabajos entregados (trabajos del estudiante)

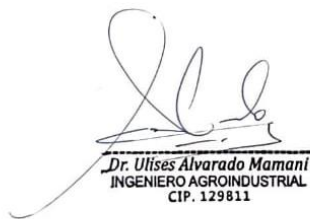
Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.



Dr. Ulises Alvarado Mamani
INGENIERO AGROINDUSTRIAL
CIP. 129811





DEDICATORIA

A Dios por la vida y salud, por guiarme en este proceso, por darme fuerzas y sabiduría durante este periodo de trabajo de investigación. Con un inmenso amor y afecto a mis queridos padres: Julia y Delfin por el apoyo incondicional, el entendimiento y entusiasmo que me dieron en los momentos más difíciles. Gracias queridos padres por darme la confianza, por brindarme muchas orientaciones, consejos y darme la mejor educación para enfrentarme a la vida que en ella lograse mis objetivos. A mis hermanos por el apoyo, el anhelo de seguir orientándome a seguir adelante por mis metas, por los consejos y por los ánimos.

Ana Erica Pari Curo



DEDICATORIA

A mis padres, **Epifanio** y **Dionicia**, quienes con su amor incondicional y esfuerzo incansable me han guiado en cada paso de mi vida. Ustedes son mi mayor Nota de inspiración y fortaleza. A mis hermanos y sobrinos, por ser mi refugio y recordarme siempre el significado de la unión familiar. Su apoyo y confianza han sido pilares fundamentales en este camino. A mis amigos, tanto aquellos que me han acompañado a lo largo de mi vida como los que conocí durante la realización de esta tesis. Su compañía, palabras de aliento y momentos compartidos han sido un motor para alcanzar esta meta. A todos ustedes, dedico este logro con gratitud y profundo cariño.

Jhon Tacuri Mayhua



La presente tesis de pregrado fue posible gracias al apoyo financiero del Programa Nacional PROCIENCIA y del proyecto “**Monitorización de la fermentación de yogur mediante técnicas ópticas *contactless*: visión por computador y termografía**”, respaldado por el CONTRATO N.º PE501082973 – 2023 del CONCYTEC. Expresamos nuestro más profundo agradecimiento por la confianza depositada y el respaldo brindado para el desarrollo de esta investigación, contribuyendo significativamente a su realización y éxito.





AGRADECIMIENTOS

En primer lugar, extendemos nuestros agradecimientos a la Universidad Nacional del Altiplano, especialmente a la Escuela Profesional de Ingeniería Agroindustrial de la Facultad de Ciencias Agrarias, por brindarnos una sólida formación académica que ha sido la base fundamental para nuestro desarrollo profesional. Su compromiso con la excelencia educativa y la promoción de valores integrales ha sido clave para adquirir competencias que hoy aplicamos con orgullo en nuestra trayectoria.

Así mismo agradecemos de manera especial a nuestro director/asesor de tesis, Dr. Ulises Alvarado Mamani, por su orientación, paciencia y apoyo constante a lo largo de todo el proceso de investigación. Sus valiosas sugerencias y comentarios han sido fundamentales para lograr los objetivos propuestos.

A nuestros jurados de tesis, Dr. Alejandro Coloma Paxi, Dr. Eduardo Manzaneda Cabala y Mg. Edgar Gallegos Rojas, por su valioso tiempo dedicado a la revisión y culminación de este proyecto. También, a todo el personal de nuestra Escuela Profesional, por su invaluable colaboración durante la ejecución de las prácticas de esta investigación.

Finalmente expresamos nuestros más sinceros agradecimientos a todas las personas que han contribuido de alguna manera en la realización de esta tesis.

Ana Erica y Jhon



ÍNDICE GENERAL

	Pág.
DEDICATORIA	
AGRADECIMIENTOS	
ÍNDICE GENERAL	
ÍNDICE DE TABLAS	
ÍNDICE DE FIGURAS	
ÍNDICE DE ANEXOS	
ACRÓNIMOS	
RESUMEN	32
ABSTRACT.....	33
CAPÍTULO I	
INTRODUCCIÓN	
1.1. OBJETIVO GENERAL	35
1.2. OBJETIVO ESPECÍFICO.....	36
CAPÍTULO II	
REVISIÓN DE LITERATURA	
2.1. SITUACIÓN ACTUAL Y PERSPECTIVA DE LA INDUSTRIA DEL YOGUR.....	37
2.2. PROCESO DE ELABORACIÓN DEL YOGUR.....	38
2.2.1. Definición del yogur.....	38
2.2.2. Principales etapas en la elaboración de yogur batido.....	40
2.2.2.1. Recepción y selección de la materia prima	40
2.2.2.2. Estandarización	41
2.2.2.3. Homogenización	42



2.2.2.4. Tratamiento térmico	43
2.2.2.5. Enfriamiento.....	43
2.2.2.6. Inoculación.....	44
2.2.2.7. Fermentación.....	44
2.2.2.8. Envasado y almacenado	45
2.3. FERMENTACIÓN DE LA LECHE HASTA SU CONVERSIÓN EN YOGUR.....	45
2.3.1. Mecanismos de acción de los microorganismos en la fermentación	47
2.3.1.1. Metabolismo de la lactosa	47
2.3.1.2. Simbiosis de las bacterias ácido lácticas	52
2.3.1.3. Acidificación y coagulación.....	56
2.3.2. Cambios en las propiedades fisicoquímicas durante la fermentación.....	56
2.3.2.1. Comportamiento del pH en la fermentación de la leche	56
2.3.2.2. Acidez.....	57
2.3.2.3. Viscosidad y gelificación.....	58
2.4. TÉCNICAS DE CONTROL PARA EL MONITOREO DE LA FERMENTACIÓN.....	61
2.4.1. pH	61
2.4.2. Acidez	63
2.4.3. Viscosidad y consistencia.....	64
2.4.4. Color	66
2.4.5. Temperatura.....	67
2.5. MÉTODOS ÓPTICOS DE CUANTIFICACIÓN APLICADOS EN LA INDUSTRIA LÁCTEA: VISIÓN POR COMPUTADOR Y TERMOGRAFÍA.....	68



2.5.1.	Visión por computador	69
2.5.1.1.	Aplicaciones de la visión por computador en la industria alimentaria.....	70
2.5.1.2.	Visión por computador en la industria láctea.....	70
2.5.2.	Termografía	73
2.5.2.1.	Principios de la termografía	73
2.5.2.2.	Aplicaciones de la termografía en alimentos	75
2.5.2.3.	Aplicación de la termografía en la industria láctea.....	76
2.6.	ADQUISICIÓN Y PROCESAMIENTO DE IMÁGENES DE VISIÓN POR COMPUTADOR Y TERMOGRAFÍA	77
2.6.1.	Adquisición de imágenes	77
2.6.2.	Digitalización de imágenes	77
2.6.3.	Propiedades de una imagen digital.....	79
2.6.4.	Procesamiento de imágenes	79
2.6.4.1.	Espacios de colores	79
2.7.	DESARROLLO DE MODELOS DE PREDICCIÓN	83
2.7.1.	Métodos convencionales de procesamiento de datos.....	84
2.7.1.1.	Técnicas de análisis de datos predictivos.....	84
2.7.1.2.	Técnica de análisis de datos descriptivos.....	85
2.7.2.	Métodos de aprendizaje automático.....	87
2.7.2.1.	Aprendizaje automático	87
2.7.2.2.	Aprendizaje no supervisado	88
2.7.2.3.	Aprendizaje supervisado	88
2.7.2.4.	Redes neuronales artificiales.....	89
2.7.2.5.	RNA de regresión.....	90



2.7.2.6. Funciones de activación	92
2.7.2.7. Optimizadores	93
2.7.2.8. Métricas de desempeño	95

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1. LUGAR DE EJECUCIÓN	96
3.2. MATERIAL EXPERIMENTAL	96
3.3. MATERIALES Y EQUIPOS	96
3.3.1. Materiales	96
3.3.2. Equipos de laboratorio	97
3.3.3. Reactivos	97
3.3.4. Bacterias ácido-lácticas	97
3.4. METODOLOGÍA EXPERIMENTAL	97
3.4.1. Descripción del proceso experimental	98
3.4.1.1. Recepción de la materia	98
3.4.1.2. Estandarización	99
3.4.1.3. Reconstitución de leche	99
3.4.1.4. Homogenización	100
3.4.1.5. Tratamiento térmico de la leche	100
3.4.1.6. Enfriamiento.....	101
3.4.1.7. Inoculación.....	101
3.4.1.8. Fermentación.....	102
3.4.1.9. Desarrollo de modelos predictivos.....	104
3.4.1.10. Entrenamiento y desarrollo de modelos.....	105



3.5. MÉTODOS TRADICIONALES PARA EL ANÁLISIS FÍSICOQUÍMICO	107
.....	107
3.5.1. Determinación de pH	107
3.5.2. Determinación de acidez titulable	107
3.5.3. Determinación de color	108
3.5.4. Determinación de viscosidad	109
3.6. MÉTODOS ÓPTICOS	109
3.6.1. Visión por computador	109
3.6.2. Termografía	111
3.7. UNIDADES DE ANÁLISIS Y OBSERVACIONES	111
3.7.1. Factores de estudio	111
3.7.2. Factores de respuesta	112
3.7.3. Indicadores	112
3.8. DISEÑO EXPERIMENTAL	112

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. IMPLEMENTACIÓN DEL SISTEMA DE FERMENTACIÓN Y CAPTURA DE IMÁGENES	114
4.1.1. Construcción de los reactores de fermentación.....	114
4.1.2. Instalación del circuito de recirculación del fluido térmico	116
4.1.3. Desarrollo del código para el controlador automático	118
4.1.4. Instalación de los sensores de temperatura y controladores.....	120
4.1.5. Construcción de la cabina e instalación de las luces y cámaras.....	121
4.1.6. Conexión inalámbrica de las cámaras a las computadoras	123
4.1.7. Validación del sistema de incubación y captura de imágenes	124



4.2. BALANCE DE MATERIA PARA LA ESTANDARIZACIÓN DE LA LECHE.....	126
4.3. MONITORIZACIÓN DE LAS CARACTERÍSTICAS FISICOQUÍMICAS DEL PROCESO DE FERMENTACIÓN DE LA LECHE MEDIANTE TÉCNICAS CONVENCIONALES.....	127
4.3.1. Efecto de las variables de estudio en el tiempo de fermentación.....	128
4.3.2. Control de acidez durante la monitorización de la fermentación de la leche	130
4.3.2.1. Efecto de la concentración proteica en la acidificación de la leche	135
4.3.2.2. Efecto de la concentración de inóculo en la acidificación de la leche	137
4.3.2.3. Efecto de la temperatura en la acidificación de la leche	140
4.3.3. Control de pH.....	143
4.3.3.1. Efecto de la concentración proteica en el pH de la leche.....	148
4.3.3.2. Efecto de la concentración de inóculo en el pH de la leche....	150
4.3.3.3. Efecto de la temperatura en el pH de la leche.....	153
4.3.6. Control de viscosidad.....	156
4.3.6.1. Efecto de la concentración proteica en la viscosidad de la leche	161
4.3.6.2. Efecto de la concentración de inóculo en la viscosidad de la leche	164
4.3.6.3. Efecto de la temperatura en la viscosidad de la leche.....	166
4.3.7. Control de variaciones de color CIELab.....	169
4.3.7.1. Efecto de la concentración proteica en valores de L*, a* y b*.....	173



4.3.7.2. Efecto de la concentración de inóculo en valores de L^* , a^* y b^*	179
4.3.7.3. Efecto de la temperatura en los valores de L^* , a^* y b^*	185
4.4. DESARROLLO DE MODELOS PREDICTIVOS DE LAS PROPIEDADES FÍSICOQUÍMICAS A PARTIR DE IMÁGENES TERMOGRÁFICAS Y DIGITALES	193
4.4.1. Métricas de desempeño de los modelos entrenados	193
4.4.1.1. Métricas de desempeño de los modelos entrenados para predecir la acidez a partir de las imágenes digitales	194
4.4.1.2. Métricas de desempeño de los modelos entrenados para predecir el pH a partir de las imágenes digitales	196
4.4.1.3. Métricas de desempeño de los modelos entrenados para predecir la viscosidad a partir de las imágenes digitales	198
4.4.1.4. Métricas de desempeño de los modelos entrenados para predecir la acidez a partir de las imágenes termográficas	200
4.4.1.5. Métricas de desempeño de los modelos entrenados para predecir el pH a partir de las imágenes termográficas	201
4.4.1.6. Métricas de desempeño de los modelos entrenados para predecir la viscosidad a partir de las imágenes termográficas	203
4.4.2. Ajuste de los modelos seleccionados en función a su métrica de desempeño	206
4.4.2.1. Nivel de ajuste del modelo de predicción de acidez basado en valores de RGB de imágenes digitales	208
4.4.2.2. Nivel de ajuste del modelo de predicción del pH basado en valores de RGB de imágenes digitales	210



4.4.2.3. Nivel de ajuste del modelo de predicción de la viscosidad basado en valores de RGB de imágenes digitales.....	212
4.4.2.4. Nivel de ajuste del modelo de predicción de la acidez basado en valores de RGB de imágenes termográficas	214
4.4.2.5. Nivel de ajuste del modelo de predicción del pH basado en valores de RGB de imágenes termográficas.....	217
4.4.2.6. Nivel de ajuste del modelo de predicción de la viscosidad basado en valores de RGB de imágenes termográficas	220
4.4.3. Descripción de la función matricial de los modelos seleccionados	223
4.4.3.1. Modelo para la predicción de acidez a partir de imágenes digitales	223
4.4.3.2. Modelo para la predicción del pH a partir de imágenes digitales	230
4.4.3.3. Modelo para la predicción de la viscosidad a partir de imágenes digitales	233
4.4.3.4. Modelo para la predicción de acidez a partir de imágenes termográficas.....	237
4.4.3.5. Modelo para la predicción del pH a partir de imágenes termográficas.....	242
4.4.3.6. Modelo para la predicción de la viscosidad a partir de imágenes termográficas.....	248
V. CONCLUSIONES	251
VI. RECOMENDACIONES	253
VII. REFERENCIAS BIBLIOGRÁFICAS.....	254
ANEXOS.....	275



ÁREA: Ingeniería y tecnología

TEMA: Propiedades físicas y estructurales

FECHA DE SUSTENTACIÓN: 13 de diciembre del 2024



ÍNDICE DE TABLAS

	Pág.
Tabla 1	Requisitos fisicoquímicos y tipos de yogur 39
Tabla 2	Características principales de las bacterias ácido - lácticas para la producción de yogur 47
Tabla 3	Dimensiones y capacidad del reactor de incubación 116
Tabla 4	Componentes usados para la automatización de los reactores de incubación 121
Tabla 5	Rangos de temperaturas predefinidas para el sistema de fermentación ... 125
Tabla 6	Resultados del control térmico durante la fermentación a las tres temperaturas de estudio 125
Tabla 7	Información nutricional de las materias primas utilizadas durante la fermentación 126
Tabla 8	Resultados obtenidos del balance de masa para la reconstitución de 6000 gramos de leche a distintos porcentajes de proteína..... 127
Tabla 9	Análisis de varianza del tiempo de fermentación según la temperatura estudiada 129
Tabla 10	Análisis y comparación Tukey para la variación del tiempo de fermentación según la temperatura estudiada 129
Tabla 11	Análisis de varianza de acidez titulable según la concentración de proteína 136
Tabla 12	Análisis y comparación Tukey para la variación de acidez titulable, según la variación de proteína 137
Tabla 13	Análisis de varianza de acidez titulable según la concentración de inóculo 139



Tabla 14	Análisis y comparación Tukey para la variación de acidez titulable, según la variación de inóculo	139
Tabla 15	Análisis de varianza de acidez titulable según las temperaturas de fermentación	142
Tabla 16	Análisis y comparación Tukey para la variación de acidez titulable, según las temperaturas de fermentación.....	142
Tabla 17	Análisis de varianza del pH según las concentraciones de proteína.....	150
Tabla 18	Análisis y comparación Tukey para la variación de pH, según las concentraciones de proteína	150
Tabla 19	Análisis de varianza del pH según las concentraciones de inóculo.....	152
Tabla 20	Análisis y comparación Tukey para la variación del pH, según las concentraciones de inóculo.....	152
Tabla 21	Análisis de varianza del pH según las temperaturas de fermentación.....	155
Tabla 22	Análisis y comparación Tukey para la variación del pH según las temperaturas de fermentación.....	155
Tabla 23	Análisis de varianza de la viscosidad según las concentraciones proteicas	163
Tabla 24	Análisis y comparación Tukey para la variación de la viscosidad según las concentraciones proteicas	163
Tabla 25	Análisis de varianza de la viscosidad según las concentraciones de inóculo	165
Tabla 26	Análisis y comparación Tukey para la variación de la viscosidad según las concentraciones de inóculo.....	166
Tabla 27	Análisis de varianza de la viscosidad según las temperaturas de fermentación	168



Tabla 28	Análisis y comparación Tukey para la variación de la viscosidad según las temperaturas de fermentación.....	169
Tabla 29	Análisis de varianza del valor L* según las concentraciones proteicas ...	174
Tabla 30	Análisis y comparación Tukey para la variación del valor L* según las concentraciones proteicas	174
Tabla 31	Análisis de varianza del valor a* según las concentraciones proteicas....	176
Tabla 32	Análisis y comparación Tukey para la variación del valor a* según las concentraciones proteicas	176
Tabla 33	Análisis de varianza del valor b* según las concentraciones proteicas....	178
Tabla 34	Análisis y comparación Tukey para la variación del valor b* según las concentraciones proteicas	178
Tabla 35	Análisis de varianza del valor L* según las concentraciones de inóculo.	180
Tabla 36	Análisis y comparación Tukey para la variación del valor L* según las concentraciones de inóculo.....	180
Tabla 37	Análisis de varianza del valor a* según las concentraciones de inóculo..	182
Tabla 38	Análisis y comparación Tukey para la variación del valor a* según las concentraciones de inóculo.....	182
Tabla 39	Intervalos valor b* en función a las concentraciones de inóculo	184
Tabla 40	Análisis y comparación Tukey para la variación del valor b* según las concentraciones de inóculo.....	184
Tabla 41	Análisis de varianza del valor L* según las temperaturas de fermentación	187
Tabla 42	Análisis y comparación Tukey para la variación del valor L* según las temperaturas de fermentación.....	187



Tabla 43	Análisis de varianza del valor a^* según las temperaturas de fermentación	190
Tabla 44	Análisis y comparación Tukey para la variación del valor a^* según las temperaturas de fermentación.....	190
Tabla 45	Análisis de varianza del valor b^* según las temperaturas de fermentación	192
Tabla 46	Análisis y comparación Tukey para la variación del valor b^* según las temperaturas de fermentación.....	193
Tabla 47	Métricas de desempeño registrados del entrenamiento de modelos predictivos de acidez a partir de valores RGB de las imágenes digitales	195
Tabla 48	Métricas de desempeño registrados del entrenamiento de modelos predictivos de pH a partir de valores RGB de las imágenes digitales.....	197
Tabla 49	Métricas de desempeño registrados del entrenamiento de modelos predictivos de viscosidad a partir de valores RGB de las imágenes digitales	199
Tabla 50	Métricas de desempeño registrados del entrenamiento de modelos predictivos de acidez a partir de valores RGB de las imágenes termográficas	201
Tabla 51	Métricas de desempeño registrados del entrenamiento de modelos predictivos de pH a partir de valores RGB de las imágenes termográficas	203
Tabla 52	Métricas de desempeño registrados del entrenamiento de modelos predictivos de viscosidad a partir de valores RGB de las imágenes termográficas	205



Tabla 53	Condiciones de cada tratamiento y el tiempo total de fermentación de la leche	207
Tabla 54	Hiperparámetros (w: pesos y b: sesgos) del modelo desarrollado para la predicción de la acidez	229
Tabla 55	Hiperparámetros (w: pesos y b: sesgos) del modelo desarrollado para la predicción del pH	232
Tabla 56	Hiperparámetros (w: pesos y b: sesgos) del modelo desarrollado para la predicción de la viscosidad.....	235
Tabla 57	Hiperparámetros (w: pesos y b: sesgos) del modelo desarrollado para la predicción de la acidez	241
Tabla 58	Hiperparámetros (w: pesos y b: sesgos) del modelo desarrollado para la predicción del pH	245
Tabla 59	Hiperparámetros (w: pesos y b: sesgos) del modelo desarrollado para la predicción de la viscosidad.....	250



ÍNDICE DE FIGURAS

	Pág.
Figura 1 Consumidores habituales de productos lácteos	37
Figura 2 Diagrama de elaboración de yogur batido.....	41
Figura 3 Esquema de la estructura del yogur establecido.....	42
Figura 4 Primera fase de la fermentación homoláctica para <i>S. thermophilus</i> y <i>L. bulgaricus</i>	49
Figura 5 Segunda fase de la fermentación homoláctica para <i>S. thermophilus</i> y <i>L. bulgaricus</i>	50
Figura 6 Tercera fase de la fermentación homoláctica para <i>S. thermophilus</i> y <i>L. bulgaricus</i>	51
Figura 7 Ruta metabólica de Leloir	52
Figura 8 Curva de crecimiento bacteriano	54
Figura 9 Curva de pH del yogur durante la fermentación	57
Figura 10 Desarrollo de la curva de acidez durante el proceso de fermentación.....	58
Figura 11 Evolución del pH y la viscosidad en función al tiempo durante la fermentación de la leche.....	61
Figura 12 Potenciómetro digital de sobremesa.....	63
Figura 13 Equipo para la determinación de acidez.....	64
Figura 14 Viscosímetro capilar	65
Figura 15 Viscosímetro rotacional.....	66
Figura 16 Colorímetro digital de sobremesa.....	67
Figura 17 (A) Estructura de una imagen digital; (B) Imagen digital en espacio de color RGB.....	69
Figura 18 Toma de imagen en circuitos mecánicos con una cámara termográfica.....	75



Figura 19	Imagen de alta y baja resolución	78
Figura 20	Espacio de color RGB	81
Figura 21	Espacio de colores CIELab L*a*b*	82
Figura 22	Etapas de desarrollo un modelo de predicción	84
Figura 23	Clasificación de las técnicas de análisis de datos.....	86
Figura 24	Diseño de una red neuronal simple	90
Figura 25	Diagrama de flujo para obtener los datos durante la monitorización	98
Figura 26	Arquitecturas de los modelos	105
Figura 27	Entrenamiento del modelo por 500 épocas	106
Figura 28	Sistema de visión por computador y termografía para la adquisición de imágenes	110
Figura 29	Reactores de incubación	116
Figura 30	Instalación del circuito de recirculación del fluido de agua caliente y agua fría para la incubación del yogur	117
Figura 31	Diseño del controlador automático (Arduino Mega 2560).....	119
Figura 32	Disposición de las cámaras a la altura del reactor en el interior de la cabina	122
Figura 33	Conexión inalámbrica de la cámara fotográfica a la computadora	123
Figura 34	Conexión inalámbrica de la cámara termográfica a la computadora	123
Figura 35	Curvas de oscilación de las temperaturas durante la fermentación de los reactores de incubación del yogur batido	125
Figura 36	Intervalo de tiempo para la fermentación (min) en función a las temperaturas de estudio.....	129



Figura 37	Curvas de acidificación de la leche con 4.2% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	131
Figura 38	Curvas de acidificación de la leche con 4.5% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	132
Figura 39	Curvas de acidificación de la leche con 4.8% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	134
Figura 40	Intervalos de acidez (% ácido láctico) en función a las concentraciones de proteína.....	137
Figura 41	Intervalos de acidez (% ácido láctico) en función a las concentraciones de inóculo	140
Figura 42	Intervalos de acidez (% ácido láctico) en función a las temperaturas de fermentación.....	142
Figura 43	Curvas de pH de la leche con 4.2% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	145
Figura 44	Curvas de pH de la leche con 4.5% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	146
Figura 45	Curvas de pH de la leche con 4.8% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	147
Figura 46	Intervalos de pH en función a las concentraciones de proteína.....	150



Figura 47	Intervalos de pH en función a las concentraciones de inóculo.....	153
Figura 48	Intervalos de pH en función a las temperaturas de fermentación.....	156
Figura 49	Curvas de viscosidad de la leche con 4.2% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	158
Figura 50	Curvas de viscosidad de la leche con 4.5% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	159
Figura 51	Curvas de viscosidad de la leche con 4.8% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	160
Figura 52	Intervalos de la viscosidad en función a las concentraciones proteicas ...	163
Figura 53	Intervalos de la viscosidad en función a las concentraciones de inóculo.	166
Figura 54	Intervalos de la viscosidad en función a las temperaturas de fermentación	169
Figura 55	Curvas de color de la leche con 4.2% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	170
Figura 56	Curvas de color de la leche con 4.5% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	171
Figura 57	Curvas de color de la leche con 4.8% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo	172
Figura 58	Intervalos del valor L* en función a las concentraciones proteicas	174



Figura 59	Intervalos del valor a^* en función a las concentraciones proteicas.....	176
Figura 60	Intervalos del valor b^* en función a las concentraciones proteicas.....	178
Figura 61	Intervalos del valor L^* en función a las concentraciones de inóculo.....	181
Figura 62	Intervalos del valor a^* en función a las concentraciones de inóculo.....	183
Figura 63	Intervalos del valor b^* en función a las concentraciones de inóculo	185
Figura 64	Intervalos del valor L^* en función a las temperaturas de fermentación...	187
Figura 65	Intervalos del valor a^* en función a las temperaturas de fermentación ...	190
Figura 66	Intervalos del valor b^* en función a las temperaturas de fermentación ...	193
Figura 67	Curvas de comportamiento de la acidez real y predicha en función a los valores RGB de las imágenes digitales	209
Figura 68	Curvas de comportamiento del pH real y predicha en función a los valores RGB de las imágenes digitales	211
Figura 69	Curvas de comportamiento de la viscosidad real y predicha en función a los valores RGB de las imágenes digitales	213
Figura 70	Curvas de comportamiento de acidez real y predicha en función a los valores RGB de las imágenes termográficas.....	216
Figura 71	Curvas de comportamiento de pH real y predicha en función a los valores RGB de las imágenes termográficas.....	219
Figura 72	Curvas de comportamiento de la viscosidad real y predicha en función a los valores RGB de las imágenes termográficas	222
Figura 73	Representación de la arquitectura del modelo desarrollado para la predicción de la acidez	224
Figura 74	Representación de la arquitectura del modelo desarrollado para la predicción del pH	230



Figura 75	Representación de la arquitectura del modelo desarrollado para la predicción de la viscosidad.....	234
Figura 76	Representación de la arquitectura del modelo desarrollado para la predicción de la acidez	239
Figura 77	Representación de la arquitectura del modelo desarrollado para la predicción del pH	243
Figura 78	Representación de la arquitectura del modelo desarrollado para la predicción de la viscosidad.....	248



ÍNDICE DE ANEXOS

	Pág.
ANEXO 1 Promedio de las estimaciones de las variables de respuesta de los tratamientos	275
ANEXO 2 Implementación de los tubos para la circulación del fluido térmico	276
ANEXO 3 Implementación de los sensores y controladores del Arduino para el control automático de la temperatura en los reactores de fermentación	276
ANEXO 4 Construcción de la cabina de captura de imágenes	277
ANEXO 5 Implementación de las luminarias en la cabina de captura de imágenes y control inalámbrico de la cámara fotográfica (A) y termográfica (B).....	277
ANEXO 6 Implementación de cámara fotográfica (A) y termográfica (B) para la monitorización del proceso de fermentación.....	278
ANEXO 7 Captura de imágenes con la cámara fotográfica y termográfica	278
ANEXO 8 Muestreo (A), medición de acidez titulable (B), pH (C), color (D) y viscosidad (E) mediante técnicas convencionales	279
ANEXO 9 Descenso del error de predicción de los modelos en su entrenamiento durante las 500 épocas.....	280
ANEXO 10 Declaración jurada de autenticidad de tesis.....	281
ANEXO 11 Autorización para el depósito de tesis en el Repositorio Institucional....	283



ACRÓNIMOS

FAO:	Organización de Naciones Unidas para la Alimentación y la Agricultura
pH:	Potencial de Hidrogeniones
°C:	Grados Celsius
°K:	Grados Kelvin
%:	porcentaje
NTP:	Norma Técnica Peruana
%m/m:	Porcentaje de masa sobre masa
°D:	Grados Dornic
C:	Carbono
H:	Hidrogeno
O:	Oxigeno
ATP:	Adenosín Trifosfato
ADP:	Adenosín Difosfato
NAD ⁺ :	Nicotinamida Adenina Dinucleótido en forma oxidada
NADH:	Nicotinamida Adenina Dinucleótido reducido
PEP:	Fosfoenolpiruvato
UDP:	Uridina Difosfato
DHAP:	Dihidroxiacetona Fosfato
G3P:	Gliceraldehido -3-fosfato
Na:	Sodio
N:	Normalidad en la fórmula de % de acidez láctico
rpm:	Revolución por minuto
CIE:	Commission Internationale de l'Eclairage



L*:	Luminosidad que va de 0 (negro) a 100 (blanco)
a*:	Indicador de color de verde a rojo
b*:	Indicador de color de azul a amarillo
C*:	Croma
R:	Canal rojo de la imagen digital
G:	Canal verde de la imagen digital
B:	Canal azul de la imagen digital
nm:	Nanómetros
µm:	Micrómetro
mm:	Milímetros
g:	Gramos
W:	Watts
RNA:	Red Neuronal Artificial
NaOH:	Hidróxido de Sodio
ECM:	Error Cuadrático Medio
EAM:	Error Absoluto Medio
R ² :	Coefficiente de Determinación
CMOS:	Complementary Metal-Oxide-Semiconductor
DHCP:	Protocolo de Configuración Dinámica de Host
PPUR:	Termorresistentes De Polipropileno
SD:	Seguridad Digital
SPI:	Serial Peripheral Interface
Pa:	Pascales
s:	Segundos
ANOVA:	Análisis de Varianza



N:	Tamaño de muestra en las Tablas de ANOVA
GL:	Grados de Libertad
SC:	Suma de Cuadrados
MC:	Media Cuadrática
kHz:	Kilo Hercios
m.s.n.m:	Metros sobre el nivel del mar
min:	Minutos



RESUMEN

En la industria del yogur, los métodos ópticos han ganado relevancia recientemente, ofreciendo alternativas rápidas y no destructivas frente a las técnicas tradicionales de control de fermentación. Por lo que, el objetivo es evaluar la precisión de las técnicas ópticas *contactless*: visión por computador y termografía en la monitorización de las propiedades fisicoquímicas de la leche durante la fermentación. Con ese propósito se construyeron dos reactores: en uno de ellos se monitorearon patrones ópticos en los espectros visible e infrarrojo, y en el otro se evaluaron las propiedades fisicoquímicas de la leche, siendo las variables de estudio la proteína (4.2, 4.5 y 4.8%), inóculo (1, 2 y 3%) y temperatura (36, 40 y 44°C), registrándose datos cada 10 minutos hasta alcanzar pH de 4.6. De las imágenes obtenidas se calcularon valores RGB medio con Python usando OpenCV y Numpy, con el que se entrenaron modelos de diferentes arquitecturas para monitorear las propiedades fisicoquímicas en la fermentación, el entrenamiento se desarrolló en Google Colaboratory. Los resultados muestran que la proteína influye en todas las variables de respuesta, el inóculo solo afectó la viscosidad y el componente a*, y la temperatura tuvo un impacto en el pH, la viscosidad y la luminosidad, siendo su efecto más relevante en la velocidad de fermentación. Los modelos desarrollados con imágenes termográficas alcanzaron precisiones superiores al 82.58%, mientras que los de imágenes digitales lograron entre 50.3% y 84.11%. Los mejores modelos requirieron una capa oculta con 24 o 28 neuronas para imágenes digitales, y 12 a 16 neuronas para las termográficas. En conclusión, la visión por computadora y la termografía muestran gran potencial para el control de las propiedades fisicoquímicas en la producción del yogur.

Palabras clave: Modelos, Imágenes, RGB, Técnicas ópticas, Termografía, Visión por computador, Yogur.



ABSTRACT

In the yogurt industry, optical methods have recently gained relevance, offering fast and non-destructive alternatives to traditional fermentation control techniques. Therefore, the objective is to evaluate the accuracy of *contactless* optical techniques: computer vision and thermography in monitoring the physicochemical properties of milk during fermentation. For this purpose, two reactors were built: in one of them optical patterns were monitored in the visible and infrared spectra, and in the other the physicochemical properties of the milk were evaluated, the variables under study being protein (4.2, 4.5 and 4.8%), inoculum (1, 2 and 3%) and temperature (36, 40 and 44°C), recording data every 10 minutes until pH 4.6 was reached. From the images obtained, mean RGB values were calculated with Python using OpenCV and Numpy, with which models of different architectures were trained to monitor the physicochemical properties in the fermentation, the training was developed in Google Colaboratory. The results show that protein influences all response variables, inoculum only affected viscosity and the a^* component, and temperature had an impact on pH, viscosity and luminosity, with its most relevant effect on fermentation rate. Models developed with thermographic images achieved accuracies greater than 82.58%, while those with digital images achieved between 50.3% and 84.11%. The best models required a hidden layer with 24 or 28 neurons for digital images, and 12 to 16 neurons for thermographic ones. In conclusion, computer vision and thermography show great potential for the control of physicochemical properties in yogurt production.

Keywords: Models, Images, RGB, Optical techniques, Thermography, Computer Vision, Yogurt.



CAPÍTULO I

INTRODUCCIÓN

En la actualidad, el consumo de yogur ha mostrado un aumento significativo a nivel mundial. Según FAO (2012), el consumo anual per cápita de productos lácteos aumentó de 28 kg en 1964 a 45 kg en 2020. Sin embargo, Freire et al. (2024) estima que para el año 2030 se podría llegar a 66 kg este aumento en el consumo de productos lácteos, incluido el yogur (Freire et al., 2024). Pero en el Perú, según la U. S. DEPARTMENT OF AGRICULTURE, (2017) el consumo per cápita de yogur es de solo 0.48 kg/habitante/año (Abanto et al., 2022).

El yogur es un producto alimenticio lácteo fermentado semisólido, producido mediante la fermentación de la leche por dos especies de bacterias lácticas: *Streptococcus thermophilus* (*S. thermophilus*) y *Lactobacillus bulgaricus* (Vieira et al., 2023). Durante el proceso de fermentación, estas bacterias transforman la lactosa en ácido láctico, lo que contribuye a las características organolépticas, texturales y nutricionales; motivo por el cual, este producto lácteo está asociado a un patrón alimentario saludable (C. Chen et al., 2017).

Durante la producción del yogur, el control de calidad se realiza con frecuencia mediante métodos tradicionales (técnicas que requieren del contacto directo con el producto) con instrumentos de medición que requieren de limpieza y recalibración constante; también son lentos y están sujetos a contaminación (Silva & Rocha, 2022). Ante la necesidad de mejorar la eficiencia y mantener altos estándares de calidad, se han desarrollado tecnologías no invasivas, como la espectroscopia (Sun et al., 2019), espectroscopia Raman (Rodríguez et al., 2013), las imágenes laser (Verdú et al., 2019), y ultrasonido (L. Zhang et al., 2024a). Estas tecnologías muestran un gran potencial en la



industria láctea por su capacidad para evaluar el proceso sin la necesidad de contacto directo con la muestra. Sin embargo, suelen ser costosas y presentan limitaciones relacionadas con el espacio, el ruido y la emisión de señales débiles (Javanmardi et al., 2021).

La visión por computador y la termografía han emergido como alternativas viables. Estas tecnologías permiten capturar, procesar y analizar imágenes para la detección rápida de parámetros críticos durante la fermentación, utilizando modelos avanzados en combinación con el aprendizaje automático. Esta integración mejoraría la eficiencia y la productividad al reducir los tiempos de procesamiento, aumentar la capacidad de clasificación y permite la recolección de datos en tiempos real durante el proceso de fermentación.

La visión por computador, extrae datos cuantitativos del color de la imagen digital mediante el procesamiento y el análisis de imágenes, lo que da como resultados el logro de una evaluación del color rápida y sin contacto (Milovanovic et al., 2021a), y la termografía se presenta como un método no invasivo y seguro para mostrar el mapa de temperaturas de los objetos, que posteriormente puede ser procesado por un ordenador (Kříž et al., 2021). Una vez que se captura una imagen, es posible medir o guardarla de inmediato para futuros estudios y comparaciones. Por lo tanto, es importante evaluar la eficiencia y precisión de las técnicas ópticas en la monitorización de la fermentación del yogur, en comparación con los métodos tradicionales.

1.1. OBJETIVO GENERAL

Evaluar el grado de precisión de las técnicas ópticas *contactless*: visión por computador y termografía en la monitorización de las propiedades fisicoquímicas (viscosidad, acidez y pH) de la leche durante el proceso de fermentación.



1.2. OBJETIVOS ESPECÍFICOS

- Implementar un sistema de monitorización por imágenes de las características fisicoquímicas (viscosidad, color, acidez y pH) de la leche durante el proceso de fermentación mediante técnicas ópticas contactless: visión por computador y termografía.
- Monitorear mediante técnicas convencionales el efecto de la temperatura, porcentaje de proteína y la concentración del inóculo en las características fisicoquímicas (viscosidad, color, acidez y pH) y velocidad de gelificación de la leche durante el proceso de fermentación.
- Desarrollar modelos predictivos a partir de imágenes registradas mediante técnicas ópticas contactless: visión por computador y termografía para estimar las propiedades fisicoquímicas (viscosidad, acidez y pH) de la leche durante el proceso de fermentación en yogur.

CAPÍTULO II


REVISIÓN DE LITERATURA

2.1. SITUACIÓN ACTUAL Y PERSPECTIVA DE LA INDUSTRIA DEL YOGUR

En una encuesta que se llevó a cabo en 2012 en varios países, se analizó el consumo de productos lácteos. Según la encuesta realizada por Valentina & Fierro, (2020), la mayoría de los consumidores de estos productos están en Europa y Asia. Entre el 80% y el 89% de los encuestados en Turquía y Rusia afirmaron consumir productos lácteos como leche, yogur y queso. Brasil, un importante consumidor de yogur en Latinoamérica, tiene un 80% de respuestas positivas.

Figura 1

Consumidores habituales de productos lácteos



Nota: Valentina & Fierro, (2020)

El yogur, reconocido por sus propiedades probióticas, contribuye a mejorar la salud intestinal al reducir la población de bacterias dañinas y restablecer el equilibrio del microbiota (Tan et al., 2018). Sin embargo, el consumo de yogur en Perú es significativamente menor que en países vecinos como Chile y Colombia (Navarro et al., 2015). Esta baja ingesta, que se sitúa por debajo de las recomendaciones de la FAO de 1

a 5 porciones por persona al día, podría deberse a factores como el precio, la falta de variedad o la poca promoción de sus beneficios.

2.2. PROCESO DE ELABORACIÓN DEL YOGUR

2.2.1. Definición del yogur

El yogur es un derivado lácteo que se produce mediante la fermentación de la leche a temperaturas controladas cercanas a 40°C (Akarca & Denizkara, 2024; Yankey et al., 2023), con cultivos lácticos (*Lactobacillus bulgaricus* y *Streptococcus thermophilus*) que producen ácido láctico a partir de la lactosa, creando una estructura viscosa parecida a un gel (C. Chen et al., 2017). Debido a que las proteínas desnaturalizadas actúan como aglutinantes dentro de una matriz de caseína. La firmeza de gel depende principalmente de la fuerza de la red tridimensional de proteínas de la leche que a su vez está gobernada por el contenido total de sólidos (Sah et al., 2016a).

Este producto lácteo se puede elaborar a partir de leche de vaca, de cabra, de oveja, camella o yegua (Atamian et al., 2014). Existen diferentes formas de yogur, entre ellas: yogur bebible bajo en grasa o sin grasa, yogur con sabor a frutas y/o cereales. Además, el yogur se puede clasificar según su naturaleza física, que puede ser sólido, semisólido o líquido (Marete et al., 2024).

- **Clasificación del yogur**

- **Por su textura pueden ser:** un yogur batido cuya fermentación se realiza en tanques de incubación produciéndose en ellos la coagulación, siendo luego sometido a un tratamiento mecánico (batido). El yogur bebible recibe un mayor tratamiento mecánico que el yogur aflanado,

cuya fermentación y coagulación se produce en su envase (Lobato-Calleros et al., 2014).

- **Por su contenido graso:** la concentración láctea afecta significativamente la textura y las propiedades sensoriales del yogur según el contenido de grasa. Los yogures se clasifican en tres variedades principales: yogur descremado (<0.5 %), yogur bajo en grasa (0.5 – 2.0%) y yogur regular ($\geq 3.25\%$) (Y. Zhao et al., 2023).
- **Por sus ingredientes:** se clasifican según la fortificación prebiótica, mediante la adición de 30 % de ingredientes no lácteos con Notas ricas en fibra como frutas (yogur frutado), cereales y aromas (yogur aromatizado) o yogur natural sin adición de saborizantes ni colorantes. Estos ingredientes no lácteos pueden ser añadidos antes o después de la fermentación (Sah et al., 2016b).

- **Requisitos fisicoquímicos**

Según las NTP 202.092:2008 los requisitos fisicoquímicos del yogur entero, yogur parcialmente descremado y yogur descremando se muestran en la Tabla 1.

Tabla 1

Requisitos fisicoquímicos y tipos de yogur

Requisitos	Yogur entero	Yogur parcialmente descremado	Yogur descremado
Materia grasa % (m/m)	Mínimo 3.0	1.0 – 2.9	Menos de 1.0
Sólidos no grasos % (m/m)	Mínimo 8.2	Mínimo 8.2	Mínimo 8.2
Acidez, expresada en % de ácido láctico	0.6 – 1.5	0.6 – 1.5	0.6 – 1.5

Nota: NTP 202.092:2008

Este proyecto de tesis se enfocará principalmente en la monitorización de las propiedades fisicoquímicas de la leche durante la elaboración de yogur batido.

2.2.2. Principales etapas en la elaboración de yogur batido

La elaboración del yogur batido puede llevarse a cabo en un tanque operado de forma totalmente manual (agitación mecánica) o un tanque multipropósito que puede calentarse a vapor o gas. En la Figura 2, se muestran las principales etapas que implica el proceso de elaboración del yogur batido.

2.2.2.1. Recepción y selección de la materia prima

La recepción es una etapa clave en la producción de yogur batido, pues asegura la calidad del producto final. Aunque la leche bovina es la más utilizada, también pueden emplearse leches de otros mamíferos, como cabra, oveja o búfala, según las preferencias del mercado y las propiedades deseadas en el yogur (El-Abbadi et al., 2014).

Es esencial que la leche sea de alta calidad, verificando su composición, especialmente el contenido proteico, ya que este influye en la textura y estabilidad del yogur. Un nivel adecuado de proteínas asegura una coagulación uniforme durante la fermentación, contribuyendo a una consistencia óptima y mejor percepción sensorial.

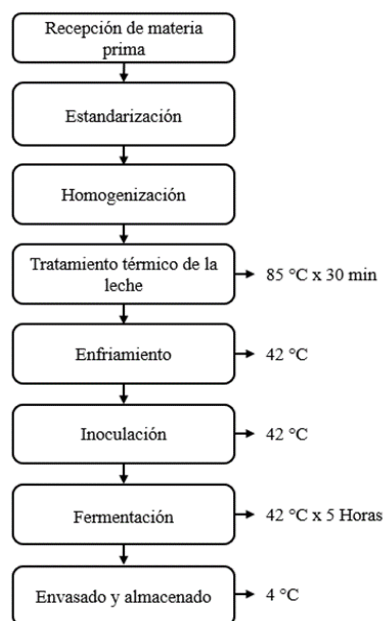
Además, la leche debe estar libre de bacterias patógenas, y de residuos indeseables, como antibióticos o pesticidas, también es esencial para garantizar la seguridad del consumidor y cumplir con las normativas alimentarias. Estas sustancias podrían inhibir la actividad de los cultivos iniciadores, afectando la fermentación y la calidad del yogur.

2.2.2.2. Estandarización

La estandarización de la leche, un proceso clave en la producción de yogur, implica ajustar los niveles de grasa entre 0.5% y 3.5%, y los sólidos no grasos entre 11% y 12% (Mahaut et al., 2003). Este ajuste puede lograrse mediante la adición de componentes como leche en polvo o suero, o la reducción de componentes como la grasa, agua y otros. En el caso del yogur, el contenido de grasa varía desde 0.1% hasta 10% y depende de las preferencias de los consumidores. La estandarización debe su importancia a los efectos que implica en el producto final, porque el contenido de grasa en la leche influye en las características del yogur; mejorando su consistencia y viscosidad. Además, afecta el comportamiento del pH en la fermentación (Sfakianakis & Tzia, 2014a).

Figura 2

Diagrama de elaboración de yogur batido




Nota: Torres et al. (2018)

2.2.2.3. Homogenización

La homogenización de la leche es un proceso estándar comúnmente aplicado en la industria láctea y sus derivados como el yogur (Sfakianakis et al., 2015). Este proceso de homogenización implica cambios microestructurales en el tamaño de los glóbulos de grasa, lo que resulta en el aumento de la superficie total lo que evita su afloramiento a la superficie por efecto de la diferencia de densidades. Además, mejora la interacción con las micelas de caseína y sus fragmentos, que participan activamente en la formación del gel y evitan la sinéresis del suero en el yogur, como se muestra en la Figura 3 (Y. Zhao et al., 2023). Sin embargo, la leche no homogenizada puede desestabilizar la estructura del yogur y reducir su viscosidad, debido a la baja interacción de los glóbulos de grasa y las redes de caseína (Jørgensen et al., 2019).

Figura 3

Esquema de la estructura del yogur establecido



Nota: Y. Zhao et al. (2023)

2.2.2.4. Tratamiento térmico

La etapa del tratamiento térmico es un proceso clave en la producción de yogur, debido a que no solo permite la destrucción de microorganismos patógenos indeseables, sino que catalizan diversos cambios fisicoquímicos que mejoran la calidad final del producto. Según Dash et al. (2022), este tratamiento inhibe la oxidación de la grasa y modifica las proteínas del suero, mejorando de forma significativa la textura del yogur.

Lindsay et al. (2021) proponen dos parámetros principales para la pasteurización del yogur: 85°C por 25 - 30 minutos o 90- 95°C durante 3- 5 minutos. Este tratamiento mejora las propiedades organolépticas y funcionales del yogur. Entre los beneficios destacan la potenciación del sabor característico, aumento de los aminoácidos libres, descenso del pH, reducción del tiempo de coagulación y la estabilización de la textura, evitando la sinéresis o la separación del suero (Deeth, 2017).

2.2.2.5. Enfriamiento

La etapa de enfriamiento después de la pasteurización permite reducir la temperatura de la leche a un rango óptimo entre 40 y 45°C, que es ideal para el crecimiento y actividad de las bacterias ácido lácticas, principalmente *Lactobacillus bulgaricus* y *Streptococcus thermophilus*. Estas bacterias son responsables de convertir la lactosa en ácido láctico, lo que acidifica la leche y facilita la coagulación para formar el yogur (Dash et al., 2022).

Este rango de temperatura garantiza que las bacterias se desarrollen de manera eficiente, lo que responde un equilibrio adecuado entre la acidez y el sabor del yogur, un enfriamiento adecuado es esencial para asegurar una fermentación homogénea y evitar problemas como la sinéresis (separación de suero) (Deeth, 2017).

2.2.2.6. Inoculación

La inoculación se lleva a cabo una vez que la temperatura de la leche se ha estabilizado en el rango óptimo de incubación, entre 40 y 45°C. En esta etapa, se añade el cultivo láctico compuesto principalmente por *Lactobacillus bulgaricus* y *Streptococcus thermophilus*, microorganismos que son responsables de la fermentación láctica (Dash et al., 2022). El cultivo se dosifica en una proporción que varía entre el 1% y el 3%, manteniendo una agitación constante durante 5 minutos. Este porcentaje puede ajustarse según la actividad de los cultivos, oscilando entre el 1% y el 7%, para asegurar una fermentación eficiente. La relación entre *Streptococcus* y *Lactobacillus* se ajusta entre 1:2 y 2:1, dependiendo del tipo de yogur que se desee producir, ya sea natural o batido (Sfakianakis & Tzia, 2014b).

2.2.2.7. Fermentación

El proceso de fermentación es crucial para la producción de yogur, ya que en esta etapa se desarrollan sus características de textura y sabor distintivo. Durante la fermentación, ocurren reacciones bioquímicas provocadas por el metabolismo de dos cultivos lácticos vivos *Streptococcus subsp. thermophilus* y *Lactobacillus delbrueckii subsp.*



bulgaricus, que se encargan de transformar la lactosa de la leche en ácido láctico. Este proceso ocurre a una temperatura de entre 40 y 45°C durante un periodo de 150 a 210 minutos. El objetivo de esta etapa es incrementar el contenido de la acidez hasta valores de 100 a 120 °D y pH de 4.6 (punto isoeléctrico) en los yogures (Mahaut et al., 2003). En este punto, comienza a formarse el coagulo debido a la precipitación de la caseína (Mazzeo, 2007).

2.2.2.8. Envasado y almacenado

El envasado y almacenado del yogur son etapas cruciales para conservar la calidad, textura y vida útil del producto final. El yogur batido se caracteriza por ser un producto más cremoso y homogéneo, con una consistencia suave que se obtiene mediante un proceso de agitación controlada después de la fermentación (Jørgensen et al., 2015).

El almacenamiento del yogur debe mantenerse refrigeradas a una temperatura de 4 a 8°C para garantizar la estabilidad del producto, alargar la vida útil del yogur batido que generalmente es de 2 a 4 semanas. Durante el almacenamiento, el pH del yogur puede seguir disminuyendo ligeramente debido a la actividad residual de las bacterias ácido - lácticas (Deeth, 2017).

2.3. FERMENTACIÓN DE LA LECHE HASTA SU CONVERSIÓN EN YOGUR

La fermentación del yogur es un proceso complejo que depende de la acción de bacterias ácido - lácticas, las cuales transforman la leche en un producto fermentado con características específicas. Durante esta fase, los microorganismos clave son



Streptococcus thermophilus y *Lactobacillus bulgaricus*, desencadenan una serie de reacciones bioquímicas esenciales para la formación del yogur (Walstra et al., 2005). Estas bacterias trabajan en sinergia, contribuyendo mutuamente al desarrollo de la acidez como a la textura del producto final. A continuación, se detallan las condiciones óptimas para el crecimiento y la actividad de estas bacterias en el proceso de elaboración del yogur.

- ***Streptococcus salivarius subsp. thermophilus***

Este microorganismo es Gram positivo y generalmente se considera termófilo, ya que la temperatura óptima para su crecimiento es de 35 a 53°C. Sus células son de forma esférica que forman cadenas, durante la etapa temprana de sus vidas y a medida que maduran desarrollan una morfología más parecida a una varilla y favorecen el crecimiento colonial de las bacterias (Walstra et al., 2005).

- ***Lactobacillus delbrueckii subsp. bulgaricus***

Por otro lado, el *Lactobacillus delbrueckii subsp. bulgaricus* es una bacteria anaerobia gran positiva en forma de bastoncillo y su temperatura óptima de crecimiento es de 40 a 44°C, lo que le permite producir cantidades muy altas de ácido láctico metabolizando la lactosa (Vedamuthu, 2013).

Tabla 2


Características principales de las bacterias ácido - lácticas para la producción de yogur

Microorganismos ácido-lácticos	Tipos de bacterias	Características	Temperatura en que se desarrolla	Función
<i>Streptococcus thermophilus</i>	Estreptococo Gram-positivo	Bacteria no móvil, anaerobio facultativo	35- 53°C, puede resistir incluso 65° C por media hora	Utiliza la lactasa para descomponer la lactosa de los productos fermentativos
<i>Lactobacillus bulgaricus</i>	Bacilo Gram-positivo	Bacteria láctea homofermentativa	40- 44°C	Disminuye el pH y puede producir hasta un 2.7% de ácido láctico.

Nota: Walstra et al. (2005)

Estos dos microorganismos se desarrollan de manera sinérgica, metabolizando la lactosa en ácido láctico y provocando la reducción del pH de la leche a medida que la fermentación avanza. Esta reducción de pH ocurre debido a la conversión de lactosa en ácido láctico, en orden de la siguiente reacción química global:

Formula de la reacción de la lactosa a ácido láctico:



2.3.1. Mecanismos de acción de los microorganismos en la fermentación

2.3.1.1. Metabolismo de la lactosa

La transformación de la lactosa en ácido láctico durante la fermentación del yogur se lleva a cabo principalmente a través de la fermentación homoláctica, que sigue la ruta metabólica de Embden - Meyerhof - Parnas (glucólisis) para convertir la glucosa en ácido láctico.




Las bacterias lácticas involucradas, como *Streptococcus salivarius subsp. thermophilus* y *Lactobacillus delbrueckii subsp. bulgaricus*, metabolizan la glucosa derivada de la hidrólisis de la lactosa a través de este proceso. La vía de Leloir, responsable del metabolismo de la galactosa, también puede participar indirectamente en la fermentación al convertir la galactosa en glucosa-6-fosfato, que luego entra en la glucólisis (Tala Orrillo, 2023). La fermentación homoláctica para las bacterias ácido lácticas consta de tres fases:

- **Primera fase: Descomposición de la lactosa**

Según Tala Orrillo, (2023) esta fase comienza con la hidrólisis de la lactosa en el interior de la célula, catalizada por la enzima β - galactosidasa, también conocida como lactasa, que descompone la lactosa en glucosa y galactosa. La glucosa entra en la vía de Embden - Meyerhof - Parnas (glucólisis), donde, a través de una serie de reacciones de fosforilación, se obtienen una molécula de gliceraldehído-3-fosfato (G3P) y una de dihidroxiacetona fosfato (DHAP) por cada molécula de glucosa. La triosa fosfato isomerasa convierte el DHAP en otra molécula de G3P, permitiendo que ambas moléculas sigan en la glucólisis. Por otro lado, la galactosa es metabolizada mediante la vía de Leloir, donde es fosforilada para formar galactosa-1-fosfato, que luego se convierte en glucosa-1-fosfato y, finalmente, en glucosa-6-fosfato, que ingresa en la glucólisis para producir gliceraldehído-3-fosfato.

Figura 4

Primera fase de la fermentación homoláctica para S. thermophilus y L. bulgaricus



Nota: Tala Orrillo (2023)

(A): β -galactosidasa

(B): Glucoquinasa

(C): Fosfoglucosa isomerasa

(D): Fosfofructoquinasa

(E): Fructosa- 1, 6-P aldolasa

(F): Triosa fosfato isómeras

• Segunda fase: Oxidación y producción de ATP

Durante esta fase del glicólisis, el gliceraldehído-3-fosfato formado en la fase anterior se oxida por la acción de la enzima gliceraldehído-3-fosfato deshidrogenasa, utilizando el cofactor NAD^+ (Nicotinamida Adenina Dinucleótido en su forma oxidada). Esta reacción produce 1,3-bisfosfoglicerato y reduce NAD^+ a NADH. Luego, el 1,3-bisfosfoglicerato transfiere un grupo fosfato a una molécula de ADP para generar ATP, mediante la acción de la fosfoglicerato quinasa, formando 3-fosfoglicerato. Posteriormente, el 3-fosfoglicerato se reordena para formar fosfoenolpiruvato (PEP) en una serie de pasos catalizados por la enolasa. Finalmente, el PEP transfiere otro grupo fosfato al ADP, generando una

molécula adicional de ATP y formando piruvato mediante la acción del piruvato quinasa. Este proceso genera energía para la célula, como se muestra en la Figura 5.

Figura 5

Segunda fase de la fermentación homoláctica para S. thermophilus y L. bulgaricus



Nota: Walstra et al. (2005)

(A): 1,3-P-glicerato

(B): Fosfoglicerato quinasa

(C): Fosfoglicerato mutasa

(D): Enolasa

(E): Piruvato quinasa


• Tercera fase: Producción de energía y reducción

El gliceraldehído-3-fosfato es oxidado y fosforilado por la enzima gliceraldehído-3-fosfato deshidrogenasa, formando 1,3-bisfosfoglicerato y produciendo NADH en el proceso. Posteriormente, el 1,3-bisfosfoglicerato cede un grupo fosfato al ADP, generando dos moléculas de ATP por cada molécula de gliceraldehído-3-fosfato a través de la fosforilación a nivel de sustrato. Finalmente, el piruvato resultante es reducido a ácido láctico (lactato) mediante la enzima lactato deshidrogenasa bajo condiciones anaeróbicas, utilizando el NADH

previamente formado, lo que regenera NAD^+ y permite la continuidad del proceso de fermentación láctica.

Figura 6

Tercera fase de la fermentación homoláctica para S. thermophilus y L. bulgaricus.



Nota: Vedamuthu (2013)

(A): Lactato deshidrogenasa


Con respecto a la galactosa, la vía metabólica de Leloir detalla el proceso mediante el cual este monosacárido, liberado tras la hidrólisis de la lactosa por acción de la enzima β -galactosidasa, se transforma en glucosa-1-fosfato, una clave intermedia en el metabolismo energético. Este proceso, conocido como galactólisis, inicia con la fosforilación de la galactosa en el carbono 1, catalizada por la enzima galactoquinasa, que produce galactosa-1-fosfato. Posteriormente, la enzima galactosa-1-fosfato uridiltransferasa transfiere un grupo uridina difosfato (UDP) desde la UDP-glucosa a la galactosa-1-fosfato, generando UDP-galactosa y glucosa-1-fosfato. Este último compuesto es convertido en glucosa-6-fosfato por la enzima fosfoglucomutasa, permitiendo su entrada en la vía de la glucólisis, donde contribuye a la generación de energía celular.

Además, la UDP-galactosa producida es reciclada en UDP-glucosa mediante la acción de la enzima UDP-galactosa 4-epimerasa, asegurando la continuidad del ciclo de interconversión entre galactosa y glucosa. Este mecanismo no solo es fundamental para el metabolismo de los

carbohidratos, sino también para garantizar la eficiencia en la utilización de la lactosa como Nota de energía. Alteraciones en esta vía, como deficiencias en las enzimas involucradas, pueden derivar en trastornos meta.

Figura 7

Ruta metabólica de Leloir



Nota: Vedamuthu (2013)

(A): Galactoquinasa

(B): Galactosa -1-P uridiltransferasa

(C): UDP- glucosa 4-epimerasa

(D): Fosfoglucomuta

Seguido de todo este proceso, las bacterias ácido lácticas poseen la enzima lactato deshidrogenasa para la síntesis de lactato a partir de piruvato (Vedamuthu, 2013). Sin embargo, la disminución de la tensión de oxígeno y el formiato (subproducto del metabolismo del *Streptococcus thermophilus*) estimula a su vez el crecimiento del *Lactobacillus bulgaricus* lo que se explica la simbiosis de las bacterias.

2.3.1.2. Simbiosis de las bacterias ácido lácticas

Los microorganismos *Streptococcus subsp. thermophilus* y *Lactobacillus delbrueckii subsp. bulgaricus* al ser inoculados



individualmente en la leche, demandan mayor tiempo de coagulación entre 8 y 10 horas. Sin embargo, al ser inocularlos en conjunto y a una temperatura de entre 40 - 45°C, el tiempo se reduce significativamente a 3 - 4 horas (Sfakianakis & Tzia, 2014a), este fenómeno demuestra la simbiosis de las bacterias ácido-lácticas para convertir la lactosa en ácido láctico. Según Courtin et al. (2002) afirma que, en condiciones anaeróbicas el *Streptococcus subsp. thermophilus* produce ácido fórmico para estimular el crecimiento de *Lactobacillus delbrueckii subsp. bulgaricus*, lo que acelera su desarrollo.

En esta interacción, *Lactobacillus delbrueckii subsp. bulgaricus* promueve el desarrollo y crecimiento de *Streptococcus subsp. thermophilus* al liberar aminoácidos esenciales (como valina, histidina y glicina) de la caseína, lo que acelera su desarrollo. El *Streptococcus subsp. thermophilus* tiene un desarrollo más rápido al inicio de la fermentación, comenzando con la producción de ácido láctico. En una segunda etapa, este microorganismo es inhibido por el propio ácido láctico producido, y la fermentación del yogur es continuada y finalizada por *Lactobacillus delbrueckii subsp. bulgaricus*. La velocidad de crecimiento de *Streptococcus subsp. thermophilus* al inicio de la fermentación es superior a la de *Lactobacillus delbrueckii subsp. bulgaricus*, con una proporción de 3 o 4:1 después de la primera hora de incubación. Posteriormente, en la última etapa, esta relación se aproxima a 1:1 (Vedamuthu, 2013).

Los cultivos liofilizados de yogur suelen presentar fases de latencia prolongados, lo que hace necesario sembrarlos al menos dos veces para obtener cultivos líquidos activos. Sin embargo, se han desarrollado


cultivos concentrados liofilizados que pueden ser utilizados directamente para inocular la leche, facilitando la fabricación de yogur a pequeña escala (Tribby & Teter, 2023).

- **Fases de crecimiento microbiano durante la fermentación del yogur**

Durante la fermentación de la leche provocada por los microorganismos *Streptococcus subsp. thermophilus* y *Lactobacillus delbrueckii subsp. bulgaricus* ocurre el siguiente crecimiento microbiano provocando diferentes ocurrencias a nivel molecular y reorganización de la estructura de la leche (Muncan et al., 2020).

Figura 8

Curva de crecimiento bacteriano



Nota: Muncan et al. (2020)

La curva de crecimiento bacteriano (Figura 8) se desarrolla pasando por las siguientes fases:



- **Fase de latencia**

Durante la fase de latencia, existe un aparente estado de reposo, en la que las células sintetizan enzimas necesarias para sus funciones metabólicas, no se observa cambio significativo. Sin embargo, internamente las células están activas, ajustando un proceso enzimático al entorno del cultivo láctico. En este tiempo, la bacteria se adapta para aprovechar los nutrientes del medio, lo que provoca un aumento en la masa celular. La duración de la latencia puede verse afectada por la edad del inóculo, ya que los inóculos más antiguos tienden a prolongarla debido a la acumulación de sustancias tóxicas y la falta de nutrientes esenciales después del crecimiento previo (Nugroho et al., 2021).

- **Fase exponencial o logarítmica**

Pasado la fase de latencia, el cultivo láctico entra en la denominada fase de crecimiento exponencial, donde los microorganismos se proliferan de una forma muy rápida. La velocidad de crecimiento que alcanza el cultivo depende de los microorganismos y factores ambientales como son la temperatura, el pH, oxigenación, etc. (Nugroho et al., 2021).

- **Fase estacionaria**

La velocidad de crecimiento comienza a disminuir hasta hacerse nula cuando alcance la fase estacionaria, debido a los cambios en la composición y concentración de nutrientes el medio, desencadenando el control y la regulación de la actividad enzimática (Muncan et al., 2020).

Durante la fase estacionaria se observan la sobrepoblación de las bacterias que provoca el agotamiento de suministros esenciales,

acumulación de productos a niveles tóxicos, disminución de oxígeno, cambios en las condiciones del pH del medio de cultivo (acidificación). Equilibrando el número de células nuevas con el número de células que mueren (Lindsay et al., 2021).

- **Fase de muerte**

Finalmente, el cultivo entra en la fase de muerte, en la cual el número de células que mueren aumenta progresivamente. La inclinación de esta fase puede variar en función del tipo de microorganismo, siendo menos pronunciada cuando los microorganismos tienen mecanismos de resistencia, como esporas o glicocálix (Muncan et al., 2020).

2.3.1.3. Acidificación y coagulación

La actividad bacteriana durante la fermentación de la leche para la obtención del yogur incrementa la concentración del ácido láctico a valores comprendidos entre el 0.6 y el 1.5%, bajo esas condiciones de acidez, las proteínas de la leche especialmente la caseína comienza a agregarse y precipitar formando redes tridimensionales, esta estructura se percibe un gel que le atribuye al yogur su textura cremosa y masa densa (Rodríguez-Bernal et al., 2014).

2.3.2. Cambios en las propiedades fisicoquímicas durante la fermentación


2.3.2.1. Comportamiento del pH en la fermentación de la leche

El pH de la leche generalmente varía entre 6.5 y 6.7 (Walstra et al., 2005). Sin embargo, cuando la leche pasa por un proceso prolongado de fermentación, se convierte en yogur debido al descenso del pH a valores

entre 4.0 y 4.5 (Rivero Martin et al., 2020). Como se muestra en la Figura 9, este parámetro es una de sus características más importantes, ya que la fermentación inducida por bacterias ácido - lácticas incrementa la concentración de acidez y reduce el pH, mejorando las propiedades fisicoquímicas y las cualidades sensoriales, lo que lo hace más atractivo para el consumidor (Rodríguez et al., 2015).

Figura 9

Curva de pH del yogur durante la fermentación



Nota: Muncan et al. (2020)

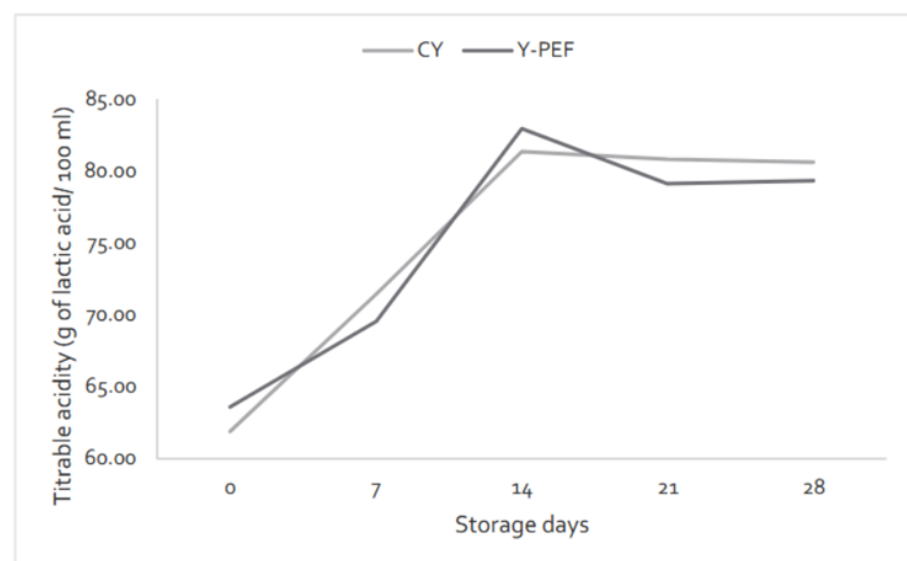
2.3.2.2. Acidez

La concentración de la acidez está directamente relacionada con la actividad metabólica y la tasa de crecimiento de los microorganismos responsables, la transformación de la lactosa en ácido láctico por el metabolismo de las bacterias, la concentración de la acidez entre 0.6 – 1.5 % induce cambios fisicoquímicos y microestructurales en la leche como la coagulación de la caseína, la formación de la textura, el sabor del producto y garantiza la calidad con las características sensoriales y estructurales deseadas. Además, tiene la capacidad de prevenir la sinéresis del suero (Alcivar Pelaez, 2016), lo que destaca la importancia de su monitoreo

durante la producción (Sofyan et al., 2022a; Yang et al., 2021a). Para medir la acidez, se utilizan unidades como el °D, donde cada equivalente representa un decigramo de ácido láctico por litro. Por ejemplo, si una leche tiene 17 °D, significa que su concentración de acidez es de 0.17 gramos por cada 100 gramos de leche (Miranda Mejía, 2022).

Figura 10

Desarrollo de la curva de acidez durante el proceso de fermentación



Nota: Miranda Mejía (2022)

2.3.2.3. Viscosidad y gelificación

La viscosidad y gelificación del yogur son propiedades estructurales clave que determinan la textura y aceptabilidad del producto final. La viscosidad en el yogur mide su resistencia a la deformación, esta propiedad física incrementa con mayor rapidez a medida que el pH desciende hasta el punto isoeléctrico ($\text{pH} < 5.2$) (Haque et al., 2001). La temperatura tiene un efecto significativo sobre la viscosidad del yogur ya que disminuye cuando la temperatura incrementa y viceversa. También

factores como el contenido de grasa, la estructura de la caseína, los tamaños de los glóbulos de grasa, la temperatura de incubación y la velocidad de enfriamiento influyen en la viscosidad final del yogur (Gilbert & Turgeon, 2021). Por otro lado, es importante aclarar que el yogur es un fluido no newtoniano, lo que significa que su viscosidad no es constante y cambia dependiendo del esfuerzo aplicado, un comportamiento conocido como adelgazamiento por cizallamiento (Lee & Lucey, 2006).

El yogur también presenta propiedades tixotrópicas, es decir, su viscosidad disminuye con el tiempo cuando se somete a una fuerza o esfuerzo cortante (Mendoza et al., 2021), pero recuperan su viscosidad inicial al dejar de aplicarse la fuerza. Esto hace que la manipulación y agitación del yogur afecten temporalmente su textura (Jørgensen et al., 2015).

La gelificación de la leche, por otro lado, es el proceso mediante el cual la leche pasa de ser un fluido a uno semisólido. Lo cual ocurre principalmente por efecto de la concentración de la acidez y reducción del pH que provocan la coagulación de las proteínas, como la caseína, durante el proceso de fermentación (Sodini et al., 2004).

- **Proteínas**

Las proteínas desempeñan un papel importante en la formación del gel durante el proceso de elaboración de yogur. Entre las principales proteínas involucradas están las caseínas y las proteínas de suero, las cuales tienen una función importante en la estructura del gel. Las



interacciones entre estas proteínas están influenciadas por el pH ya que reduce las fuerzas electrostáticas de repulsión entre las micelas de caseína favoreciendo la formación de textura y estabilidad del producto final (Arab et al., 2023).

Un aumento en el contenido de proteínas, particularmente en relación con los sólidos totales, mejora la elasticidad del gel, lo que reduce la posibilidad de ruptura y mejora las propiedades de textura. Además, al incrementar los niveles de proteína, se refuerza la firmeza del gel y se reduce la sinéresis, que es la separación de suero del yogur (Zhao et al., 2016).

- **Grasa**


La leche contiene típicamente entre un 2.5% y un 3% de grasa, mientras que, en el yogur, la proporción de grasa varía dependiendo del tipo de producto. Los yogures enteros presentan un contenido graso más elevado, mientras que los descremados tienen niveles significativamente más bajos. Curiosamente, los yogures descremados suelen exhibir una mayor firmeza y viscosidad en comparación con los enteros, debido a los ajustes en la composición de sólidos y la redistribución de proteínas en ausencia de grasa.

Por otro lado, la adición de sustitutos de grasa en los yogures bajos en grasa puede influir significativamente en su textura, mejorando características como la cremosidad, pero también puede inducir efectos no deseados, como la sinéresis del suero, fenómeno que afecta la estabilidad estructural del producto. Este equilibrio entre composición, textura y

calidad es crucial en el diseño de yogures con contenido graso reducido, ya que busca satisfacer tanto las demandas del consumidor como los estándares tecnológicos (Clark et al., 2019).

Figura 11

Evolución del pH y la viscosidad en función al tiempo durante la fermentación de la leche



Nota: Muncan et al. (2020)

2.4. TÉCNICAS DE CONTROL PARA EL MONITOREO DE LA FERMENTACIÓN

Durante la fermentación del yogur, se monitorean varios parámetros fisicoquímicos que afectan su calidad y características finales (Ruales, 2012). Entre ellos incluyen el pH, acidez y otros que son cruciales para la formación del gel y la estabilidad del producto.

2.4.1. pH

El pH es un parámetro directamente relacionado con la concentración de ácido en un sistema, ya que un incremento en la acidez provoca una disminución



en el valor de pH. Esta relación inversa hace del pH una herramienta fundamental para monitorear y controlar el proceso de fermentación de la leche. Durante la fermentación, el descenso gradual del pH refleja el progreso de la actividad metabólica de los microorganismos, que producen ácido láctico a partir de los azúcares presentes en la leche.

El pH no solo indica el avance de la fermentación, sino que también es crucial para garantizar la calidad y seguridad del producto final. En este contexto, el proceso de fermentación se da por concluido al alcanzar un pH de 4.6, ya que este valor marca el punto isoeléctrico de las proteínas de la leche, principalmente la caseína, lo que resulta en su coagulación. Fijar este umbral asegura la consistencia adecuada del producto, inhibe el crecimiento de microorganismos indeseables y contribuye a la estabilidad del yogur, factores esenciales para un producto final seguro y de alta calidad (Sözeri Atik et al., 2023).

El pH mide la concentración de hidrogeniones (H^+) libres y se expresa como el grado de acidez o alcalinidad de una sustancia en una escala que va de 0 a 14, donde 7 representa un pH neutro, como el del agua (H_2O). Valores por encima a 7 señalan alcalinidad, mientras que valores por debajo indican acidez, como ocurre en el yogur. La medición del pH en el proceso de fermentación del yogur se realiza mediante métodos tradicionales y comúnmente utilizado en la industria. Este procedimiento suele llevarse de manera intermitente (Liu et al., 2024), utilizando el electrodo de un potenciómetro, conocido por su confiabilidad a nivel de laboratorio. Posteriormente aparecieron los sensores de vidrio, que han sido prohibidos en los últimos años por los peligros de ruptura en las líneas de producción. También, se han desarrollado sensores electrónicos (Figura 12), sensores de retrodispersión de luz infrarroja y entre otras técnicas modernas

(Arango et al., 2020). Todas estas herramientas disponen de una alta precisión y rapidez en la evaluación; sin embargo, tienen la desventaja por la necesidad de ser incorporados en las paredes de los tanques de fermentación que, si no son adecuadamente desinfectados antes y después de la producción, podría contribuir a una contaminación cruzada (Jiménez et al., 2004).


Figura 12

Potenciómetro digital de sobremesa



2.4.2. Acidez

La determinación de la acidez en la leche generalmente se realiza mediante empleando un acidímetro (Figura 13) y con una valoración ácido-base, que implica una reacción de neutralización. Esta técnica de medición de acidez por colorimetría es un método tradicional lento y laborioso. En la leche, el ácido láctico reacciona con una base fuerte como el hidróxido de sodio (NaOH), formando lactato de sodio y agua (Schütterle et al., 2024). Esta reacción se puede representar como:



El punto en que todo el ácido láctico se neutraliza se observa cuando la fenolftaleína añadida genera una coloración turquesa lo que se conoce como el punto final de la titulación, y permite calcular la acidez de la leche, que comúnmente se expresa en grados °D.

Figura 13

Equipo para la determinación de acidez



2.4.3. Viscosidad y consistencia

Para la medición de viscosidad, como menciona (Jiménez et al., 2004), se utiliza un viscosímetro digital que permite obtener mediciones de viscosidad y torque a distintas velocidades de giro (0 - 100 rpm). Este enfoque, basado en la extracción de muestras y en la medición del torque a diversas velocidades, es esencial en fluidos complejos que presenten comportamientos no Newtonianos, en los cuales la viscosidad varía en función de la velocidad de corte (Najgebauer-Lejko et al., 2020). Para medir esta propiedad se emplean métodos de medición que implican el contacto y muestreo con los viscosímetros:

- **Viscosímetro capilar**

El método se basa en medir el tiempo que un fluido tarda en atravesar un tubo capilar (Figura 14) bajo la influencia de la gravedad, lo que permite calcular su viscosidad cinemática. Es especialmente adecuado para fluidos de baja viscosidad, como agua, leche o cartuchos, debido a su simplicidad y precisión en estos rangos. Sin embargo, presenta limitaciones significativas cuando se aplica a fluidos más complejos, como emulsiones o suspensiones, o a aquellos con alta viscosidad, donde factores como el comportamiento no newtoniano o la presencia de partículas pueden afectar la confiabilidad de los resultados. Por ello, para fluidos más densos o con propiedades reológicas particulares, es necesario emplear métodos alternativos que ofrezcan mayor sensibilidad y capacidad para caracterizar estas propiedades con precisión. (X. Wang et al., 2023).

Figura 14

Viscosímetro capilar



- **Viscosímetro rotacional**

Similar al viscosímetro capilar usado por Jiménez et al., (2004), este equipo (Figura 15) mide la resistencia al movimiento de un cuerpo sólido inmerso en un fluido. Es especialmente útil para medir fluidos tanto de baja como de alta

viscosidad, incluidos aquellos que presentan comportamiento no Newtoniano, donde la viscosidad depende de la velocidad de corte aplicada (Sözeri Atik et al., 2023).

Figura 15

Viscosímetro rotacional



2.4.4. Color

El color es un parámetro físico que expresa la calidad del yogur e influye en la aceptabilidad del producto por parte del consumidor. Es una de las primeras características percibidas y desempeñan un papel importante en la evaluación sensorial de los alimentos (Ścibisz et al., 2019a). Los consumidores utilizan el color como un indicador de la frescura, calidad y atractivo del producto.

Para medir el color se emplea un colorímetro previamente calibrado (Figura 16), midiendo la reflectancia de la muestra. En este proceso se extraen muestras de yogur y se colocan en un recipiente de cuarzo transparente, lo que permite el paso de luz. A partir de esto se obtiene los parámetros (L^* , a^* , b^*) de la escala de Hunter, donde L^* representa la luminosidad, a^* el tono rojizo y verdoso y b^* el tono amarillento o azulado (Daszkiewicz et al., 2024).

Por otro lado, se puede realizar la medición del color en la escala CIELab utilizando un espectrofotómetro, donde los valores de luminosidad (L^*), enrojecimiento (a^*) y amarillez (b^*) se miden empleando una cubeta de vidrio con muestra a una temperatura de aproximadamente 20°C . Según Daszkiewicz et al. (2024), este análisis permite una evaluación precisa del color en el yogur natural, para calcular el croma se utiliza la Ecuación 1 que está dada por:

$$C^* = (a^{*2} + b^{*2})^{1/2} \quad \text{Ec. (1)}$$

Donde C^* es la croma, a^* y b^* es el componente de color de la escala CIELab.

Figura 16

Colorímetro digital de sobremesa



2.4.5. Temperatura

La temperatura es otro parámetro de control que influye significativamente en el desarrollo de las bacterias ácido - lácticas, por ende, tiene un efecto significativo sobre la calidad del yogur y el tiempo necesario de fermentación, significa que a menor temperatura es mayor el tiempo necesario para completar la fermentación (Sofyan et al., 2022a; Yang et al., 2021a). Para el control de la



temperatura generalmente se emplean sensores resistivos de contacto, que son sumergidos o incrustados en las paredes internas de los equipos de fermentación, pero el uso de sensores termográficos por su ventaja de ser no invasivos se viene implementando para la monitorización de la temperatura en los procesos de producción del yogur (Bahmani et al., 2024; Kayacan Çakmakoglu et al., 2024).

En referencia a los parámetros de control del proceso de fermentación del yogur se puede afirmar que son métodos de cuantificación que permite evaluar las propiedades fisicoquímicas del yogur, como el pH, acidez titulable, color, viscosidad y temperatura, las técnicas convencionales empleadas para el control de dichos parámetros generalmente requieren de muestreo a excepción del control de la temperatura. Esta necesidad de muestreo conduce a riesgos potenciales de contaminación o alteración del proceso de fermentación, lo cual tiene implicaciones importantes en términos de precisión, representatividad y cantidad de producto final.

2.5. MÉTODOS ÓPTICOS DE CUANTIFICACIÓN APLICADOS EN LA INDUSTRIA LÁCTEA: VISIÓN POR COMPUTADOR Y TERMOGRAFÍA

En la última década, la industria alimentaria ha experimentado un crecimiento significativo en el desarrollo y adopción de métodos no invasivos para evaluar la calidad (Prasad, 2015). Existen numerosos ejemplos documentados sobre de uso de visión por computador y tecnología termográfica en este sector (Walsh et al., 2020). Una de las áreas de interés es el uso de cámaras digitales para medir el color en imágenes, que presentan ventajas como una resolución ajustable y un costo más bajo en comparación con los instrumentos tradicionales.

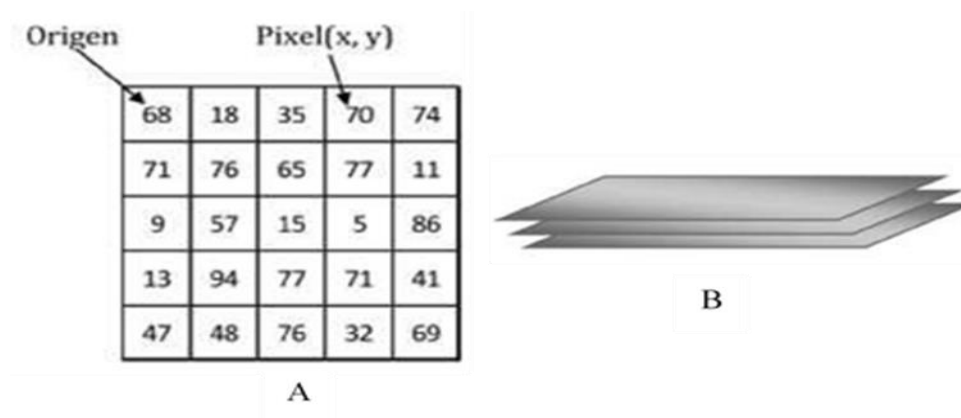
2.5.1. Visión por computador

Según Nixon & Aguado, (2019) una imagen se define como una función bidimensional $I(x, y)$, donde (x, y) son coordenadas espaciales que definen un plano. La amplitud de I en cualquier par (x, y) se denomina intensidad o nivel de gris en ese punto de la imagen. Cuando (x, y) toman valores discretos como la intensidad, se obtiene una imagen digital. A cada punto identificado por el par (x, y) se le llama píxel, que es la unidad mínima de la imagen. A cada píxel se le asigna un número que representa el brillo promedio; un número bajo indica baja luminosidad y un número alto indica alta luminosidad.

Actualmente, se ha logrado incorporar más detalles en las imágenes, permitiendo que una imagen contenga más de un espectro. La Figura 17 muestra los tres espectros que forman una imagen en color RGB. Para cada píxel, se registran los niveles correspondientes a la intensidad de luz de cada color: rojo (R), verde (G) y azul (B), que conforman el espacio de color RGB (Red, Blue, Green) (Velho et al., 2009).

Figura 17

(A) Estructura de una imagen digital; (B) Imagen digital en espacio de color RGB





2.5.1.1. Aplicaciones de la visión por computador en la industria alimentaria

En el ámbito de la ciencia agrícola, la visión por computador está abarcando áreas de control de calidad, eficiencia y seguridad de los productos. En control de la calidad de los alimentos, las cámaras y algoritmos permiten detectar imperfecciones en frutas, verduras y alimentos procesados. Asimismo, esta tecnología evalúa la frescura de los alimentos mediante procesos automatizados, abarcando desde la postcosecha, cosecha, procesamiento y almacenamiento (Ma et al., 2024).

2.5.1.2. Visión por computador en la industria láctea

En la era actual, la industria láctea se encuentra inmersa en la transición hacia la Industria 4.0, donde la adopción de dispositivos inteligentes interconectados está transformando significativamente la actividad industrial (Konstantinidis et al., 2022, 2023). En este contexto tecnológico, la visión por computadora juega un rol esencial para que el sistema virtual interactúe con el entorno real (Javaid et al., 2022).

La adopción de la visión por computadora en la industria láctea responde a la necesidad de controles continuos y estrictos de los parámetros de calidad y producción de la leche y sus derivados (Silva & Rocha, 2022). Además, se debe a las significativas limitaciones que presentan los métodos tradicionales para aplicaciones cotidianas *in situ* que demanda el sector lácteo (Loddo et al., 2022; Pérez-Calabuig et al., 2023). Aunque estos métodos tradicionales como la espectrometría, espectrofotometría (Silva & Rocha, 2022), espectroscopía (Alvarado et al.,



2022a; Pradana et al., 2022; Silva et al., 2021), fotometría y biosensor potenciométrico (Gonçalves et al., 2024) son precisos, pero suelen ser lentos, invasivos y requieren una infraestructura compleja, personal altamente calificado, además el uso de reactivos nocivos para el medio ambiente.

La implementación y desarrollando de la visión por computador y las técnicas de procesamiento de imágenes, se percibe como una alternativa bastante fiable para afrontar los retos planteados a las metodologías existentes dentro de un contexto de la industria láctea que demanda mayor versatilidad (Minz & Saini, 2021a, 2021b). Además, la visión por computador ya se fue aplicando para las mediciones de propiedades de lubricación (H.-H. Wang & Sun, 2004b), fusión (Everard et al., 2005) y dorado (H.-H. Wang & Sun, 2001) del queso durante su cocción, sus resultados han demostrado efectividad y múltiples ventajas que motivaron su rápido desarrollo y el desarrollo de diferentes técnicas de procesamiento y análisis de imágenes (Zhu et al., 2021).

La visión por computador se fortaleció con la incorporación de modelos de aprendizaje automático como las redes neuronales (Janke et al., 2019). Esto se debe a que las redes neuronales tienen la capacidad de establecer regresiones no lineales entre los parámetros de imágenes digitales y propiedades fisicoquímicas reales del objeto en estudio (Huang et al., 2007). Se documentaron exitosas aplicaciones de la visión por computador junto a las redes neuronales en la estimación de propiedades físicas de productos lácteos (Sofu & Ekinci, 2007) y en la detección de residuos de antibióticos en la leche (Urapen & Masawat, 2015).



El desarrollo más significativo de la visión por computador fue con la llegada de las redes neuronales convolucionales del aprendizaje profundo, que ejecuta de forma automática las tareas de extracción de características de las imágenes y la correlación con los parámetros del objeto en estudio (Janke et al., 2019; Pradana et al., 2022). Sus aplicaciones permiten el control de trazas de melamina en yogures (Pérez-Calabuig et al., 2023) y también en leche en polvo (Pradana et al., 2022) con una precisión que supera el 95%.

El desarrollo de modelos inteligentes de procesamiento y análisis de datos han mejorado significativamente la eficacia de la visión por computador en tareas de monitoreo de procesos y control de calidad en la industria láctea (Sofu & Ekinici, 2007). Paralelamente, el interés de los investigadores se ha orientado hacia el uso de teléfonos inteligentes, debido a su adaptabilidad y portabilidad, para la detección de adulterantes (R. A. Costa et al., 2020; Lima et al., 2020; Silva et al., 2021) y residuos de antibióticos (Maroubo et al., 2021; Masawat et al., 2015). Muchas de estas investigaciones han empleado herramientas como PhotoMetrix® e ImageJ® para el procesamiento de imágenes y la detección de variaciones de colores (Gonçalves et al., 2024). En el futuro, se espera que sea posible determinar la calidad y composición de los alimentos de manera más sencilla, a través del escaneo de la superficie de los productos (Bosakova-Ardenska, 2024).

2.5.2. Termografía

La termografía es una técnica de análisis que utiliza cámaras infrarrojas para capturar y visualizar la radiación térmica emitida por los cuerpos en forma de imágenes de temperatura. Este método permite medir, sin contacto directo, las variaciones térmicas en una superficie, proporcionando información precisa sobre la distribución del calor en tiempo real (Kim et al., 2014). Los problemas en los equipos suelen manifestarse como cambios en su temperatura; por ello, los manuales de los fabricantes especifican el rango normal de temperatura de operación, información que el personal de mantenimiento utiliza como referencia para identificar posibles anomalías. Para llevar a cabo un análisis de temperatura, es necesario establecer una rutina programada de medición y recopilación de datos que permite detectar variaciones en esta magnitud (Cuibus et al., 2014).

2.5.2.1. Principios de la termografía

Todos los cuerpos cuya temperatura es superior al cero absoluto (0 °K o -273°C) emiten radiación térmica invisible al ojo humano (Wilson et al., 2023). La magnitud de esta radiación está directamente relacionada con la temperatura del objeto y puede calcularse mediante la Ecuación 2:

$$E = \varepsilon\sigma T_e^4 \quad \text{Ec. (2)}$$

Donde: E es la magnitud de la radiación, ε es la emisividad, σ es la constante de Stefan Boltzmann, T_e es la temperatura del objeto medida en °K.

A través de la energía emitida por un objeto, es posible determinar su temperatura, ya que la cantidad de energía infrarroja que emite aumenta

proporcionalmente con su temperatura. Los objetos más calientes emiten mayor radiación infrarroja. Aunque esta energía es invisible al ojo humano, la tecnología actual ha desarrollado equipos especializados, como cámaras termográficas, capaces de captarla y convertirla en imágenes visibles denominadas termogramas. Estas imágenes no solo permiten visualizar las variaciones de temperatura de los objetos, sino también analizar patrones térmicos, lo que resulta invaluable en diversas aplicaciones científicas, industriales y médicas. Por ejemplo, en procesos de fermentación láctea, estas herramientas permiten monitorear en tiempo real las temperaturas críticas, optimizando la eficiencia y calidad del producto final.

- **Cámara termográfica**

La cámara termográfica es un dispositivo que mide la radiación térmica emitida por los cuerpos y la transforma en una imagen visible con diversos colores, los cuales están determinados por la temperatura de los objetos. Estas cámaras suelen operar en longitudes de onda entre $8 \mu\text{m}$ y $15 \mu\text{m}$. La Figura 18 muestra una cámara termográfica utilizada para evaluar el comportamiento térmico de un motorreductor empleado en un proceso de manufactura.

Figura 18

Toma de imagen en circuitos mecánicos con una cámara termográfica



Nota: Wilson et al. (2023)

2.5.2.2. Aplicaciones de la termografía en alimentos

En los últimos años, la implementación de nuevas tecnologías desde los centros de investigación hasta el proceso de la industria alimentaria ha sido muy rápida. La termografía infrarroja es una herramienta utilizada en muchos campos, incluida la agricultura y la tecnología de la ciencia de los alimentos (Cuibus, 2013).

La termografía tiene un enorme potencial en diversas operaciones agrícolas, empezando por la evaluación de la viabilidad de las plántulas, la estimación del estado hídrico del suelo, la detección del estrés hídrico en los cultivos y la programación eficiente del riego. También es útil para identificar plantas afectadas por enfermedades y patógenos, estimar el rendimiento de los cultivos y evaluar la madurez de frutas y verduras (Vadivambal & Jayas, 2011).



2.5.2.3. Aplicación de la termografía en la industria láctea

En la industria láctea la tecnología termográfica ha sido utilizado para prevenir edemas en los pezones durante el ordeño mecánico; esta tecnología muestra una visión detallada de los estudios desarrollados en el tejido del pezón en vacas lecheras (Tangorra et al., 2019). Logrando optimizar la producción de leche al detectar y abordar de manera temprana el estrés en los pezones causado durante el proceso de ordeño mecánico. Por otro lado, un estudio realizado en cabras ratifica el estrés producido durante el ordeño mecánico. Al aplicar la tecnología termográfica permite una detección temprana y más rápida los problemas de salud, lo que podría ayudar a mejorar el bienestar de las productoras lecheras (Zaninelli et al., 2018).

Por otro lado, Osintsev, (2014), llevó a cabo una investigación de la aplicación de la termografía en la coagulación de la leche, analizando los cambios de temperatura que ocurren durante el proceso de coagulación. Asimismo, Emteborg et al., (2014), aplica esta tecnología en producción de quesos en donde se empleó una cámara termográfica en conjunto con un liofilizador para supervisar los ciclos de liofilización en queso Tomme de Savoie en tiempo real. La cámara proporcionó una resolución espacial superior en comparación con el sensor de Pt- 100 convencional.

2.6. ADQUISICIÓN Y PROCESAMIENTO DE IMÁGENES DE VISIÓN POR COMPUTADOR Y TERMOGRAFÍA

2.6.1. Adquisición de imágenes

La visión por computadora, desde sus inicios en la década de 1960 (Gonzalez & Woods, 2008), se clasifica como un subcampo de la inteligencia artificial que permite a las computadoras interpretar el mundo real (Janke et al., 2019), a partir de las imágenes. Dichas imágenes se captan utilizando cámaras de video, que se encarga entre sus múltiples funciones la de convertir las ondas de luz visibles en señales eléctricas o en un formato de video correspondiente. Existe una amplia variedad de cámaras para la adquisición de imágenes, incluidas cámaras de video, webcams, cámaras termográficas, escáneres, entre otras (Nixon & Aguado, 2019).

El proceso de adquisición de una imagen digital es similar al sistema visual humano:

- La cámara captura la imagen
- La imagen adquirida se convierte de formato analógico a digital, para permitir su procesamiento
- La imagen digital es procesable con múltiples herramientas de procesamiento de imágenes, dependiendo de los tratamientos a las que se quiere someter se utilizan herramientas apropiadas, los cálculos de procesamiento de imágenes se realizan a través de una computadora.

2.6.2. Digitalización de imágenes

La imagen es un elemento fundamental de un sistema de visión por computador y se origina en el sensor de imagen de una cámara, que viene a ser

una matriz de fotosensores que transforma la luz del rango visual (380 nm y 750 nm) en señales eléctricas y en valores numéricos (Addanki et al., 2022), que se almacenan en una matriz tridimensional (RGB), donde cada elemento se conoce como píxel, y sus valores oscilan entre 0 y 255 (Caccamo et al., 2004).

El proceso de digitalización de una imagen consta de dos etapas según Nixon & Aguado, (2019):

Muestreo: en este proceso, se captura la imagen cuando un dispositivo de adquisición realiza el muestreo de la imagen fotográfica, dividiéndola en píxeles y organizándola en una matriz con m filas y n columnas. El muestreo se emplea para definir el tamaño de los píxeles y asignar los valores de brillo a la imagen. En la Figuras 19 se presentan ejemplos de diferentes tipos de muestreo.

Cuantización: en este proceso se asignan valores a los elementos de la matriz, donde cada valor representa la variable física en un punto específico. En donde una representación visual que se obtiene se establece un rango de valores, donde el valor más bajo se asocia con un nivel de gris negro y el valor más alto corresponde a un nivel de gris blanco.

Figura 19

Imagen de alta y baja resolución



2.6.3. Propiedades de una imagen digital

Una imagen digital presenta tres propiedades fundamentales:

- *Resolución*: se refiere al número de filas y columnas de píxeles que conforman la imagen.
- *Definición*: indica el nivel de nitidez observable en una imagen. Esta propiedad está relacionada con la cantidad de bits utilizados para codificar el valor de un píxel. Para una profundidad de n bits, un píxel puede adoptar 2^n valores diferentes.
- *Número de planos*: corresponde a la cantidad de matrices o conjuntos de píxeles que forman la imagen. Las imágenes en escala de grises están compuestas por un solo plano, mientras que las imágenes a color se forman por tres planos.

2.6.4. Procesamiento de imágenes

Según Fernandes et al. (2020), para el procesamiento de imágenes implica las siguientes operaciones:

2.6.4.1. Espacios de colores

Un espacio de color se refiere a la especificación de un sistema de coordenadas y un subespacio dentro de ese sistema, donde cada color puede ser representado como un punto individual. Actualmente existen diversos espacios de colores o modelos, cada uno diseñados con fines específicos.

Es útil definir algunos términos relacionadas con los aspectos teóricos de color para comprender mejor cómo funciona estos espacios de color.

- *Luminosidad*: medida que indica la energía que el observador percibe desde la Nota de luz.
- *Brillo*: característica subjetiva según la persona que lo recibe.
- *Contraste*: diferencia entre valores de intensidad de píxeles presentes en la imagen.
- *Matiz*: asociado con la longitud de onda dominante en la mezcla de ondas de luz.
- *Saturación*: pureza relativa de la luz blanca mezclada con un matiz.
- *Cromaticidad*: matiz y saturación, se denomina cromaticidad.
- *Gamut*: es la gama de colores que un dispositivo puede reproducir.
- *Resplandor*: monto total de energía que fluye desde la Nota y es medida en Watts (W).

En el procesamiento de imágenes, los espacios de colores se pueden clasificar de diferentes categorías según Fernandes et al. (2020), los más comunes son los espacios de color basados en RGB y CIELab ($L^*a^*b^*$).

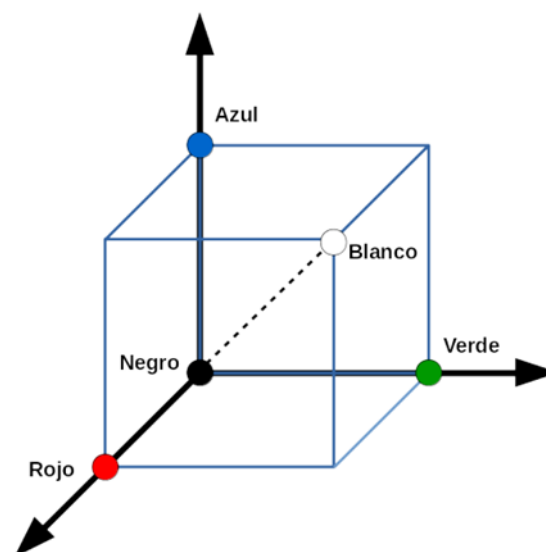
a) Espacio de color RGB

En el espacio el color RGB, cada color se define mediante una triada de valores correspondientes al rojo, verde y azul (Figura 19). Este sistema utiliza coordenadas cartesianas en tres dimensiones, comenzando en el punto cero, conocido como el cubo RGB (Loesdau et al., 2014a).

A través de la energía emitida por un objeto, es posible determinar su temperatura, ya que la cantidad de energía infrarroja que emite aumenta proporcionalmente con su temperatura. Los objetos más calientes emiten mayor radiación infrarroja. Aunque esta energía es invisible al ojo humano, la tecnología actual ha desarrollado equipos especializados, como cámaras termográficas, capaces de captarla y convertirla en imágenes visibles denominadas termogramas. Estas imágenes no solo permiten visualizar las variaciones de temperatura de los objetos, sino también analizar patrones térmicos, lo que resulta invaluable en diversas aplicaciones científicas, industriales y médicas. Por ejemplo, en procesos de fermentación láctea, estas herramientas permiten monitorear en tiempo real las temperaturas críticas, optimizando la eficiencia y calidad del producto final.

Figura 20

Espacio de color RGB




Nota: Sepúlveda Giraldo (2007)

b) Espacio de color CIELab

En el espacio de colores CIELab (Figura 20), los componentes principales que definen la ubicación de un color son: L^* para luminancia, a^* para el eje que va del rojo positivo al verde negativo, b^* para eje que va del amarillo positivo al azul negativo. Los rangos de estos componentes son: L^* varía de [0 - 100], donde 0 indica la ausencia total de luminancia (negro) y 100 indica luminancia completa (blanco). Los valores de a^* y b^* oscilan entre [-60 a 60] representando las variaciones entre los colores opuestos en sus respectivos ejes (Loesdau et al., 2014b).

Figura 21

*Espacio de colores CIELab $L^*a^*b^*$*



Nota: Sepúlveda Giraldo (2007)



2.7. DESARROLLO DE MODELOS DE PREDICCIÓN

El desarrollo de modelos de predicción es un proceso fundamental en la ciencia de datos y el aprendizaje automático, ya que permite convertir estos datos en conocimiento accionable. Estos modelos son esenciales para predecir resultados futuros basados en patrones identificados en datos históricos, facilitando la toma de decisiones informadas en diversas industrias, desde la salud hasta las finanzas (J. Chen et al., 2023).

Pasos para desarrollar según Chen et al. (2023) son:

- *Definición del problema:* planteamos y describimos nuestro problema, se evalúan los datos que se disponen y se define nuestro objetivo concreto.
- *Preparar y explorar los datos:* se describe los métodos empleados para la obtención del modelo.
- *Generar modelos:* se diseña un modelo.
- *Validar modelo:* se verifica si el modelo diseñado funciona.
 - *Implementación y actualización de modelos:* el modelo pasa a ser implementado a nivel operativo y requiere ser actualizado.



estimación utilizando datos empíricos y, posteriormente, a su contrastación mediante pruebas de validación que aseguren su precisión y aplicabilidad. Un aspecto clave de estas técnicas es la selección de una variable dependiente principal, que constituye el foco del análisis predictivo y determina las relaciones a modelar. Entre las técnicas predictivas destacan las denominadas *ad hoc*, diseñadas específicamente para clasificar los datos en grupos predefinidos basados en criterios establecidos. Además, estas técnicas son ampliamente utilizadas en áreas como la segmentación de mercados, el diagnóstico médico y el control de calidad industrial, debido a su capacidad para identificar patrones subyacentes y proyectar resultados futuros con mayor precisión. La correcta implementación de estas herramientas depende no solo de una adecuada selección del modelo, sino también de la calidad de los datos disponibles y del contexto en el que se aplican, lo que refuerza la importancia del conocimiento previo y de un análisis cuidadoso. (Pérez, 2014).

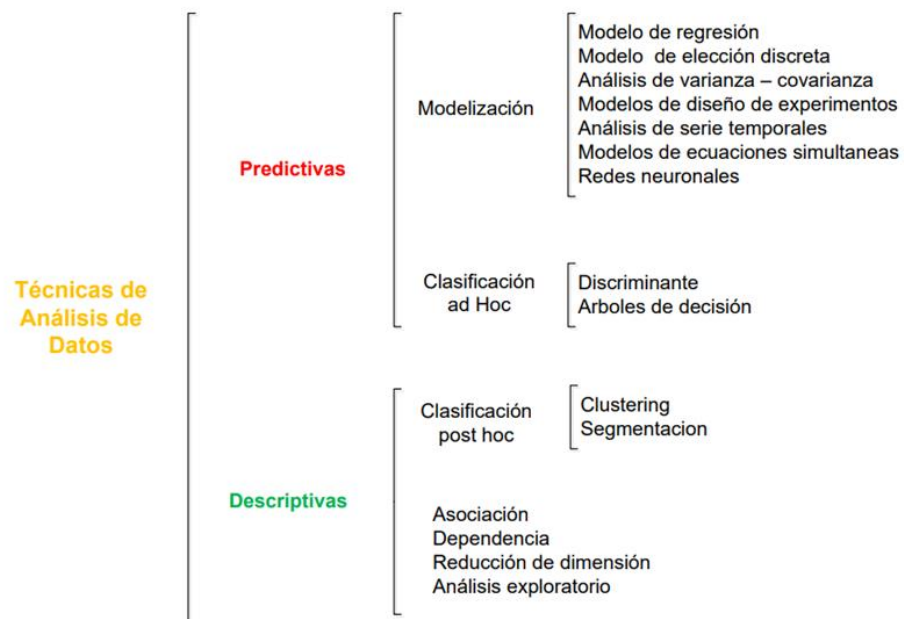
2.7.1.2. Técnica de análisis de datos descriptivos

En esta técnica, no se distingue de manera inicial entre variables dependientes o independientes, no se parte de un modelo predefinido para los datos. Los modelos se generan automáticamente a partir del reconocimiento de patrones. Entre las técnicas más relevantes se encuentran las de clasificación *post hoc*, que permiten clasificar los datos sin la necesidad de una especificación previa de los grupos. Esto significa que la categorización emerge del análisis, en lugar de ser impuesta desde el principio.

En la Figura 23, se representan las técnicas de análisis de datos más utilizadas: predictivas y descriptivas (Pérez, 2014).

Figura 23

Clasificación de las técnicas de análisis de datos



Nota: Pérez (2014)

Dentro del conjunto de técnicas predictivas, las redes neuronales artificiales (RNA) se destacan como herramienta poderosa para la modelización y predicción de datos. Estas técnicas incluyen tanto enfoques predictivos como descriptivos.

Las técnicas predictivas abarcan modelos de regresión, modelos de elección discreta análisis de varianza y covarianza, así como análisis de series temporales y modelos de ecuaciones simultáneas. Por otro lado, las técnicas descriptivas incluyen el análisis discriminante, árboles de decisión, clustering, y segmentación, entre otros.

La técnica de análisis multivariante, que abarca modelos de regresión y ecuaciones simultáneas, representa una opción viable para el estudio. Sin embargo, los diferentes comportamientos de las variables en funciones lineales, no lineales, algorítmicas y exponenciales dificultan el diseño del modelo. Además, los errores en los datos originales pueden introducir incertidumbre (ruido en los datos), complicando el proceso.

Para minimizar estas incertidumbres y garantizar que la técnica sea capaz de analizar todas las variables de estudio, se propone la RNA como la técnica más adecuada para llevar a cabo el trabajo. La capacidad de las RNA para manejar complejidad y variabilidad en los datos las convierte en una opción ideal para el desarrollo de modelos predictivos en este contexto.

2.7.2. Métodos de aprendizaje automático

2.7.2.1. Aprendizaje automático

El aprendizaje automático (Machine Learning) es una rama avanzada de la inteligencia artificial que se centra en el desarrollo de sistemas capaces de aprender y adaptarse de manera autónoma a partir de datos. A diferencia de los programas tradicionales, que operan bajo un conjunto fijo de instrucciones, los modelos de aprendizaje automático son diseñados para identificar patrones y relaciones dentro de grandes volúmenes de datos. Estos modelos mejoran y evolucionan a medida que se le exponen a más información, refinando sus modelos predictivos sin intervención humana directa. Esta capacidad de automejora permite que las aplicaciones basadas en Machine Learning se adapten dinámicamente

a cambios y nuevos desafíos, haciendo que esta tecnología sea crucial en campos como la medicina, la finanza, la automatización industrial, etc. (Alfaro & Ospina, 2021).

2.7.2.2. Aprendizaje no supervisado

En el aprendizaje no supervisado, las RNA entrenan sin necesidad de una salida específica, ya que pueden ajustar sus parámetros internamente. Esto es posible gracias a la redundancia en los valores de entrada, lo que también permite que su estructura sea sencilla (Guijano et al 2008).

2.7.2.3. Aprendizaje supervisado

En este tipo de aprendizaje los modelos se desarrollan con variable dependiente e independiente, lo que les permite identificar y corregir errores durante el proceso de entrenamiento (Nasteski, 2017). Este tipo de entrenamiento es el que se utilizó en el presente estudio explicando conceptos como los pesos y los sesgos que se estabilizan con la finalidad de que el Error Cuadrático Medio (ECM) en el conjunto de entrenamiento converja a un valor mínimo (Jimenez, 2012).

Un aspecto crucial en el entrenamiento de RNA es determinar el momento adecuado para detener el proceso, con el objetivo de evitar el sobreajuste. Este fenómeno ocurre cuando la RNA se adapta excesivamente a los datos de entrenamiento, memorizando patrones específicos en lugar de aprender características generales. Como resultado, su capacidad para generalizar a nuevos datos se ve comprometida, lo que afecta negativamente su desempeño. Para mitigar este problema, se emplea



la validación, una partición específica del conjunto de datos destinada a evaluar el error de la red después de cada época de entrenamiento. Este procedimiento permite monitorear el rendimiento del modelo y establecer un criterio para detener el entrenamiento en el punto donde la red presenta el mejor equilibrio entre precisión en los datos de entrenamiento y generalización a datos desconocidos. Cuando el error comienza a aumentar, se procede a detener el entrenamiento, lo que se conoce como detención temprana (Saravanan & Sujatha, 2018). Este método ya está implementado automáticamente en todas las funciones de creación de redes supervisadas en el software (Nasteski, 2017). Por lo tanto, es crucial decidir el porcentaje adecuado de datos que se utilizara para el entrenamiento, la validación y la prueba, ya que en un entrenamiento excesivo o insuficiente puede generar errores en el diseño de la RNA.

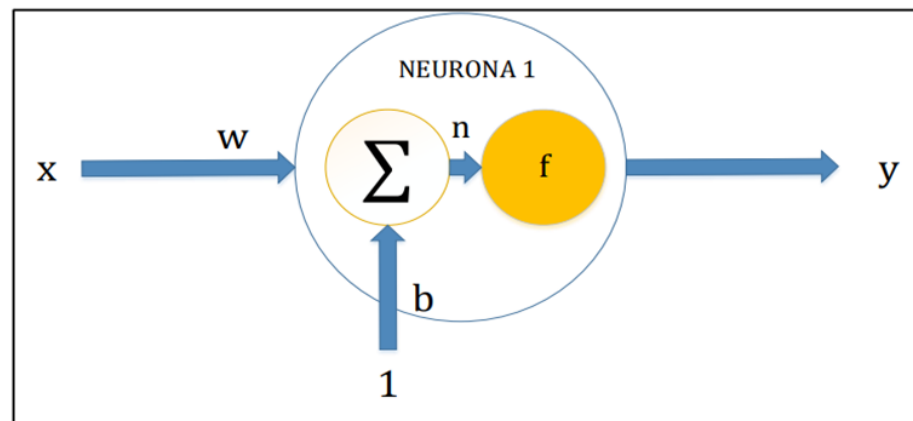
2.7.2.4. Redes neuronales artificiales

Las RNA son una técnica avanzada de análisis de datos que emula el funcionamiento del cerebro humano al procesar, aprender e identificar patrones de manera interconectada. Estas herramientas destacan por su versatilidad para abordar problemas complejos en áreas como el reconocimiento de imágenes, la predicción de tendencias y la optimización de procesos industriales. Una de sus principales ventajas radica en su flexibilidad para manejar grandes volúmenes de datos multivariados y no lineales, superando las limitaciones de técnicas tradicionales más rígidas y complicadas. Además, las RNA mejoran su desempeño mediante el entrenamiento continuo, lo que permite crear modelos robustos y dinámicos. Gracias a su capacidad de generalización y aprendizaje

profundo, son ideales para aplicaciones en la detección de anomalías, predicciones en tiempo real y automatización de decisiones, posicionándose como herramientas clave en un entorno de datos complejos y en constante evolución. (Menichetti et al., 2023).

Figura 24

Diseño de una red neuronal simple



Nota: Funes et al. (2015)

2.7.2.5. RNA de regresión

La regresión lineal es un método estadístico que busca modelar la relación entre una variable dependiente (la que queremos predecir) y una o más variables independientes (predictores). En el contexto de redes neuronales, la regresión lineal se puede abordar de diferentes maneras:

- **Redes neuronales simples:** son perceptrones o redes neuronales de una capa, son formas básicas de red neuronal artificial, estas redes constan de una sola capa de nodos.
- Estos modelos utilizan arquitecturas relativamente sencillas.
- Son adecuados para problemas menos complejos.



- Se pueden implementar con librerías como *Scikit-learn*.
- **Deep Learning:** subcampo del aprendizaje automático (Machine Learning), basado en el uso de redes neuronales artificiales con múltiples capas, conocidas como redes neuronales profundas.

Según Novac et al. (2022), en muchas aplicaciones de redes neuronales se emplean bibliotecas para definir sus modelos, siendo las más populares:

- **Tensorflow**

La primera versión de TensorFlow se lanzó en 2015 con el objetivo de reunir múltiples bibliotecas en un paquete cohesivo que pudiera usarse para resolver una variedad de problemas de aprendizaje automático (Novac et al., 2022). Dando lugar a una gran flexibilidad a la hora de diseñar un modelo de red, debido a sus bibliotecas como Contrib y Keras que se podían utilizar para definir capas. Siendo así, una biblioteca de código abierto desarrollada por Google que se utiliza principalmente para el aprendizaje automático y el desarrollo de redes neuronales profundas (Vasilev et al., 2019).

- **PyTorch**

PyTorch fue lanzado en el año 2016 con la idea de mantener la aplicación simple, lo que permite modificarla rápidamente y mantenerla actualizada con las últimas tendencias en el campo de la inteligencia artificial (Novac et al., 2022). PyTorch dentro de las redes neuronales se incorpora a tres principios fundamentales de los cuales el primero es el método a través del cual se definen sus funciones. El marco define todos sus componentes de una manera Pythonica, con la intención de que sea

fácilmente utilizable para los usuarios que ya están familiarizados con el lenguaje de programación Python (Vasilev et al., 2019).

Sobre el mismo tema de la simplicidad, el hecho de que los componentes se definan a través de interfaces es el segundo principio de PyTorch. A través de esto, la complejidad de definir y usar componentes se enmascara mediante inicializaciones simples y llamadas a funciones, lo que lleva a una identificación más clara de los conceptos centrales de las redes neuronales y, por lo tanto, a una curva de aprendizaje más fácil.

El último principio del marco es que un diseño simple es mejor, incluso cuando se sacrifica algo de rendimiento, ya que un diseño más complejo podría llevar a que la integración sea más compleja y pierda rendimiento a largo plazo (Vasilev et al., 2019).

2.7.2.6. Funciones de activación

Las funciones de activación son esenciales en las redes neuronales para evitar que la salida sea simplemente lineal. Estas funciones, junto con técnicas como el aprendizaje profundo, permiten que los modelos procesen conjuntos de datos complejos, de alta dimensionalidad y no lineales, especialmente en redes con múltiples capas ocultas. (Sharma et al., 2020).

Las funciones de activación o también llamada función de umbral o función de transferencia que permiten aprender y dar sentido a los mapeos son los siguientes:

- *Sigmoide*: la función sigmoide es una función no lineal comúnmente utilizada que transforma valores en un rango entre 0 y 1. Por lo que no

es simétrica respecto a cero, lo que implica que los signos de las salidas de las neuronas serán siempre positivos, esto puede mejorarse escalando la función (Sharma et al., 2020).

- *Tanh*: es la función tangente hiperbólica, sus valores se encuentran en el rango de -1 a 1. Al igual que la función sigmoide, la gradiente de la función *Tanh* es más pronunciada (Sharma et al., 2020).
- *ReLU*: significa unidad de revestimiento rectificado y es una función de activación no lineal que se usa ampliamente en redes neuronales. Una de las ventajas de usar esta función es que no todas las neuronas se activan al mismo tiempo, esto debido a que, en algunos casos el valor de la gradiente es cero por lo que las ponderaciones y los sesgos no se actualizan durante el paso de retro propagación en el entrenamiento de las redes neuronales (Sharma et al., 2020).
- *Softmax*: la función Softmax es una generalización de la sigmoide para problemas de clasificación multiclase. A diferencia de la sigmoide, que se usa para la clasificación binaria, la función Softmax se utiliza para asignar probabilidades a múltiples clases. Para cada punto de datos, devuelve una probabilidad asociada a cada clase, asegurando que la suma de todas las probabilidades sea 1 (Sharma et al., 2020).

Estas funciones introducen no linealidades, permitiendo a las redes neuronales aprender patrones complejos y modelar datos del mundo real.

2.7.2.7. Optimizadores

Los optimizadores son componentes esenciales en el entrenamiento de redes neuronales que permiten ajustar los parámetros internos de la red para minimizar el error y mejorar su rendimiento (Seyrek

& Uysal, 2023). Por lo tanto, en esta sección se explican los algoritmos de optimización de Adam, Adamax, RMSProp y Nadam, que se utilizan ampliamente en varias aplicaciones de aprendizaje profundo.

- *Adam*: la estimación adaptativa del momento (Adam) es un algoritmo de optimización que calcula las tasas de aprendizaje adaptativo para cada parámetro, este optimizador fue desarrollado por kingma y Ba (Taqi et al., 2018). Adam determina tasas de aprendizaje versátiles discretas para diferentes parámetros y datos a gran escala, también mejora la eficiencia computacional simplificando los requisitos de memoria (Chowdhury et al., 2021).
- *Adamax*: es un optimizador de la variante de Adam que se basa en la normalización de infinity, otro optimizador introducido por kingma y Ba (Taqi et al., 2018). Adamax tiene la gran ventaja de ser notablemente sensible a la selección de hiperparámetros, lo que da como resultado soluciones más confiables.
- *RMSProp*: la propagación de cuadrada media (RMSProp) es un algoritmo de optimización que es una adaptación del Adagrad, desarrollado para reducir la tasa de aprendizaje monótonamente decreciente del Adagrad (Seyrek & Uysal, 2023).
- *Nadam*: es un algoritmo de optimización que combina el momento de Adam y Nesterov para lograr un menor tiempo de entrenamiento. Se puede adaptar reemplazando el vector de momento anterior con el vector de momento actual del optimizador de Adam (Seyrek & Uysal, 2023).



2.7.2.8. Métricas de desempeño

Según Salas et al. (2019), en Deep Learning, las métricas de desempeño son cruciales para evaluar el nivel de ajuste y error de las predicciones de los modelos desarrollados. Las métricas de desempeño más comunes son:

- **Error absoluto medio:** calcula la diferencia absoluta entre las predicciones y los valores reales, también utilizado en problemas de regresión.
- **Error cuadrático medio:** mide la diferencia al cuadrado entre las predicciones y los valores reales y se adecua a los problemas de regresión.
- **Coefficiente de determinación (R^2):** es una herramienta valiosa para evaluar la calidad de un modelo de regresión y comprender cuanto de la variabilidad en los datos se captura mediante las relaciones establecidas por el modelo.



CAPÍTULO III

MATERIALES Y MÉTODOS

3.1. LUGAR DE EJECUCIÓN

El trabajo de investigación se ejecutó en el Taller de Frutas y Hortalizas de la Escuela Profesional de Ingeniería Agroindustrial de la Universidad Nacional del Altiplano, ubicado a una altitud de 3827 m.s.n.m. en la ciudad de Puno.

3.2. MATERIAL EXPERIMENTAL

En el presente estudio, se empleó leche descremada en polvo deshidratada por atomización a baja temperatura (*Low Heat*), procedente de California (EE. UU.) y suministrada por DairyAmerica®. Asimismo, se utilizaron suero de leche en polvo y concentrado proteico, suministradas por la misma empresa DairyAmerica®.

3.3. MATERIALES Y EQUIPOS

3.3.1. Materiales

- Leche en polvo (*Low Heat*) DairyAmerica de California (EE. UU.)
- Suero en polvo DairyAmerica de California (EE. UU.)
- Concentrado DairyAmerica proteico de California (EE. UU.)
- Reactores de incubación
- Controlador automático (Arduino Mega 2560)
- Vasos precipitados, 25ml, 50ml, 150ml y 250ml pírex
- Piseta
- Cubo de cuarzo
- Varilla de agitación



3.3.2. Equipos de laboratorio

- Colorímetro, XZB modelo portátil, China. Made in China
- Potenciómetro, HANNA instruments, China, Made in China
- Viscosímetro rotacional, modelo NDJ-8S China, Made in China
- Equipo de congelación, Marca Metalfrio, China, Made in China
- Acidímetro de laboratorio
- Balanza analítica de precisión, Marca AND, USA, Made in USA
- Termómetro, MARCA Elly Decor, China, Made in China
- LactoScan, MILCOTESTER MÁSTER ECO, Bulgaria Made in Bulgaria
- Cámara termográfica, Modelo HT - 03, China, Made in China
- Cámara fotográfica, Canon, Taiwán, Made in Taiwán

3.3.3. Reactivos

- Solución alcohólica de fenolftaleína al 1%
- Hidróxido de sodio (NaOH) al 0,1 Normal
- Agua destilada
- Alcohol etílico medicinal de 70°

3.3.4. Bacterias ácido-lácticas


Cultivo láctico liofilizado (*Streptococcus salivarius subsp. thermophilus* y *Lactobacillus delbrueckii subsp. bulgaricus*), fue de la marca Italiana SACCO LYOFAST Y456B (Lote: C367875A), suministrada por la empresa DANISCO.

3.4. METODOLOGÍA EXPERIMENTAL

El presente trabajo de investigación se ha desarrollado según el diagrama experimental mostrado en la Figura 25.

Figura 25

Diagrama de flujo para obtener los datos durante la monitorización



3.4.1. Descripción del proceso experimental

3.4.1.1. Recepción de la materia

Durante esta etapa se realizó la recepción de los ingredientes, incluyendo leche en polvo, suero en polvo, concentrado proteico e inóculo. Se inspeccionaron visualmente los envases para verificar que estuvieran herméticamente sellados y libres de daños físicos. Posteriormente, se



tomaron muestras representativas de cada ingrediente, las cuales se disolvieron en agua destilada y se analizaron utilizando un Lactoscan para determinar su composición nutricional exacta. Estos análisis son esenciales para realizar un balance de materia preciso y garantizar el cumplimiento de las especificaciones de la fórmula establecida.

3.4.1.2. Estandarización

En esta etapa se llevó a cabo la estandarización de la composición de las muestras en seco, siguiendo los procedimientos descritos por Alvarado et al., (2022). Para ello, se utilizaron leche en polvo, suero de leche en polvo y concentrado proteico en seco. El objetivo principal fue obtener una leche reconstituida con un 12% de sólidos totales y diferentes niveles de contenido proteico: 4.2, 4.5 y 4.8%. Para determinar las proporciones exactas de cada ingrediente en las mezclas, se utilizó la herramienta Solver de Microsoft Excel 2021 (versión 2108), lo que permitió un cálculo preciso y eficiente de las cantidades necesarias de concentrado proteico y suero de leche en polvo a incorporar en cada formulación.

3.4.1.3. Reconstitución de leche

La reconstitución de la leche se realizó siguiendo los procedimientos empleados por Alvarado et al., (2022). Para este fin se empleó agua destilada a 40°C en un contenedor con capacidad suficiente de 6 litros, en la que se mezcló la leche en polvo estandarizada a los valores preestablecidos de 12% de sólidos totales y 4.2, 4.5 y 4.8% de contenido proteico.

3.4.1.4. Homogenización

La mezcla se realizó con agitación constante. Durante esta etapa de homogenización se sometió a la leche en polvo a un proceso mecánico de agitación suave y constante durante 15 minutos en agua destilada, para asegurar una completa dilución de los sólidos. Este proceso garantiza una distribución más uniforme de los componentes de la leche, mejorando su estabilidad durante la pasteurización de la leche reconstituida.

3.4.1.5. Tratamiento térmico de la leche

El tratamiento térmico de pasteurización de la leche es una etapa crucial en la elaboración del yogur, ya que permite reducir significativamente la carga bacteriana contaminante que podría competir con los cultivos lácticos añadidos. En este estudio, se empleó una pasteurización a 80°C durante 25 minutos, asegurando un equilibrio óptimo entre la eliminación de microorganismos no deseados y la preservación de la calidad nutricional y sensorial de la leche. Este tratamiento térmico progresivo no solo inactiva bacterias indeseables, sino que también induce cambios beneficiosos en la estructura proteica de la leche: la precipitación de proteínas séricas sobre las micelas de caseína mejora su estabilidad, y la formación de sales cálcicas contribuye a un gel más firme y homogéneo en el producto final (Lindsay et al., 2021). De esta manera, se sientan las bases para un proceso de fermentación eficiente y obtener un yogur de alta calidad.



3.4.1.6. Enfriamiento

Una vez finalizada la pasteurización, la leche se sometió a un enfriamiento rápido utilizando un baño de agua fría, con el objetivo de reducir rápidamente su temperatura y alcanzar las condiciones óptimas para la fermentación. Las temperaturas finales de enfriamiento fueron 36, 40 y 44°C, según el diseño experimental.

3.4.1.7. Inoculación

Para obtener la disolución del cultivo se utilizó un método desarrollado por Oliveira et al., (2012) y modificado más adelante por el instituto SENATI (2019), para agregar el inóculo a la leche y proceder con la fermentación siguiendo estos pasos:

- Se adiciona el contenido del sobre en un litro de leche a 4°C, previamente pasteurizada (85°C por espacio de 10 minutos).
- Se mezcla la leche y el cultivo en un vaso de 1000 ml, por un tiempo de 3 a 4 minutos tratando de homogenizar la mezcla, antes de separar la cantidad a utilizar. Removiendo suavemente en forma circular, para no formar espumas; evitando así la contaminación del cultivo con bacterias presentes en el aire.
- De la disolución se extrajo con micropipetas calibradas 28.6 ml (equivalente al 1 % de cultivo) y se envasó en contenedores herméticos y estériles de polietileno.
- Se almacenó en congelación (-20°C) con el objetivo de inactivar las bacterias.



Una vez que la leche pasteurizada se enfríe a las temperaturas de estudio (36, 40 y 44°C), se descongela el cultivo y se incorpora a la leche. Luego se procede con el homogenizado suave durante un minuto garantizando la distribución uniforme del cultivo y evitando la formación de espuma.

Para iniciar con la etapa de inoculación, se retiraron los cultivos lácticos concentrados al 1% del congelador y se descongelaron parcialmente en Baño María a temperatura de 37°C. La cantidad de cultivo a descongelar varía según el porcentaje de inoculación requerida (1, 2 y 3%).

Por otro lado, una vez alcanzada la temperatura de fermentación deseada, el cultivo láctico se adicionó a la leche reconstituida previamente estandarizada y pasteurizada. La mezcla, para asegurar una distribución homogénea del cultivo, se removió suavemente durante 5 minutos.

3.4.1.8. Fermentación

La fermentación se realizó en dos reactores de incubación equipadas con sistemas de control de temperatura. Se establecieron tres temperaturas de fermentación: 36, 40 y 44°C. Durante este proceso, se tomaron muestras periódicas de uno de los reactores para determinar pH, acidez titulable, viscosidad y color mediante métodos convencionales y del otro reactor se capturaron las imágenes digitales y termográficas (métodos ópticos). Para estas determinaciones se combinaron técnicas ópticas y métodos tradicionales que describimos a continuación:

- **Métodos ópticos**

Los métodos ópticos empleados se encargaron de registrar los cambios en el espectro infrarrojo y visible que ocurrieron durante el proceso de fermentación de la leche. Para ello, se emplearon dos cámaras una fotográfica y la termográfica, ubicados estratégicamente según las recomendaciones de He et al., (2021). Las imágenes digitales RGB captadas permitieron registrar los principales cambios durante el proceso de fermentación de la leche.

- **Extracción de RGB de las imágenes termográficas y digitales**

Para el análisis de las imágenes termográficas y digitales, se desarrollaron códigos en Python. Se emplearon módulos como OpenCV para la lectura de las imágenes, Os para acceder a la carpeta donde se almacena las imágenes y Numpy para promediar los valores de los pixeles de los espectros de color RGB de forma individual. Esta información es fundamental para cuantificar los cambios en el color y la temperatura durante el proceso de fermentación.

- **Métodos tradicionales**

Por otro lado, en el reactor 1, se implementó un protocolo según la metodología propuesta por X. Zhang et al., (2024), recolectando muestras de 10 ml en vaso precipitado de 25 ml cada 10 minutos. Se realizaron análisis de pH, colorimetría (en cuarzo transparente) y la titulación con ácido base. Una vez realizada la lectura se pasa a descartar las muestras y los materiales se lavaron con bastante agua destilada.

Asimismo, se ha extraído muestras de 50 ml del reactor 1 para determinar la viscosidad del yogur, el muestreo se realizó cada 30 minutos

y cuando el pH descendió por debajo de 6 se ajustó la frecuencia de medición a un tiempo de 10 minutos. Las mediciones de viscosidad se realizaron con el usillo número 1 a una velocidad inicial de 60 rpm durante 5 minutos. La velocidad de giro se reduce a medida que incrementa la viscosidad, cuando el pH desciende por debajo de 5 se cambió el usillo al número 2 o 3.

3.4.1.9. Desarrollo de modelos predictivos

Los datos de pH, acidez, color y viscosidad se registraron en una hoja de Excel, y se calcularon los valores promedios y sus desviaciones estándar, así mismo los valores de RGB tanto de las imágenes digitales y termográficas se promediaron y calcularon sus desviaciones estándar de las tres réplicas. Los valores promedios se emplearon para el entrenamiento de los modelos predictivos a base de RNA (Figura 26).

Los valores RGB de las imágenes digitales y termográficas se emplearon para el desarrollo de modelos de predicción como se muestran en las Ecuaciones 3, 4, 5.

$$pH = f(R, G, B, T, t, \%P, \%I) \quad \text{Ec. (3)}$$

$$ACIDEZ = f(R, G, B, T, t, \%P, \%I) \quad \text{Ec. (4)}$$

$$VISCOSIDAD = f(R, G, B, T, t, \%P, \%I) \quad \text{Ec. (5)}$$

Donde R, G y B son los valores promedio de los valores de los pixeles de los espectros roja, verde y azul tanto de la imagen fotográfica y termográfica, T es la temperatura de fermentación de la leche, t es el tiempo en minutos a la que se quiere predecir los parámetros de control, %P es el contenido de proteína de la leche, %I es la concentración de inóculo empleado para la fermentación.

Figura 26

Arquitecturas de los modelos

```
RNA_RGB_DIG_ACIDEZ.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardaron todos los cambios
+ Código + Texto RAM Disco + Gemini
1 #Red Neuronal
2 neuronas=32
3 modelo=Sequential([
4     layers.Dense(neuronas, activation="relu", input_shape=[7]),
5     layers.Dense(neuronas, activation="relu"),
6     layers.Dense(neuronas, activation="relu"),
7     layers.Dense(neuronas, activation="relu"),
8     layers.Dense(neuronas, activation="relu"),
9     layers.Dense(neuronas, activation="relu"),
10    layers.Dense(neuronas, activation="relu"),
11    layers.Dense(neuronas, activation="relu"),
12    #layers.Dense(8, activation="relu"),
13    #layers.Dropout(0.25),
14    layers.Dense(1, activation=None)
15 ])
16
17
18 from tensorflow.keras import optimizers
19
20 #op=optimizer.SGD(0.1)
21 #op=optimizer.RMSprop(0.01)
22 op=optimizers.Adam(0.1)
```

3.4.1.10. Entrenamiento y desarrollo de modelos

En el entrenamiento de los modelos de red neuronal artificial se siguió el método de Reiser et al. (2021) empleando los datos preprocesados obtenidos mediante visión por computador y termografía, y los datos obtenidos de propiedades fisicoquímicas como: pH, acidez y viscosidad, mediante métodos convencionales. El entrenamiento consistió en correlacionar los valores de los métodos ópticos con cada una de las propiedades fisicoquímicas, para dicho propósito se empleó la plataforma de Google Colaboratory y el lenguaje de programación Python, donde la estructura de la red neuronal se construyó utilizando módulos como Tensorflow, Keras, Numpy, Pandas Matplotlib, principalmente.

Los datos de entrenamiento se almacenaron en una hoja de Excel de Google Drive y mediante una línea de códigos se accedió a su contenido desde la plataforma de Google Colab. El total de los datos fue dividido en dos grupos, 90% para el entrenamiento y 10% para la validación. Enseguida se especificaron los datos de entrada (x) y salida (y) para proseguir con el escado y normalización de los datos. Las arquitecturas de

las redes neuronales se obtuvieron mediante la combinación de 1, 2, 4, 6 y 8 capas ocultas con 4, 8, 12, 16, 20, 24, 28 y 32 neuronas por capa, cada combinación se entrenó 5 veces durante 500 épocas (Figura 27), en cada época de entrenamiento se ajusta la tasa de aprendizaje y se va reduciendo el error de predicción. Tras el entrenamiento se calcularon los valores de las métricas de desempeño (EAM, ECM y R^2) y luego los modelos entrenados, mediante una línea de código, se almacenaron en una carpeta de Google Drive y los valores de las métricas de desempeño se almacenaron en hojas de Excel de Google Drive.

La selección del mejor modelo se basó en maximizar el R^2 , que mide la precisión del ajuste, minimizar el EAM y el ECM, que cuantifican los errores de predicción. El modelo óptimo fue aquel que logró el mayor R^2 y el menor EAM y ECM, garantizando precisión y consistencia en las predicciones tras completar el entrenamiento, este criterio fue establecido por Batista et al. (2021a).

Figura 27

Entrenamiento del modelo por 500 épocas

```
RNA_RGB_DIG_ACIDEZ.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Sit. edit. por última vez: 9 de octubre
Comentar Compartir
+ Código + Texto
Conectar + Camar
1 hist-modelo_fit(xe_train,y_train,epochs=500)
Epoch 472/500
25/25 ----- 0s 1ms/step - loss: 0.1023 - acc: 0.0191
Epoch 473/500
25/25 ----- 0s 1ms/step - loss: 0.1020 - acc: 0.0206
Epoch 474/500
25/25 ----- 0s 1ms/step - loss: 0.1000 - acc: 0.0195
Epoch 475/500
25/25 ----- 0s 1ms/step - loss: 0.0989 - acc: 0.0182
Epoch 476/500
25/25 ----- 0s 1ms/step - loss: 0.0958 - acc: 0.0180
Epoch 477/500
25/25 ----- 0s 1ms/step - loss: 0.0981 - acc: 0.0194
Epoch 478/500
25/25 ----- 0s 1ms/step - loss: 0.0962 - acc: 0.0184
Epoch 479/500
25/25 ----- 0s 1ms/step - loss: 0.0921 - acc: 0.0172
Epoch 480/500
25/25 ----- 0s 1ms/step - loss: 0.1000 - acc: 0.0199
Epoch 481/500
25/25 ----- 0s 1ms/step - loss: 0.0990 - acc: 0.0201
Epoch 482/500
25/25 ----- 0s 1ms/step - loss: 0.0961 - acc: 0.0182
```



3.5. MÉTODOS TRADICIONALES PARA EL ANÁLISIS FÍSICOQUÍMICO

3.5.1. Determinación de pH

Para la determinación del pH se aplicó el método descrito por X. Zhang et al., (2024). Utilizando un potenciómetro de sobre mesa previamente calibrado con soluciones estándar de pH 4, 7 y 10. Se tomaron muestras de 10 g de la leche fermentada del reactor 1, en un vaso precipitado de 25 ml, procediendo a enfriar la muestra a una temperatura ambiente (20 a 25°C) y posteriormente se sumergió el electrodo en la muestra del vaso. Cada evaluación se realizó por duplicado para asegurar la precisión. El muestreo se llevó a cabo durante todo el proceso de fermentación extrayendo muestra por cada 10 minutos para así cumplir con el objetivo de la monitorización de la fermentación del yogur.

3.5.2. Determinación de acidez titulable

El porcentaje de acidez se determinó siguiendo el método propuesto por X. Zhang et al., (2024). Tomando 10 g de muestra de la leche fermentada del reactor 1, esta muestra se puso en el vaso precipitado de 25 ml previamente enfriada a temperatura ambiente y se procedió a la titulación agregándole 3 gotas de fenolftaleína como indicador, se agitó suavemente para homogenizar la solución, luego se agregó la solución alcalina de hidróxido de sodio al 0.1 N. con un equipo acidímetro, todas las titulaciones se llevaron a cabo por duplicado para asegurarse de la precisión. Una vez que la mezcla alcance un pH de 8.2 y/o se observe el color rosa pálido se detiene la adición del hidróxido y se prosigue con el registro del gasto obtenido en la titulación, el gasto se reemplaza en la Ecuación 6 para obtener el porcentaje de ácido láctico en la muestra. Este procedimiento se



llevó a cabo durante todo el proceso de fermentación con un intervalo de tiempo de 10 minutos de muestreo.

Para determinar el porcentaje de ácido láctico se utilizó la siguiente Ecuación:

$$\% \text{ Ácido} = \frac{(mlNaOH) * (N) * (Meq)}{\text{peso de la muestra}} \times 100 \quad \text{Ec. (6)}$$

Donde:

ml NaOH: gasto de NaOH

N: Normalidad del NaOH (0.1)

Meq: Miliequivalente de ácido predominante en la muestra (Meq = 0.09)

Es importante señalar que este método de titulación se empleó tanto para la leche como para las muestras de leche en el proceso de la fermentación del yogur.

3.5.3. Determinación de color

Para determinar este proceso del color, se siguió el método descrito por Costa et al. (2015). A lo largo de todo el proceso de monitorización de la fermentación y formación del coagulo, se tomó muestras de 10 g procediendo a enfriarlas a temperatura ambiente para luego verter en un cubo de cuarzo transparente que permite el paso de la luz. Se evaluó el color de la muestra en la escala CIELab y se determinó las siguientes coordenadas de color: luminosidad (L^* , 100 = blanco, 0 = negro), enrojecimiento (a^* , +rojo, -verde) y amarilleo (b^* , +amarillo, -azul). Estos análisis se realizaron en intervalos de 10 minutos durante todo el proceso de fermentación de la leche.



3.5.4. Determinación de viscosidad

La viscosidad durante el proceso de fermentación se evaluó utilizando un viscosímetro rotacional, las mediciones se realizaron a intervalos de 30 minutos. Sin embargo, una vez que el pH de la leche desciende por debajo de 6.0, el intervalo de muestreo se redujo a cada 10 minutos para capturar con mayor precisión los cambios en la viscosidad a medida que incrementa la concentración del ácido láctico por efecto de la fermentación.

Las mediciones se realizaron con diferentes velocidades y usillos durante 5 minutos a temperatura ambiente (15 - 20°C) acorde al esfuerzo de corte de la muestra, lo que permitió obtener una lectura precisa de la viscosidad en todas las etapas de la fermentación de la leche. A medida que la viscosidad aumentaba debido a la coagulación de las proteínas y la formación del coagulo, la velocidad de rotación se fue disminuyendo gradualmente. Esto se hizo para evitar que las fuerzas de cizallamiento afectaran negativamente las mediciones y asegurar que el equipo determine de manera precisa el comportamiento reológico de la fermentación del yogur.

3.6. MÉTODOS ÓPTICOS

3.6.1. Visión por computador


Se utilizó una cámara fotográfica digital CANON (Cannon® Kiss X Rebel SL3 200D, Lens EF-S 18-55 mm 1:4-5.6 IS STM, diámetro del lente 58 mm, tecnología CMOS, 4K y 24.2 Mega Pixeles con conexión Wi-Fi y Bluetooth), instalado en la cabina del reactor 2 siguiendo el método descrito por Milovanovic et al. (2021). Las cámaras tanto digitales como termográficas se ubicaron verticalmente a una distancia de 25 cm de la superficie central de la leche cómo

se observa en la Figura 28 A. La configuración de la cámara fotográfica fue la siguiente: velocidad de obturación 36 fotogramas por segundo, modo de operación semi automática, velocidad ISO 25600, flash apagado, distancia focal 58 mm, lente 35 unidades de Zoom. En la cabina se acoplaron dos lámparas LED (FLYING ® LED 8-00.6M 15W AC175-265V 50 Hz 8000K 2022.12) de 40 Hz, ubicado exactamente a un ángulo de 45° de la superficie central de la leche en el reactor. Tanto las lámparas como la cámara estaban fijadas dentro de la cabina cubica de paredes recubiertas con material negro opaca para evitar interferencias de la luz. La cabina tiene una abertura lateral para la entrada de las muestras, a la vez que está conectada a una Nota de corriente mediante cables de alimentación.

La cámara fotográfica fue conectada a la computadora con una dirección IP automática DHCP (Protocolo de Configuración Dinámica de Host) y mediante el Software de emparejamiento EOS Utility Launcher se controló los intervalos de captura de imágenes. Las imágenes digitales proporcionaron información sobre cambios en color en el espacio de color RGB.

Figura 28

Sistema de visión por computador y termografía para la adquisición de imágenes



Nota: La figura (A) muestra los reactores 1 y 2 instalados dentro de la cabina. La figura (B) muestra la cámara fotográfica (CF) y cámara termográfica (CT) instalados en el reactor 2.

3.6.2. Termografía

De la misma forma se procedió a instalar la cámara termográfica como se muestra en la Figura 28 B, siguiendo los procedimientos descritos por Baranowski et al., (2012). La cámara se instaló verticalmente a una altura de 25 cm de la superficie central de la leche. Para el control de la captura de imágenes, la cámara termográfica se conectó por Wifi a una computadora mediante la dirección IP: 192.168.230.1, esta dirección apertura una ventana en cualquier navegador por donde se observa la imagen termográfica y un botón para la captura de imágenes, para accionar dicho botón en intervalos de tiempo predefinido se desarrolló un código con el lenguaje de programación Python. La cámara termográfica empleada fue de la marca A-BF® RX-500 del Modelo: HT-06 con rango de temperatura operativo -20 a +500°C, resolución de imagen: 256x192, rango espectral 7.5 a 13 μm y una resolución térmica de $\pm 0.04^\circ\text{C}$.

Según Zolfagharnassab et al., (2022), las imágenes de las cámaras térmicas se basan en el hecho de que todos los materiales emiten radiación infrarroja en función a su temperatura y la termografía mide la radiación emitida por el objeto. Las diferencias en la difusividad térmica son parámetros de contraste para producir el termograma, esto permite que la termografía no requiera de iluminación, pero necesita de una temperatura ambiente constante.

3.7. UNIDADES DE ANÁLISIS Y OBSERVACIONES

3.7.1. Factores de estudio

- **Temperatura de fermentación**
 - 36°C
 - 40°C



- 44°C
- **Concentraciones de inóculo**
 - 1%
 - 2%
 - 3%
- **Porcentajes de proteína**
 - 4.2%
 - 4.5%
 - 4.8%

3.7.2. Factores de respuesta

- Propiedades fisicoquímicas
- Patrones de variación de las imágenes digitales y termográficas
- Modelos de predicción

3.7.3. Indicadores

- pH
- Acidez titulable (% ácido láctico)
- Color (CIELab)
- Viscosidad (mPa/s)
- Tiempo de fermentación (minutos)

3.8. DISEÑO EXPERIMENTAL

En el presente trabajo de investigación se utilizó un Diseño Completamente al Azar (DCA) con tres réplicas para evaluar el efecto de tres (03) factores principales: temperaturas de fermentación (36, 40 y 44°C), concentraciones de inóculo (1, 2 y 3 %) y



concentraciones de proteína (4.2, 4.5 y 4.8 %). Este diseño experimental fue seleccionado por su capacidad para distribuir aleatoriamente las unidades experimentales y minimizar la influencia de factores externos no controlados en los resultados.

Cada combinación factorial resultante de los niveles de estos factores se replicó tres veces, generando un total de 27 tratamientos experimentales (3 temperaturas por 3 concentraciones de inóculo por 3 concentraciones de proteína y por 3 réplicas) haciendo un total de 81 unidades experimentales. Los parámetros evaluados incluyeron:

- **pH:** monitoreado durante todo el proceso de fermentación.
- **Acidez titulable:** evaluada durante todo el proceso de la fermentación para cuantificar la cantidad de ácido producido.
- **Viscosidad:** medida durante todo el proceso para evaluar las propiedades reológicas del producto en fermentación.
- **Color en la escala CIELab:** registrado para analizar los cambios en los valores de L*, a* y b* asociados a los tratamientos.

Para el análisis estadístico, se empleó un análisis de varianza (ANOVA) para identificar efectos significativos de los factores individuales sobre las variables de respuesta. En los casos en que se detectaron diferencias estadísticamente significativas ($p < 0.05$), se aplicó la prueba de comparación múltiple de Tukey para identificar las diferencias específicas entre los tratamientos. Todo el análisis se llevó a cabo utilizando el software Minitab 18 Statistical Software (versión 18.1), que permitió realizar cálculos estadísticos precisos y representaciones gráficas claras de los resultados.

Este diseño experimental proporcionó un marco robusto y confiable para comprender la influencia de las variables controladas sobre las propiedades fisicoquímicas y color de la leche fermentada.



CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. IMPLEMENTACIÓN DEL SISTEMA DE FERMENTACIÓN Y CAPTURA DE IMÁGENES

4.1.1. Construcción de los reactores de fermentación

Los reactores de fermentación fueron diseñados a partir de una olla circular de acero inoxidable con una capacidad de 7 litros. Para la construcción de la cubierta externa, se utilizó una lámina de acero inoxidable 304° con dimensiones de 110 x 19 cm y un espesor de 1.0 mm. La cubierta internada fue fabricada con el mismo material, pero con dimensiones de 95 x 17 cm, mientras que la cubierta interna correspondió directamente a la olla original. La cavidad entre las cubiertas externa e intermedia se rellenó con fibra de vidrio como material aislante, con el objetivo de minimizar la pérdida de calor del fluido térmico recirculante hacia el exterior.

Para sellar la cavidad entre la cubierta intermedia y la base de la olla central, se empleó una lámina circular con un diámetro de 27 cm. De manera similar, para cerrar la base entre la cubierta intermedia y la cubierta externa, se empleó otra lámina circular un diámetro con 34 cm de diámetro. En cuanto a la parte superior, el espacio entre el borde superior de la olla y los bordes superiores de las cubiertas externa e intermedia se selló con una lámina en forma de anillo, con un diámetro externo de 34 cm y un diámetro interno de 27 cm, dejando libre el acceso al interior de la olla.

El segundo reactor se construyó utilizando las mismas dimensiones y materiales que el primero, siguiendo el diseño general basado en el modelo de marmita desarrollado por Cruz Amaro, (2022). Para la circulación del fluido térmico, se instalaron tubos de acero inoxidable de media pulgada de diámetro. Lo cual se colocó tanto en la base del reactor, perforando las cubiertas externas e intermedia, mientras que el tubo de salida se ubicó en la parte superior, en el lado opuesto. Adicionalmente, se instaló una tercera tubería del mismo diámetro equipada con una llave de paso, ésta tercera tubería conecta el interior de la olla con el exterior con la finalidad de muestreo. La instalación de las tuberías se realizó siguiendo las recomendaciones de Chacaguasay Lobato & Picho Barrionuevo, (2016).

Para elevar el reactor en 8 cm, se construyó una plataforma utilizando tubos y perfiles de 1 pulgada, unidos mediante soldadura especializada para acero inoxidable. Las imperfecciones generadas por la soldadura se eliminaron con un esmeril eléctrico de desbaste, logrando un acabado uniforme.

En la Figura 29 se muestra el reactor de incubación finalizado, junto con sus accesorios, como llaves de paso, uniones universales y el soporte. El diseño y las características del equipo construido son similares a los descritos por Lobato-Calleros et al., (2014), y se empleó con fines de investigación.

Figura 29

Reactores de incubación



En la Tabla 3 se presentan los datos dimensionales (capacidad, altura y diámetro) de los reactores construidos para la incubación del yogur.

Tabla 3

Dimensiones y capacidad del reactor de incubación

Variable	Dimensiones	Unidad de medida
Capacidad del reactor	7	Litros
Altura interna	16	cm
Diámetro interno	27	cm
Altura externa	19	cm
Diámetro externo	34	cm
Fibra de vidrio	5	kg
Láminas de acero inoxidable AISI 304	2	Unidades

4.1.2. Instalación del circuito de recirculación del fluido térmico


La plataforma empleada para la instalación tanto de los reactores de fermentación y la cabina de captura de imágenes fue una mesa rectangular con 82.5 cm de altura, 80.5 de ancho, 158.5 cm de largo y el espesor de la plataforma es de 1”.

El circuito de recirculación de fluido térmico, como se muestra en la Figura 30, se instaló empleando materiales termorresistentes de polipropileno (PPUR) de media pulgada de diámetro. También, se implementó el contenedor del fluido térmico con una capacidad máxima de 20 litros.

En la Figura 30 el fluido térmico del contenedor (B) inicia su recorrido por una tubería que conecta el contenedor con un presurizador 1 de 120 Watts de potencia de la marca BERKLIN® Modelo BKL – 120, este equipo eléctrico genera la fuerza de empuje suficiente para desplazar el fluido hasta el reactor (R1), tras el llenado de la cavidad interna del reactor, el fluido vuelve al contenedor (B). El fluido térmico para el reactor (R2) ingresa del contenedor al presurizador (2) y regresa al mismo contenedor tras recurrir todo el circuito.

Figura 30

Instalación del circuito de recirculación del fluido de agua caliente y agua fría para la incubación del yogur



Nota: (A) es el contenedor de fluido frío, (B) es el contenedor del fluido térmico, (1) es el presurizador para el reactor (R1), (2) es el presurizador para el reactor (R2). Elaboración propia.



4.1.3. Desarrollo del código para el controlador automático

Se empleó una tarjeta de Arduino Mega 2560 R3 que usa un microcontrolador ATmega2560 con la finalidad de garantizar la estabilidad de la temperatura de la leche durante la fermentación. Para el desarrollo del código del controlador automático, se empleó las siguientes librerías:

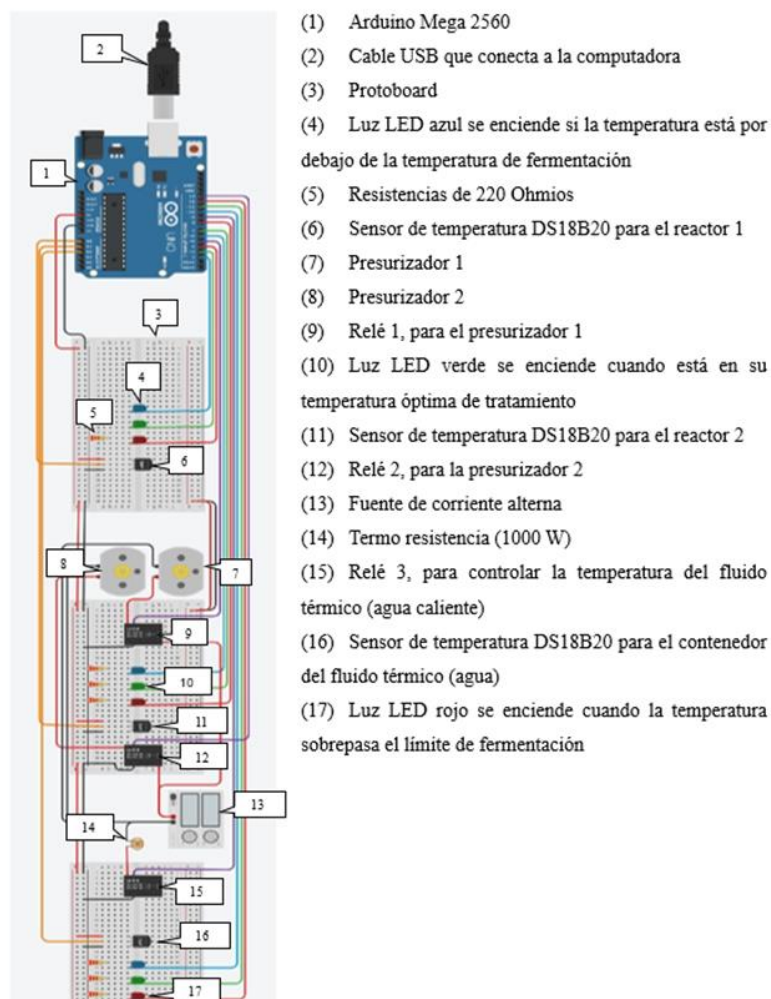
- **SPI.h:** esta librería permite la comunicación SPI (Serial Peripheral Interface) entre el Arduino y la tarjeta SD (Seguridad Digital) de almacenamiento.
- **SD.h:** permite la lectura y escritura de archivos en la tarjeta SD.
- **Wire.h:** esta librería permite al Arduino comunicarse con el reloj RTC instalado.
- **RTClib.h:** es una librería que permite controlar el módulo de reloj DS1307 para obtener fecha y hora.
- **OneWire.h:** permite a la tarjeta de Arduino establecer comunicación con los sensores de temperatura (DS18B20) mediante el protocolo *One-Wire*.
- **DallasTemperature.h:** mediante la conexión *One-Wire* el sensor DS18B20 interactúa con el Arduino.

El código para el funcionamiento del módulo de Arduino se desarrolló empleando el simulador Autodesk Tinkercad, el código desarrollado inicia con la definición de las librerías y Pines (puertos de conexión), luego se configuran los sensores empleando el protocolo de comunicación *One-Wire*, donde el sensor de temperatura del reactor 1 está conectado al pin 22, del reactor 2 al pin 23 y del contenedor del fluido caliente al pin 24. Seguidamente se estableció los rangos de oscilación térmica ($\pm 0.25^{\circ}\text{C}$) para cada tratamiento en estudio. En la función *setup()* del código, se establece la comunicación del módulo de Arduino con la tarjeta

SD, el reloj RTC y los sensores de temperatura DS18B20. También se asigna los pines para los LEDs y relés. Ya en la función *loop ()* se inicia la lectura de los tres sensores de temperatura y el almacenamiento de los valores en la tarjeta SD. En función a los datos de temperatura registrados por los sensores se activan o desactivan los LEDs y relés con el propósito de mantener la temperatura dentro de los rangos de oscilación establecidas. Finalmente, el intervalo establecido para las lecturas de las temperaturas fue de 20 segundos. Esta lógica de programación se ejecutó siguiendo las pautas descritas por Schwartz, (2014).

Figura 31

Diseño del controlador automático (Arduino Mega 2560)





4.1.4. Instalación de los sensores de temperatura y controladores

Se conectaron al Arduino 3 sensores de temperatura DS18B20 y 9 indicadores LEDs (rojo, verde y azul), tres LEDs por cada reactor y otros tres LEDs en el contenedor del fluido caliente. Por otra parte, para la instalación de los sensores se utilizó resistencias de 400 ohmios para su adecuado funcionamiento, y en cada uno de los LEDs se colocó una resistencia de 220 ohmios para alargar su vida útil, como se muestra en la Figura 31.

El Arduino funciona con corriente continua a un máximo de 7 voltios, lo que limita su capacidad para controlar directamente dispositivos que requieren corriente alterna, como los presurizadores y la resistencia utilizada para calentar el fluido térmico, los cuales operan a 220 voltios. Debido a esta diferencia en las especificaciones de voltaje y tipo de corriente, es indispensable el uso de relés. Los relés son interruptores electromagnéticos que permiten controlar cargas de corriente alterna de alta tensión, como los de 220 voltios, mediante señales de bajo voltaje generadas por el Arduino. Este componente actúa como un intermediario, garantizando que el Arduino pueda controlar de manera segura y eficiente los equipos que requieren corriente alterna, sin que el sistema se vea afectado por las altas tensiones involucradas.

En la Tabla 4 se describen los elementos que componen el sistema embebido presentando una lista de los componentes requeridos de los periféricos de acople de señales.

Tabla 4*Componentes usados para la automatización de los reactores de incubación*

Nombre	Cantidad	Componente
Arduino Mega 2560	1	Microcontrolador ATmega2560
R1, R2, R3, R4, R5, R6, R7, R8, R9	9	220 Ω
RT1, RT2, RT3	3	400 Ω
Presurizador del reactor 1	2	Presurizador de 120 W
Presurizador del reactor 2		
Relé del presurizador 1	3	Relé
Relé del presurizador 2		
Relé de la resistencia térmica		
Led del fluido térmico	3	LED azul
Led del reactor 1		
Led del reactor 2		
Led del fluido térmico	3	LED verde
Led del reactor 1		
Led del reactor 2		
Led del fluido térmico	3	LED rojo
Led del reactor 1		
Led del reactor 2		
Sensor de °T del reactor 1	3	Sensor de temperatura DS18B20
Sensor de °T del reactor 2		
Sensor de °T del fluido térmico		
Nota de corriente alterna	1	220 voltios y 2 Amperios
Termo resistencia de 1000 W	1	Resistencia térmica

4.1.5. Construcción de la cabina e instalación de las luces y cámaras

Para construir la cabina tal como se muestra en la Figura 32, se utilizó tubos rectangulares de aluminio de 1x2 pulgadas. La estructura, de dimensiones

150 x 65 x 90 cm, se ensambló con un total de 15 perfiles, unidos mediante tornillos autoperforantes. En la parte superior, se incorporaron 5 perfiles transversales, espaciados uniformemente, esto para reforzar la estructura y fijar tanto la cámara fotográfica y termográfica. Los focos LED de corriente alterna empleados para la iluminación también se fijaron a la estructura formando un ángulo de 45° con la superficie de la leche para iluminar de manera óptima los reactores. Finalmente, la estructura de la cabina fue cubierta con tres capas de tela negra con la finalidad de evitar reflejos de la luz e interferencias de luz externa. La estructura de la cabina de toma de imágenes se construyó siguiendo las pautas y recomendaciones realizadas por Milovanovic et al., (2021).

Figura 32

Disposición de las cámaras a la altura del reactor en el interior de la cabina



4.1.6. Conexión inalámbrica de las cámaras a las computadoras

Las cámaras instaladas dentro de la cabina de fermentación se conectaron individualmente a una computadora siguiendo los procedimientos descritos anteriormente, las conexiones realizadas se muestran en la Figura 33 para la cámara fotográfica y en la Figura 34 para la cámara termográfica. Esta conexión de las cámaras a las computadoras permitió controlar con mayor precisión los intervalos de tiempo para la captura de imágenes.

Figura 33

Conexión inalámbrica de la cámara fotográfica a la computadora





Figura 34

Conexión inalámbrica de la cámara termográfica a la computadora



4.1.7. Validación del sistema de incubación y captura de imágenes

El equipo diseñado y construido fue sometido a pruebas preliminares de fermentación y recirculación del fluido térmico, con el objetivo de evaluar su rendimiento y eficiencia. A partir de los resultados obtenidos, se realizaron ajustes en el diseño estructural y en el software para optimizar su funcionamiento. En el controlador, se programaron rangos de temperatura referenciales específicos para asegurar tanto la integridad de los componentes como el correcto funcionamiento del proceso de fermentación. Estos ajustes permitieron garantizar que la temperatura en los reactores se mantuviera dentro del rango adecuado para la fermentación, evitando fluctuaciones que pudieran afectar la calidad del proceso. Los rangos de temperatura referenciales utilizados en los experimentos, que fueron clave para el éxito de las pruebas, se detallan en la Tabla 5.

La Tabla 6 presenta los datos de temperatura registrados por los sensores DS18B20 durante los procesos de fermentación a las diferentes temperaturas estudiadas. Se observa que, en general, las fluctuaciones de temperatura durante la fermentación se mantuvieron dentro del rango predefinido a excepción de la fermentación realizada a 36°C que tuvo oscilaciones por encima de lo previsto, tal como se muestran en la Figura 35. Frente a este efecto observado, JAMES & Charlotte, (2019) afirma que los sistemas de transferencia de calor convectiva presentan desafíos en mantener la estabilidad térmica. Sin embargo, es fundamental conservar una temperatura constante dentro del rango óptimo para el crecimiento de las bacterias lácticas. Los estudios de Zhang et al., (2024) y Yang et al. (2021) respaldan la importancia de un rango de temperatura constante para mejorar la calidad y las propiedades reológicas del yogur.

Tabla 5

Rangos de temperaturas predefinidas para el sistema de fermentación

Temperaturas de fermentación (°C)	Rango de oscilación térmica en los reactores (°C)	Rango de temperatura del fluido térmico (°C)
36	36 ±0.25	37 – 38
40	40 ±0.25	41 – 42
44	44±0.25	45 – 46

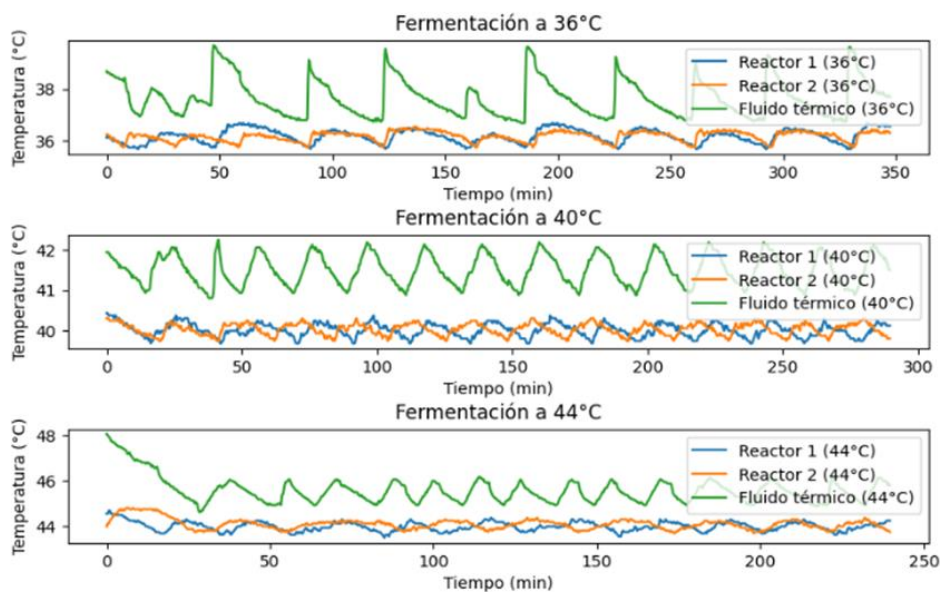
Tabla 6

Resultados del control térmico durante la fermentación a las tres temperaturas de estudio

°T de fermentación (°C)	°T del reactor 1 (°C)	°T del reactor 2 (°C)	°T de fluido térmico (°C)
36	36.19 ± 0.26	36.18 ± 0.19	37.66 ± 0.73
40	40.01 ± 0.16	40.04 ± 0.14	41.50 ± 0.38
44	43.99 ± 0.19	44.09 ± 0.22	45.54 ± 0.51

Figura 35

Curvas de oscilación de las temperaturas durante la fermentación de los reactores de incubación del yogur batido



4.2. BALANCE DE MATERIA PARA LA ESTANDARIZACIÓN DE LA LECHE

La leche empleada para los procesos de fermentación fue reconstituida a partir de leche, suero y concentrado proteico en polvo, en todos los casos siempre manteniendo constante el contenido de sólidos totales en 12% mientras que el contenido proteico, de acuerdo las variables de estudio se establece 3 niveles de proteína 4.2, 4.5 y 4.8%. Las cantidades necesarias para mezclar de cada componente para cumplir las restricciones se calcularon empleando la composición nutricional que se muestra en la Tabla 7 y el software Solver de Microsoft Office LTSC Professional Plus 2021 (versión 2108).

Tabla 7

Información nutricional de las materias primas utilizadas durante la fermentación

Componentes	Leche en polvo (g)	Agua (g)	Concentrado proteína (g)	Suero en polvo (g)
Humedad	3.8	100.0	5.14	8.62
Proteína	34.0	0.0	80.69	11.0
Resto	62.2	0.0	14.17	80.38
% TOTAL	100.0%	100.0%	100.0%	100.0%

Los resultados de los cálculos realizados se muestran en la Tabla 8, donde se observa que la cantidad de leche en polvo disminuye a medida que aumenta la cantidad necesaria de concentrado proteico. Esta llevó variación a la necesidad de recurrir al suero en polvo, el cual fue utilizado para equilibrar el contenido de lactosa en la mezcla, ya que el concentrado proteico en polvo carece de este disacárido esencial para la producción del yogur. Esta estrategia fue fundamental para asegurar que la fermentación ocurriera de manera adecuada, manteniendo la calidad y características del producto final, al proporcionar la lactosa necesaria para el crecimiento de las bacterias lácticas.

Tabla 8

Resultados obtenidos del balance de masa para la reconstitución de 6000 gramos de leche a distintos porcentajes de proteína

% de proteína	Leche en polvo (g)	Agua (g)	Concentrado proteína (g)	Suero en polvo (g)	Leche reconstruida (g)
4.2	748.44	5251.56	0.00	0.00	6000
4.5	703.83	5250.75	40.42	5.00	6000
4.8	659.22	5249.93	80.85	10.00	6000

En referencia a los componentes empleados para la reconstitución de la leche, Zhao et al., (2016) y Ali et al., (2023) confirman la influencia directa de los componentes adicionales en la formación estructural durante la fermentación de la leche mejorando la calidad del yogur ya que favorecen la retención del agua.

4.3. MONITORIZACIÓN DE LAS CARACTERÍSTICAS FISICOQUÍMICAS DEL PROCESO DE FERMENTACIÓN DE LA LECHE MEDIANTE TÉCNICAS CONVENCIONALES

Durante el proceso de monitorización, se realizaron a cabo pruebas para evaluar diversos parámetros fermentativos, como la acidez, el pH, la viscosidad y el color. Los resultados obtenidos reflejan claramente los efectos de los distintos niveles de los componentes de la leche, tales como la temperatura de fermentación, el porcentaje de proteínas y el porcentaje de inóculo, sobre las variables de respuesta previamente establecidas. Estos análisis permitieron comprender cómo las variaciones en los factores de fermentación influyen en las características organolépticas y funcionales del yogur, lo que es crucial para optimizar el proceso y garantizar la calidad del producto final.



4.3.1. Efecto de las variables de estudio en el tiempo de fermentación

El análisis estadístico de varianza (ANOVA) no encontró un efecto significativo ($p > 0.05$) de la concentración de proteína ni del porcentaje de inóculo sobre el tiempo de fermentación de la leche. Este hallazgo fue confirmado mediante la prueba de Tukey, la cual demostró que los tiempos de fermentación para los diferentes niveles de estas variables son estadísticamente iguales.

En contraste, la temperatura de fermentación fue la única variable que mostró un efecto significativo ($p < 0.05$) sobre el tiempo de fermentación. A temperaturas más altas, el tiempo requerido para completar la fermentación fue menor, mientras que, a temperaturas más bajas, el tiempo de fermentación se incrementó. Este comportamiento se alinea con lo reportado por Yang et al. (2021a), quienes describen un efecto térmico similar sobre los tiempos de fermentación en productos lácteos. Los resultados del ANOVA, presentados en la Tabla 9, respaldan esta observación, y las diferencias significativas entre los niveles de temperatura fueron corroboradas por la prueba de Tukey, cuyos resultados se detallan en la Tabla 10. Además, en la Figura 36 se ilustran los intervalos de tiempo promedio para la fermentación a distintas temperaturas.

El análisis de varianza de los resultados demuestra de manera clara y precisa, que tanto la concentración de proteína como el porcentaje de inóculo no influyen de forma significativa ($p > 0.05$) en el tiempo de fermentación, mientras que la temperatura sí tiene un efecto perceptible. La similitud de estos resultados con los estudios previos refuerza la validez de los hallazgos y así mismo las herramientas estadísticas utilizadas (ANOVA y Tukey) permiten corroborar dichos efectos.

Tabla 9

Análisis de varianza del tiempo de fermentación según la temperatura estudiada

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Temperatura (°C)	2	323622	161811	183.98	0.000
Error	78	68600	879		
TOTAL	80	392222			

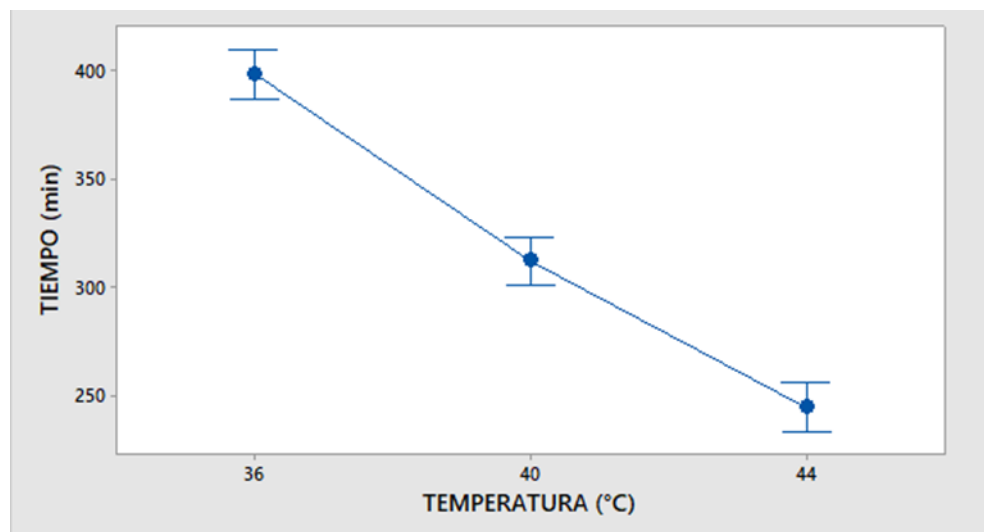
Tabla 10

Análisis y comparación Tukey para la variación del tiempo de fermentación según la temperatura estudiada

Temperatura (°C)	N	Media	Agrupación
36	27	398.89	A
40	27	312.22	B
44	27	244.44	C

Figura 36

Intervalo de tiempo para la fermentación (min) en función a las temperaturas de estudio



4.3.2. Control de acidez durante la monitorización de la fermentación de la leche

La acidificación de la leche se estudió empleando distintas concentraciones de proteína y fermentándola a 36, 40 y 44°C, con porcentajes de inóculo del 1, 2 y 3%, utilizando métodos convencionales de medición. Este proceso comienza con la conversión de lactosa en ácido láctico, resultado de la actividad metabólica de las bacterias ácido-lácticas. Inicialmente, la producción de ácido es lenta, debido a que las bacterias permanecen en fase estacionaria. Sin embargo, a medida que avanza la fermentación, el proceso se acelera, coincidiendo con la fase de crecimiento exponencial de las bacterias (Sfakianakis & Tzia, 2014b).

Los resultados muestran que la acidez final oscila entre 0.5 y 0.8 g de ácido láctico por cada 100 g de muestra, dentro del rango establecido por la NTP 202.092:2008 para yogur descremado. Por su parte, el tiempo de fermentación varió entre 210 y 420 minutos, dependiendo de las condiciones evaluadas. Las Figuras 37, 38 y 39 evidencian que a 36°C el tiempo de fermentación fue mayor, independientemente del porcentaje de inóculo, lo cual se explica por la temperatura óptima de crecimiento de las bacterias ácido-lácticas, generalmente entre 40 y 45°C (Courtin et al., 2002). A temperaturas de 40°C y 44°C, el tiempo de fermentación se reduce, como también reportó Tala Orrillo, (2023), quien observó que temperaturas más altas favorecen la degradación acelerada de la lactosa. Sin embargo, la acidez final fue inferior a la esperada para un batido de yogur, posiblemente debido al efecto amortiguador de la proteína, como sugieren Ali et al. (2023).

Figura 37

Curvas de acidificación de la leche con 4.2% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo





Figura 38

Curvas de acidificación de la leche con 4.5% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo




En referencia a la Figura 38, donde se utilizó leche con una concentración proteica del 4.5%, se aprecia que la temperatura influyó significativamente en el tiempo de fermentación. A 44°C, se alcanzaron los valores deseados de acidez (0.6-0.7 g/100g) en menor tiempo, independientemente del porcentaje de inóculo. Conforme se redujo la temperatura de fermentación, el tiempo se prolongó. Estos resultados sugieren que una temperatura más alta favorece la actividad de las bacterias lácticas, acelerando la acidificación. No obstante, la acidez final fue ligeramente inferior a la reportada por Ali et al. (2023) para yogures enriquecidos con proteínas de suero. Shori & Baba, (2014) también observaron un aumento en la acidez con mayores niveles de proteína, lo que sugiere que otros factores, como la temperatura y el porcentaje de inóculo, o las condiciones de procesamiento, podrían influir en los resultados obtenidos.

Los resultados presentados en la Figura 39 corresponden a leche fermentada con una concentración proteica del 4,8%, donde la acidez final osciló entre 0,6 y 0,8 g de ácido láctico/100 g. Aunque estos valores cumplen con el rango establecido por la NTP 202.092:2008 para yogur descremado, Aryana & Olson (2017) sugieren que, para yogures regulares o parcialmente desnatados, la acidez mínima titulable debería ser del 0.9%. Esta diferencia podría indicar una acidificación insuficiente, lo que podría deberse a factores como la temperatura de fermentación o la concentración de proteína empleada. Es posible que una temperatura de fermentación más alta o una mayor concentración proteica hayan influido en una menor producción de ácido láctico, lo que afectará la acidez final del producto. Este hallazgo resalta la importancia de ajustar adecuadamente las condiciones de fermentación para lograr una acidez más cercana a los estándares requeridos para yogures de calidad.

Figura 39

Curvas de acidificación de la leche con 4.8% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo



Los resultados revelan una tendencia clara de la influencia de la temperatura sobre el tiempo de fermentación y la producción de ácido láctico, este efecto fue respaldado por estudios previos. Los resultados sugieren que, aunque la concentración de proteína y el porcentaje de inóculo juegan un rol en el proceso de acidificación, la temperatura es el factor dominante. A temperaturas más altas, se acelera la acidificación, acortando el tiempo de fermentación, lo que concuerda con estudios previos. Sin embargo, la concentración de proteína podría estar actuando como un amortiguador, limitando el aumento de la acidez final.

4.3.2.1. Efecto de la concentración proteica en la acidificación de la leche

Los resultados del análisis de varianza (ANOVA) indicaron diferencias significativas ($p < 0.05$) en los valores de acidez alcanzados al utilizar distintas concentraciones de proteína en la elaboración de yogur, con un nivel de confianza del 95%. Estos resultados se presentan en la Tabla 11. La prueba de Tukey reveló que las concentraciones de proteína de 4.2% y 4.8% generaron niveles de acidez significativamente más elevados en comparación con el yogur elaborado con un 4.5% de proteína. Estas comparaciones se muestran en la Tabla 12, mientras que los intervalos de acidez correspondientes a las diferentes concentraciones de proteína se ilustran en la Figura 40.

Al comparar estos resultados con estudios previos de Xu et al., (2022) quienes analizaron el efecto de la concentración proteica sobre las propiedades fisicoquímicas del yogur, reportando valores de acidez entre 0.68% y 1.15%. Estos hallazgos coinciden con los valores obtenidos en los tratamientos con 4.2% y 4.8% de proteína de este estudio, los cuales se

encuentran dentro del rango establecido por la NTP 202.092:2008 para yogur descremado (0.6% a 1.5% de acidez titulable).

Por su parte, Aita et al., (2015) reportaron una acidez titulable de 0.71% a 1.01% en yogures fortificados con diferentes niveles de proteína, lo cual también se aproxima a los resultados obtenidos para los tratamientos con 4.2% y 4.5% de proteína en el presente estudio. Sin embargo, Wherry et al., (2019) informaron valores de acidez entre 1.17% y 1.19% en yogures sin grasa y sin sabor, enriquecidos con concentrado proteico, cifras notablemente superiores a las reportadas en este trabajo.

El análisis estadístico confirma que la concentración de proteína tiene un impacto significativo en los niveles de acidez del yogur. Los resultados sugieren que las concentraciones más altas de proteína (4.2% y 4.8%) favorecen una mayor producción de ácido láctico, lo cual es consistente con el comportamiento reportado por otros autores. Es importante destacar que, si bien la acidez final se encuentra dentro del rango permitido por las normativas, las diferencias entre los estudios pueden estar influenciadas por factores como la fortificación con concentrados proteicos o las condiciones de procesamiento.

Tabla 11

Análisis de varianza de acidez titulable según la concentración de proteína

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Proteína (%)	2	0.1475	0.073767	10.68	0.000
Error	78	0.5386	0.006905		
TOTAL	80	0.6861			

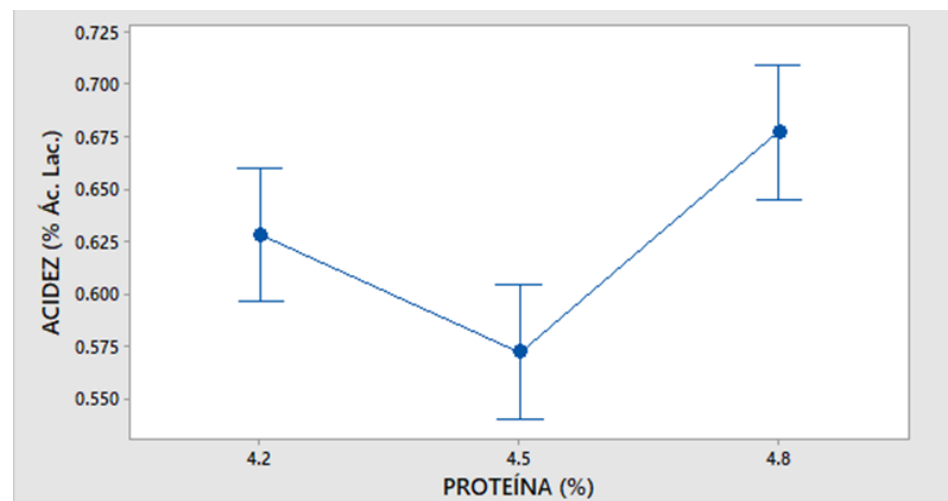
Tabla 12

Análisis y comparación Tukey para la variación de acidez titulable, según la variación de proteína

Proteína (%)	N	Media	Agrupación
4.8	27	0.6769	A
4.2	27	0.6281	A
4.5	27	0.5725	B

Figura 40

Intervalos de acidez (% ácido láctico) en función a las concentraciones de proteína



4.3.2.2. Efecto de la concentración de inóculo en la acidificación de la leche

La concentración de inóculo, evaluada de manera independiente de otros factores, no mostró un efecto significativo en la producción de ácido láctico ($p > 0.05$), según el análisis de varianza (ANOVA) presentado en la Tabla 13. De forma coherente, los resultados de la prueba de Tukey, mostradas en la Tabla 14, tampoco revelaron diferencias estadísticas



significativas entre las medias de acidez alcanzadas con las tres concentraciones de inóculo evaluadas. Esto sugiere que, a pesar de que la concentración de inóculo es un factor relevante, su impacto en la acidez es limitado y que otros elementos, como las condiciones de fermentación (temperatura, tiempo o concentración de proteínas), podrían tener un papel más influyente en la variación de la acidez. Los intervalos de acidez observados para los yogures elaborados con diferentes concentraciones de inóculo se presentan de manera visual en la Figura 41, lo que permite una comparación clara de los efectos en la acidez, reforzando la idea de que el inóculo no fue el factor más determinante en este caso.

Adicionalmente, se evaluó el efecto del porcentaje de inóculo sobre la acidez titulable, obteniéndose valores de acidez final que varían entre 0.60 y 0.68 g de ácido láctico por cada 100 g de yogur. De acuerdo con la NTP 202.092:2008, este yogur descremado se encuentra dentro del rango aceptable de acidez láctica, que va de 0.6% a 1.5%.

Al comparar estos resultados con los reportados por (Aita et al., 2015), quienes encontraron valores de acidez entre 0.77% y 1.01% durante la elaboración de yogur, se observa una diferencia significativa, ya que los valores obtenidos en nuestro estudio son considerablemente más bajos. De manera similar, Horiuchi & Sasaki, (2012) reportaron una acidez del 0.7% utilizando un inóculo del 0.1% (p/p), lo que sugiere una relación simbiótica entre las bacterias ácido-lácticas. En este proceso, *Streptococcus thermophilus* favorece el crecimiento de *Lactobacillus bulgaricus*, estableciendo una correlación entre el crecimiento bacteriano y la fermentación, como también lo indicaron Yao et al., (2022). No obstante,

los resultados obtenidos revelan que el porcentaje de inóculo no ejerce una influencia significativa sobre la acidez titulable de la leche ($p > 0.05$), lo que refuerza la hipótesis de que las condiciones de fermentación podrían ser más determinantes en el proceso.

Tabla 13

Análisis de varianza de acidez titulable según la concentración de inóculo

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Inóculo (%)	2	0.04554	0.022771	2.77	0.069
Error	78	0.64060	0.008213		
TOTAL	80	0.68614			

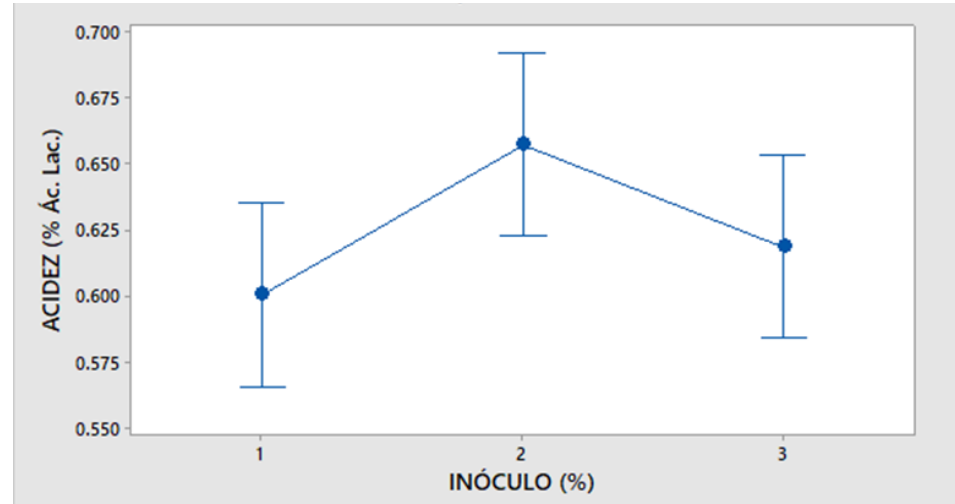
Tabla 14

Análisis y comparación Tukey para la variación de acidez titulable, según la variación de inóculo

Inóculo (%)	N	Media	Agrupación
2	27	0.6577	A
3	27	0.6190	A
1	27	0.6008	A

Figura 41

Intervalos de acidez (% ácido láctico) en función a las concentraciones de inóculo



4.3.2.3. Efecto de la temperatura en la acidificación de la leche

Las temperaturas de fermentación no mostraron un efecto significativo ($p > 0.05$) sobre la concentración final de acidez del yogur, como se puede observar en los resultados del análisis de varianza (ANOVA) presentados en la Tabla. 15. De manera complementaria, los resultados de la prueba de Tukey confirmaron que las medias de acidez no presentaron diferencias estadísticas significativas entre las distintas temperaturas de fermentación evaluadas, lo cual se detalla en la Tabla 16. Esto sugiere que, en este contexto experimental, la temperatura de fermentación no influyó de manera destacada en la acidez final del yogur. Los intervalos de acidez observados para las diferentes temperaturas de fermentación se ilustran en la Figura 42, lo que proporciona una representación visual clara de los resultados y refuerza la conclusión de que este factor no fue determinante en la variación de la acidez.



En comparación con los resultados reportados por Lopes et al. (2019), quienes llevaron a cabo la fermentación del yogur a temperaturas de entre 35 y 50°C, con valores de acidez comprendidos entre 0.5% y 0.90%, se sugiere que las temperaturas más elevadas podrían favorecer una mayor actividad de las bacterias lácticas, promoviendo así un incremento en la producción de ácido láctico. Del mismo modo, Barros et al. (2019) reportaron valores de acidez titulable en el rango de 0.64% a 0.73%, atribuyendo esta variabilidad a la acción de la lactosa y su posterior hidrólisis a temperaturas de 43°C. Por otro lado, Jakubowska & Karamucki (2020) informaron valores de acidez titulable entre 0.37% y 0.56%, los cuales resultan inferiores a los obtenidos en el presente estudio. Estas discrepancias podrían deberse a diferencias en las condiciones de fermentación o en las cepas bacterianas utilizadas.

Es importante resaltar que la variación en la temperatura de fermentación no solo influye en la acidez, sino también tiene un impacto considerable en los procesos fermentativos y en las características sensoriales del yogur. Sofyan et al. (2022b) indicaron que los yogures más suaves se obtienen cuando la fermentación se realiza a temperaturas entre 32 y 39°C, lo que sugiere que la temperatura no solo afecta la tasa de acidificación, sino también el proceso de formación del gel.

Los resultados evidencian que ni la concentración de inóculo ni la temperatura de fermentación parecen influir de manera significativa en la acidez final del yogur, bajo las condiciones experimentales evaluadas. No obstante, factores como la interacción entre cepas bacterianas o las

condiciones ambientales, tales como la temperatura del medio, podrían estar influyendo en el comportamiento ácido-láctico.

Tabla 15

Análisis de varianza de acidez titulable según las temperaturas de fermentación

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Temperatura (°C)	2	0.03346	0.016732	2.00	0.142
Error	78	0.65268	0.008368		
TOTAL	80	0.68614			


Tabla 16

Análisis y comparación Tukey para la variación de acidez titulable, según las temperaturas de fermentación

Temperatura (°C)	N	Media	Agrupación
36	27	0.6545	A
40	27	0.6127	A
44	27	0.6103	A

Figura 42

Intervalos de acidez (% ácido láctico) en función a las temperaturas de fermentación



4.3.3. Control de pH

El control del pH durante el proceso de fermentación se realizó utilizando técnicas convencionales. La fermentación de la leche se dio por finalizada cuando se alcanzó un pH de 4.6, valor referencial adoptado de los estudios realizados por Sözeri Atik et al., (2023).

En las Figuras 43, 44 y 45 se muestran las curvas de descenso del pH durante la fermentación de la leche a temperaturas de 36, 40 y 44°C, inoculadas con 1, 2 y 3% de cultivo láctico. Todos los procesos de fermentación concluyeron cuando el pH alcanzó valores entre 4.5 y 4.6, como lo recomiendan Aryana & Olson (2017). En este estudio, el tiempo fue empleado como un parámetro clave para monitorear el proceso de fermentación, mientras que el pH determinaba el punto final del mismo. Es decir, si el pH no alcanzaba el valor establecido, el proceso de fermentación continuaba. Las figuras muestran claramente el efecto significativo de la temperatura de fermentación sobre el tiempo necesario para alcanzar un pH de 4.6. Este efecto se demostró mediante un análisis de varianza (ANOVA), cuyos resultados se presentan en la Tabla 9, y fue complementado con la prueba de Tukey, cuyos resultados se encuentran en la Tabla 10.

Los resultados obtenidos evidencian una clara relación entre la disminución del pH, la temperatura de fermentación y el crecimiento de las bacterias ácido-lácticas. Al inicio del proceso, se observa una disminución lenta del pH, lo que correspondería a la fase de latencia, en esta fase la leche permanece aún en estado líquido. Posteriormente, se registra un descenso más abrupto del pH, que estaría asociado a la fase logarítmica del crecimiento de las bacterias ácido-lácticas. Este punto de inflexión, observado alrededor de un pH de 5.7, marca el inicio del proceso de gelificación, un comportamiento que coincide con



los estudios de Körzendörfer & Hinrichs, (2019), quienes señalaron una relación directa entre la disminución del pH y el desarrollo de la estructura del gel. Finalmente, se observa una desaceleración en la tasa de acidificación a partir de un pH de 5.0 hasta 4.8, prolongándose hasta llegar al pH de 4.6, lo que concuerda con los resultados descritos por Muncan et al. (2021). Comparativamente, estos resultados confirman la relación inversa entre la temperatura de incubación y el tiempo de fermentación: a mayor temperatura, menor es el tiempo necesario para alcanzar el pH de 4.6, tal como lo indicaron Sofyan et al. (2022).

El hecho de que el tiempo de fermentación sea inversamente proporcional a la temperatura sugiere que este parámetro no solo es crucial para la tasa de acidificación, sino también para optimizar la eficiencia del proceso industrial. Los datos obtenidos en este estudio respaldan hallazgos previos en la literatura y refuerzan la importancia del control preciso del pH como un indicador clave en la producción de yogur, que garantiza la calidad y las características sensoriales deseadas.

Figura 43

Curvas de pH de la leche con 4.2% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo




Figura 44

Curvas de pH de la leche con 4.5% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo





Figura 45

Curvas de pH de la leche con 4.8% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo



4.3.3.1. Efecto de la concentración proteica en el pH de la leche

Las diferentes concentraciones de proteína mostraron un efecto significativo ($p < 0.05$) en los valores de pH alcanzados al finalizar el proceso de fermentación. Este efecto se evidenció a través del análisis de varianza (ANOVA), cuyos resultados se presentan en la Tabla 17. La prueba de Tukey reveló que, a una concentración de proteína del 4.5%, el valor de pH fue significativamente menor en comparación con las concentraciones de 4.2% y 4.8%. Las diferencias entre los valores de pH obtenidos para las distintas concentraciones de proteína se presentan en la Tabla 18, mientras que los intervalos de pH en función de las concentraciones de proteína se ilustran en la Figura 46.

Al comparar los resultados obtenidos en este estudio con los reportados en investigaciones previas, se observa una notable similitud con los hallazgos de Wherry et al. (2019), quienes informaron valores de pH entre 4.3 y 4.61 en yogures enriquecidos con concentrado proteico. Estos resultados son consistentes con los tres tratamientos realizados en el presente estudio, lo que sugiere que el uso de concentrados proteicos puede mantener un rango de pH estable en diferentes formulaciones.

Por otro lado, Körzendörfer & Hinrichs (2019b), realizaron un tratamiento en el que incorporaron proteína de leche en polvo junto con un porcentaje de grasa, reportando valores de pH entre 4.60 y 4.80. Este estudio destaca que la inclusión de grasa, además de la proteína láctea, también influye en el pH del yogur, lo que subraya la relevancia de estos componentes en la formulación del producto. Asimismo, C. Wang et al. (2021) presentaron datos de pH que oscilan entre 4.15 y 4.56 en yogures



elaborados con proteína vegetal de soya. Estos resultados indican que el tipo de proteína utilizado puede tener un impacto significativo en el pH del yogur, lo que podría afectar tanto sus características sensoriales como nutricionales.

Los resultados obtenidos en este estudio confirman que la concentración de proteína tiene un efecto claro y significativo sobre el pH final del yogur, con la concentración de 4.5% mostró la mayor reducción de pH. Este hallazgo es consistente con estudios previos que señalan que el aumento en la concentración de proteínas, en particular proteínas lácteas, puede acelerar la acidificación del producto. El comportamiento observado puede atribuirse a la capacidad de las proteínas de la leche para interactuar con las bacterias ácido-lácticas, facilitando la producción de ácido láctico y, por ende, reduciendo el pH.

Además, las diferencias en los valores de pH entre proteínas lácteas y proteínas vegetales, como las reportadas en los estudios comparados, destacan que no solo la concentración, sino también el origen de la proteína juega un papel crucial en la dinámica de acidificación y en las propiedades finales del yogur. Las proteínas vegetales, por ejemplo, suelen generar un pH final más bajo, lo que podría estar vinculado a su menor capacidad de tamponamiento en comparación con las proteínas de origen animal.

Tabla 17

Análisis de varianza del pH según las concentraciones de proteína

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Proteína (%)	2	0.03682	0.018409	5.20	0.008
Error	78	0.27599	0.003538		
TOTAL	80	0.31280			

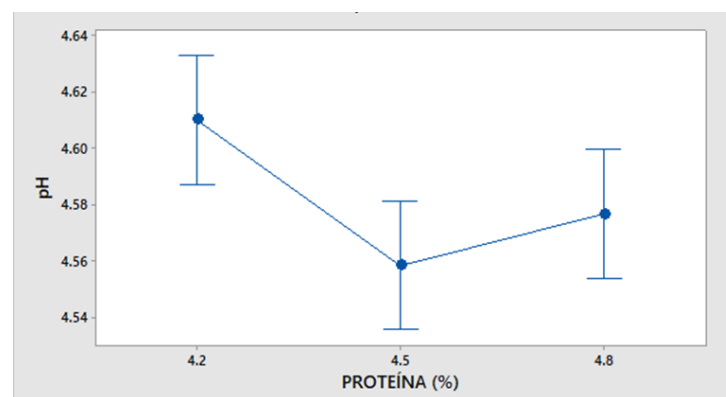
Tabla 18

Análisis y comparación Tukey para la variación de pH, según las concentraciones de proteína

Proteína (%)	N	Media	Agrupación
4.2	27	4.61000	A
4.8	27	4.5767	A B
4.5	27	4.5585	B

Figura 46

Intervalos de pH en función a las concentraciones de proteína



4.3.3.2. Efecto de la concentración de inóculo en el pH de la leche

Las diferentes concentraciones de inóculo empleadas en la elaboración del yogur no tuvieron un efecto significativo ($p > 0.05$) en los valores de pH al final del proceso de fermentación. Esta afirmación se



fundamenta en los resultados del análisis de varianza (ANOVA), que se presentan en la Tabla 19. La falta de significancia se explica por el hecho de que la fermentación se detuvo una vez que el pH alcanzó un valor cercano a 4.6, lo que resultó en valores de pH estadísticamente iguales. Esta conclusión fue corroborada mediante la prueba de Tukey, cuyos resultados se muestran en la Tabla 20, mientras que los intervalos de pH en los que culminó el proceso de fermentación se ilustran en la Figura 47.

Al comparar nuestros resultados con los reportados por Aita et al. (2015), quienes encontraron valores de pH que oscilaron entre 4.24 y 4.67 durante la elaboración de yogur, no se observan diferencias significativas. No obstante, es importante destacar que los valores obtenidos en dicho estudio fueron ligeramente inferiores a los reportados en nuestra investigación. Shu et al. (2014) señalan que una mayor concentración de inóculo puede acelerar la velocidad de producción de ácidos, observando en su estudio que, con un inóculo del 1%, la producción de ácido se incrementa lentamente durante las primeras tres horas, seguida de un aumento más rápido, lo que provoca una disminución pronunciada del pH.

El hecho de que las concentraciones de inóculo no presenten un efecto significativo sobre el pH final en este estudio puede estar relacionado con la naturaleza autorreguladora del proceso de fermentación, en el cual las bacterias ácido-lácticas continúan produciendo ácido hasta alcanzar un punto de equilibrio, determinado por un pH de aproximadamente 4.6. Este valor de pH actúa como un límite que define la finalización de la fermentación, independientemente de la concentración inicial de inóculo.

Sin embargo, cabe destacar que, aunque el inóculo no influye significativamente en el pH final, puede tener un impacto en otras fases del proceso, como la velocidad de acidificación. En estudios como el de Shu et al. (2014), se ha observado que la tasa de producción de ácido es mayor a concentraciones más elevadas de inóculo, lo que sugiere que el inóculo podría ser más relevante en la fase inicial o media de la fermentación, antes de que el pH alcance el valor de corte.

Tabla 19

Análisis de varianza del pH según las concentraciones de inóculo

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Inóculo (%)	2	0.001106	0.000553	0.14	0.871
Error	78	0.311697	0.003996		
TOTAL	80	0.312803			


Tabla 20

Análisis y comparación Tukey para la variación del pH, según las concentraciones de inóculo

Inóculo (%)	N	Media	Agrupación
2	27	4.58667	A
1	27	4.5807	A
3	27	4.5778	A

Figura 47

Intervalos de pH en función a las concentraciones de inóculo



4.3.3.3. Efecto de la temperatura en el pH de la leche

La temperatura es un factor que influye directamente en la actividad metabólica y el desarrollo de las bacterias ácido-lácticas. Este efecto significativo ($p < 0.05$) se demuestra mediante el análisis de varianza (ANOVA), cuyos resultados se presentan en la Tabla 21. Los controles de pH para todos los tratamientos se realizaron cada 10 minutos, y el proceso de fermentación culminó cuando el pH se acercó al valor preestablecido de 4.6. El análisis estadístico revela que el descenso del pH es más lento a una temperatura de 36°C en cada intervalo de muestreo, lo que permite una mayor precisión en el control de la finalización del proceso de fermentación al alcanzar el pH deseado. En contraste, a temperaturas de 40 y 44°C, el descenso del pH es más rápido en el mismo intervalo de tiempo, lo que resultó en un mayor descenso respecto al valor preestablecido. Estas diferencias se corroboraron mediante la prueba de Tukey, cuyos resultados se detallan en la Tabla 22. Además, los intervalos de pH alcanzados en función de las temperaturas de fermentación se ilustran en la Figura 48.



Los resultados obtenidos evidencian una clara relación entre la disminución del pH, la temperatura de fermentación y el crecimiento de las bacterias ácido-lácticas. Inicialmente, se observa una disminución lenta del pH, que podría corresponder a la fase de latencia, en la que la leche permanece en estado líquido. Posteriormente, se registra un descenso abrupto del pH, asociado a la fase logarítmica de crecimiento de las bacterias ácido-lácticas. Este punto de inflexión en la curva de acidificación, que ocurre alrededor de un pH de 5.7, marca el inicio de la gelificación, un comportamiento coincidente con los hallazgos de Körzendörfer & Hinrichs, (2019), quienes indicaron que existe una relación directa entre la disminución del pH y el desarrollo de la estructura del gel. Finalmente, se alcanzó una fase de desaceleración en la tasa de acidificación, con una disminución más lenta del pH desde 5.0 hasta 4.6, lo que coincide con los resultados descritos por Muncan et al. (2021). Además, se observó que, cuanto mayor es la temperatura de incubación, menor es el tiempo necesario para alcanzar el pH objetivo, lo que concuerda con lo señalado por Sofyan et al. (2022), quienes también indicaron que la proteína influye en la acidificación del yogur.

Los resultados obtenidos en este estudio refuerzan la importancia de la temperatura como un factor clave en la cinética de la acidificación durante la fermentación del yogur. El hecho de que la disminución del pH sea más lenta a 36°C podría estar asociado con una menor actividad enzimática y un crecimiento bacteriano más gradual, lo que permite un mayor control sobre el proceso de fermentación. Este hallazgo es crucial en términos de optimización industrial, ya que una fermentación más

controlada a bajas temperaturas podría mejorar las propiedades sensoriales y estructurales del yogur, evitando una acidificación excesiva que podría afectar negativamente su textura y sabor.

Por otro lado, la rápida caída del pH a 40°C y 44°C indica menor tiempo de procesamiento. Sin embargo, esta situación podría resultar en una acidez excesiva que afecte negativamente las características sensoriales y nutricionales del yogur. Estos resultados subrayan la necesidad de equilibrar cuidadosamente la velocidad de fermentación con la precisión en el control del pH para garantizar que el producto final cumpla con los estándares de calidad deseados, preservando tanto sus propiedades organolépticas como su seguridad microbiológica. Además, es fundamental optimizar los tiempos de fermentación para maximizar la eficiencia sin comprometer la calidad del yogur.

Tabla 21

Análisis de varianza del pH según las temperaturas de fermentación

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Temperatura (°C)	2	0.03426	0.017131	4.80	0.011
Error	78	0.27854	0.003571		
TOTAL	80	0.31280			


Tabla 22

Análisis y comparación Tukey para la variación del pH según las temperaturas de fermentación

Temperatura (°C)	N	Media	Agrupación
36	27	4.60667	A
40	27	4.5822	A B
44	27	4.55630	B

Figura 48

Intervalos de pH en función a las temperaturas de fermentación



4.3.6. Control de viscosidad

La formación de la viscosidad durante la fermentación de la leche es un factor crucial para determinar la calidad del yogur. Este parámetro está influenciado por la concentración de sólidos, el contenido proteico y la temperatura de fermentación, que en conjunto promueven una adecuada formación de la estructura del gel. Según Walstra et al. (2006), la firmeza del yogur aumenta conforme el pH disminuye, ya que este alimento es un fluido no newtoniano cuya viscosidad aparente disminuye con el aumento de la velocidad de cizallamiento.

Los resultados, representados en las Figuras 49, 50 y 51, muestran que la viscosidad se mantiene estable durante gran parte de la fermentación debido al efecto del cizallamiento aplicado en el muestreo. Este cizallamiento reduce temporalmente la firmeza del yogur por su naturaleza no newtoniana. No obstante, hacia el final del proceso, cuando el pH se aproxima al punto isoeléctrico de la caseína ($\text{pH} < 5,2$), se registra un aumento significativo de la viscosidad. En esta fase, las caseínas precipitan y forman una red tridimensional de gel junto con proteínas séricas.



Inicialmente, las micelas de caseína permanecen dispersas, estabilizando la mezcla. A medida que el pH desciende, estas micelas se desestabilizan, agregándose para generar una estructura de gel. Este cambio estructural, observable cerca del punto isoeléctrico, incrementa abruptamente la viscosidad. Además, el comportamiento no newtoniano permite que las fuerzas de cizallamiento reduzcan temporalmente la resistencia del gel en formación, pero su influencia disminuye una vez que el gel adquiere suficiente fortaleza, resultando en un aumento marcado de la viscosidad al final del proceso.

Figura 49

Curvas de viscosidad de la leche con 4.2% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo




Figura 50

Curvas de viscosidad de la leche con 4.5% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo





Figura 51

Curvas de viscosidad de la leche con 4.8% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo



4.3.6.1. Efecto de la concentración proteica en la viscosidad de la leche

El efecto de la concentración proteica de la leche sobre los valores de viscosidad en el yogur fue evaluado mediante un análisis de varianza (ANOVA). Los resultados, presentados en la Tabla 23, indican que la cantidad de proteína en la leche afecta significativamente ($p < 0.05$) el valor de la viscosidad.

Este mismo efecto ha sido observado en otros estudios. Por ejemplo, Mitra et al. (2022) documentaron que, durante la elaboración de yogur con suero de leche y proteína vegetal, la formación de la red proteica mejoraba significativamente, alcanzando rangos de viscosidad de entre 1220 y 2580 mPa/s. Asimismo, Najgebauer-Lejko et al. (2020b) reportaron valores de viscosidad entre 2000 y 3000 mPa/s en yogures con inclusiones de té, lo que sugiere que la interacción de los polifenoles del té con las proteínas lácteas incrementa la viscosidad del producto. Hashim et al. (2021) también señalaron que la viscosidad del yogur aumenta con la concentración de proteínas, obteniendo valores de entre 450 y 2880 mPa/s. En contraste, Lu et al. (2023) encontraron que la adición de almidón en la producción de yogur redujo significativamente la viscosidad a valores de entre 350 y 1610 mPa/s, lo que atribuyeron a la limitada capacidad de hidrólisis del almidón.

Estos resultados están en línea con los obtenidos en el presente estudio, donde se observó una disminución de la viscosidad a medida que se reducía la concentración de proteína en los tratamientos. Esto sugiere que la concentración proteica es un factor determinante en la viscosidad



del yogur, ya que una menor concentración de proteína resulta en una red proteica menos densa, lo que disminuye la viscosidad.

El análisis de Tukey también confirmó el efecto significativo de las diferentes concentraciones proteicas sobre la viscosidad, tal como se detalla en la Tabla 24. Los intervalos de viscosidad en función de las concentraciones de proteína se presentan en la Figura 52.

El comportamiento observado en este estudio subraya la importancia de la concentración proteica en la determinación de las propiedades reológicas del yogur. La proteína desempeña un papel crucial en la formación de la estructura de gel durante la fermentación, y su concentración influye directamente en la densidad y estabilidad de dicha red. A medida que aumenta la concentración de proteína, se genera una mayor cantidad de enlaces entre las moléculas proteicas, lo que refuerza la estructura del gel y eleva la viscosidad del yogur. Esto se refleja en el aumento progresivo de la viscosidad a mayores concentraciones proteicas, lo que coincide con los estudios previos citados.

Por otro lado, la reducción de la viscosidad en yogures con concentraciones proteicas menores se debe a la menor disponibilidad de proteínas para formar enlaces que estabilicen la red tridimensional del gel. Esta menor densidad proteica provoca una disminución en la resistencia del gel frente al cizallamiento, resultando en una textura más líquida y una menor viscosidad.

Tabla 23

Análisis de varianza de la viscosidad según las concentraciones

proteicas

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Proteína (%)	2	748171	374086	56.98	0.000
Error	78	512057	6565		
TOTAL	80	1260229			

Tabla 24


Análisis y comparación Tukey para la variación de la viscosidad según

las concentraciones proteicas

Proteína (%)	N	Media	Agrupación
4.8	27	1621.6	A
4.5	27	1479.9	B
4.2	27	1387.92	C

Figura 52

Intervalos de la viscosidad en función a las concentraciones proteicas



4.3.6.2. Efecto de la concentración de inóculo en la viscosidad de la leche

La actividad metabólica del inóculo es fundamental en la producción de ácido láctico, desencadenando la precipitación de las caseínas y la formación de redes tridimensionales, un proceso conocido como gelificación. Este fenómeno puede evaluarse mediante el esfuerzo de corte requerido para deformar la estructura formada. Para determinar el efecto de diferentes concentraciones de inóculo sobre la viscosidad del yogur, se realizó un análisis de varianza (ANOVA). Los resultados, presentados en la Tabla 25, muestran un efecto significativo ($p < 0.05$) de las concentraciones de inóculo sobre la viscosidad. La prueba de Tukey, detallada en la Tabla 26, confirmó que una concentración de inóculo del 3% genera yogures con mayor viscosidad que los elaborados con un 1%. Los intervalos de viscosidad obtenidos para cada concentración de inóculo se ilustran en la Figura 53.

Los valores de viscosidad obtenidos en este estudio, que oscilan entre 1440 y 1543 mPa/s, se alinean con los reportados por Celik & Temiz (2022), quienes destacaron que la capacidad de los cultivos iniciadores para producir exopolisacáridos está estrechamente vinculada con la viscosidad del yogur. Por su parte, Horiuchi & Sasaki (2012) analizaron la interacción entre *Lactobacillus bulgaricus* y *Streptococcus thermophilus*, observando que el formiato producido por *Streptococcus* estimula el crecimiento de *Lactobacillus*, acelerando la fermentación a 43°C. Sin embargo, no identificaron un efecto significativo sobre la viscosidad al emplear proporciones iguales de ambas bacterias, concordando con los

hallazgos de Aita et al. (2015). Esto sugiere que, aunque la simbiosis bacteriana optimiza la fermentación, la viscosidad final depende de otros factores, como la capacidad de producción de exopolisacáridos y la concentración proteica.

Estudios recientes, como los de Mitra et al. (2022) y Lu et al. (2023), reportaron viscosidades entre 350 y 2580 mPa/s en yogures con diferentes combinaciones de proteínas y cultivos iniciadores, respaldando los resultados del presente trabajo. El impacto del inóculo sobre la viscosidad se relaciona directamente con su capacidad para producir ácido láctico y exopolisacáridos, ambos esenciales para la formación de la red gelificada. En este estudio, el inóculo al 3% demostró un efecto significativo en la viscosidad final, fortaleciendo la estructura proteica del yogur. Aunque otros factores, como la composición proteica y las proporciones bacterianas, también influyen, la capacidad de ciertos cultivos para generar exopolisacáridos emerge como una clave determinante en la calidad final del producto.

Tabla 25

Análisis de varianza de la viscosidad según las concentraciones de inóculo

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Inóculo (%)	2	120892	60446	4.14	0.020
Error	78	1139336	14607		
TOTAL	80	1260229			


Tabla 26

Análisis y comparación Tukey para la variación de la viscosidad según las concentraciones de inóculo

Inóculo (%)	N	Media	Agrupación
3	27	1543.6	A
2	27	1496.8	A B
1	27	1449.0	B

Figura 53

Intervalos de la viscosidad en función a las concentraciones de inóculo



4.3.6.3. Efecto de la temperatura en la viscosidad de la leche

Otro de los factores determinantes en la producción de yogur es la temperatura de fermentación. Su efecto sobre la viscosidad del yogur fue evaluado mediante un análisis de varianza (ANOVA), cuyos resultados se presentan en la Tabla 27. El análisis estadístico demuestra que las temperaturas de fermentación evaluadas tienen un efecto significativo ($p < 0.05$) en la formación de la viscosidad del yogur. La prueba de Tukey (Tabla 28) confirmó que la fermentación a 36°C resulta en una mayor

viscosidad en comparación con las demás temperaturas. Este resultado concuerda con lo señalado por Yang et al. (2021c), quienes afirman que, entre 32°C y 39°C, el yogur presenta una textura más viscosa, suave y agradable.

En la Figura 54 se muestran los intervalos de viscosidad obtenidos a diferentes temperaturas de fermentación, destacando particularmente el intervalo correspondiente a 36°C. Estos resultados indican que la temperatura de fermentación es un factor crucial en la determinación de la viscosidad final del yogur.

Al contrastar los resultados de este estudio con los de Aldaw Ibrahim et al. (2019), quienes evaluaron temperaturas de fermentación de 40, 43 y 46°C, se observaron valores de viscosidad significativamente más bajos, entre 672 y 993 mPa/s, en comparación con los obtenidos en nuestra investigación. Esta diferencia podría deberse a condiciones específicas de fermentación o a las variaciones en los ingredientes utilizados, lo que subraya la importancia de la temperatura en la modificación de las propiedades reológicas del yogur. Por otro lado, Yang et al. (2021d) evaluaron la fermentación a temperaturas de 30, 37, 40, 42 y 45°C, obteniendo los mejores resultados de viscosidad a 37°C. Aunque nuestro estudio no incluye esta temperatura específica, es interesante notar que la viscosidad óptima reportada por Yang et al. (2021d) coincide con el rango de temperaturas utilizadas en nuestra investigación, lo que sugiere que la temperatura de fermentación es un factor crítico para alcanzar una viscosidad adecuada.

Hadi A. et al. (2017) también analizaron la viscosidad durante el almacenamiento del yogur, reportando valores entre 1057 y 2159 mPa/s. Al comparar estos resultados con los de nuestro estudio, se observa que los valores de viscosidad son consistentes, lo que sugiere que el comportamiento de la viscosidad durante el almacenamiento en ambos estudios es similar.

El impacto de la temperatura sobre la viscosidad del yogur ha sido ampliamente estudiado debido a su influencia en la estructura del gel proteico y en la actividad de los cultivos iniciadores. En este estudio, se observó un efecto significativo de la temperatura de fermentación, destacando que a 36°C se obtienen los valores de viscosidad más altos. Este hallazgo es coherente con la literatura existente, en la que se menciona que temperaturas moderadas permiten una formación más estable de la red proteica, promoviendo una mayor viscosidad.

Las diferencias observadas en los valores de viscosidad reportados por otros estudios podrían estar vinculadas a factores como el tipo de proteína empleada, la cepa de cultivos iniciadores y las condiciones de almacenamiento.

Tabla 27

Análisis de varianza de la viscosidad según las temperaturas de fermentación

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Temperatura (°C)	2	296872	148436	12.02	0.000
Error	78	963357	12351		
TOTAL	80	1260229			

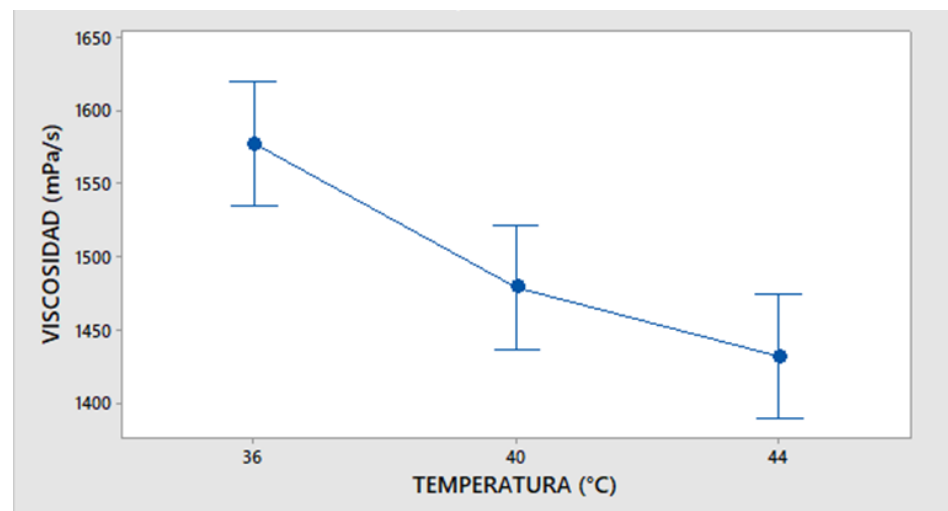
Tabla 28

Análisis y comparación Tukey para la variación de la viscosidad según las temperaturas de fermentación

Temperatura (°C)	N	Media	Agrupación
36	27	1577.6	A
40	27	1479.5	B
44	27	1432.3	B

Figura 54

Intervalos de la viscosidad en función a las temperaturas de fermentación



4.3.7. Control de variaciones de color CIELab

Las mediciones de color se realizaron cada 10 minutos durante la fermentación, observando incrementos en los valores L^* , a^* y b^* . Los resultados, ilustrados en las Figuras 55, 56 y 57, muestran ligeras variaciones en el color a lo largo del proceso. El análisis estadístico indicó diferencias significativas entre los tratamientos ($p < 0.05$), atribuyendo mayor influencia al porcentaje de proteína y

la temperatura de fermentación, que provocaron aumentos notables en los parámetros de color L^* , a^* y b^* .

Figura 55

Curvas de color de la leche con 4.2% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo




Figura 56

Curvas de color de la leche con 4.5% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo





Figura 57

Curvas de color de la leche con 4.8% de proteína fermentada a distintas temperaturas (36, 40 y 44°C) y en porcentajes de inóculo: a) 1% de inóculo, b) 2% de inóculo y c) 3% de inóculo



4.3.7.1. Efecto de la concentración proteica en valores de L^* , a^* y b^*

- Efecto en L^*

Las diferentes concentraciones de proteína ejercen un efecto significativo ($p < 0.05$) sobre el valor L^* del color en la escala CIELab, como se evidencia en el análisis de varianza (ANOVA) presentado en la Tabla 29. Este efecto ha sido respaldado por los hallazgos de Du et al. (2021), quienes también reportan variaciones en el valor de luminosidad en función de las concentraciones proteicas en yogur convencional.

Al comparar los resultados obtenidos, que oscilan entre 84.99 y 85.69, con los reportados en investigaciones previas, se observa una similitud con los valores encontrados por Akgun et al. (2018), quienes documentaron valores de L^* entre 84.77 y 85.45 en yogures enriquecidos con probióticos, cifras comparables a las obtenidas en este estudio. De manera similar, Wherry et al. (2019) evaluaron el uso de proteínas de suero de leche ácida, dulce y descremada en la producción de yogur, reportando valores de L^* entre 81.76 y 82.42, lo que evidencia que la inclusión de estas proteínas también afecta la luminosidad del producto.

A través de la prueba de Tukey, se determinó que la concentración de proteína del 4.2 y 4.5% generaron el valor máximo de L^* , como se muestra en la Tabla 30. En la Figura 58 se ilustran los intervalos de los valores de L^* para las distintas concentraciones proteicas.

La similitud entre los resultados obtenidos y los reportados en la literatura puede atribuirse a la influencia de las concentraciones proteicas sobre la estructura del yogur, la cual afecta el comportamiento del color del producto. Esta interacción, que reduce el valor de L^* , se debe

probablemente a los cambios en la dispersión y absorción de luz provocados por la mayor densidad proteica en la matriz del yogur.

Tabla 29

Análisis de varianza del valor L^ según las concentraciones proteicas*

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Proteína (%)	2	7.043	3.5215	9.50	0.000
Error	78	28.919	0.3708		
TOTAL	80	35.962			


Tabla 30

Análisis y comparación Tukey para la variación del valor L^ según las concentraciones proteicas*

Proteína (%)	N	Media	Agrupación
4.2	27	85.697	A
4.5	27	85.478	A
4.8	27	84.9911	B

Figura 58

Intervalos del valor L^ en función a las concentraciones proteicas*



- **Efecto en a***

Las diferentes concentraciones de proteína, según el análisis de varianza (ANOVA) presentado en la Tabla 31, tienen un efecto significativo ($p < 0.05$) sobre el valor a* del color en la escala CIELab, con valores que oscilan entre -2.86 y -2.34. Este efecto ha sido corroborado por los resultados de Wherry et al. (2019).

A través de la prueba de Tukey, se determinó que una concentración del 4.8% de proteína alcanzó el valor máximo del componente a*, tal como se muestra en la Tabla 32. En la Figura 59 se ilustran los intervalos de los valores de a* correspondientes a las diferentes concentraciones proteicas.

Al comparar nuestros resultados con otras investigaciones, se observa que Wherry et al. (2019) reportaron valores de a* entre -2.71 y -1.03 en yogures elaborados con suero de leche ácido, descremado y dulce, lo cual es consistente con los hallazgos de este estudio. De manera similar, Akgun et al. (2018) reportaron valores que oscilan entre -2.71 y -2.28 en yogures con probióticos, datos que también son comparables a los obtenidos en este estudio. Además, Du et al. (2021), en su investigación sobre yogures con adición de colorantes naturales como cúrcuma, pulpa de fresa y una muestra sin colorantes, reportaron valores cercanos (-2.99 ± 0.06), lo que refuerza la similitud con los datos obtenidos en este estudio.

En definitiva, las concentraciones proteicas tienen un impacto directo sobre el valor del componente a*. La coherencia entre los valores de este estudio y los reportados en la literatura indica que el uso de diferentes concentraciones de proteína es un factor clave en la modulación de las propiedades colorimétricas del yogur. Estos hallazgos aportan

evidencia adicional sobre el efecto de la composición proteica para mantener características físicas deseadas en productos lácteos fermentados.

Tabla 31

Análisis de varianza del valor a^ según las concentraciones proteicas*

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Proteína (%)	2	3.712	1.85590	19.17	0.000
Error	78	7.552	0.09682		
TOTAL	80	11.264			


Tabla 32

Análisis y comparación Tukey para la variación del valor a^ según las concentraciones proteicas*

Proteína (%)	N	Media	Agrupación
4.8	27	-2.3400	A
4.5	27	-2.6300	B
4.2	27	-2.8633	C

Figura 59

Intervalos del valor a^ en función a las concentraciones proteicas*



- **Efecto en b***

Las diferentes concentraciones de proteína, de acuerdo con el análisis de varianza (ANOVA) presentado en la Tabla 32, tienen un efecto significativo ($p < 0.05$) sobre el valor b* del color en la escala CIELab, con valores que oscilan entre 3.45 y 4.56. Este efecto ha sido corroborado por los resultados de Guerra et al. (2022).

Mediante la prueba de Tukey, se identificó que una concentración de proteína del 4.8% generó el valor máximo de b*, como se muestra en la Tabla 34. En la Figura 60 se ilustran los intervalos de los valores de b* correspondientes a las distintas concentraciones proteicas.

Al comparar nuestros resultados con investigaciones previas, Wherry et al. (2019) reportaron valores de b* entre 5.73 y 8.32 en yogures elaborados con suero de leche ácido, leche descremada y suero de leche dulce, resultados que superan a los obtenidos en este estudio. Sin embargo, Pan-utai et al. (2020) encontraron valores de b* que oscilan entre 4 y 5 en yogures de leche fresca de vaca fermentada, sin aditivos, lo que es más comparable con los resultados de nuestro estudio.

El análisis de los valores del componente b*, demuestra que es sensible a los cambios en la concentración proteica. Es posible que la mayor concentración de proteínas promueva una mayor interacción con la luz, alterando las propiedades reflectantes del yogur y, por ende, su percepción cromática. La diferencia entre los resultados obtenidos y los reportados por Wherry et al. (2019) podría deberse a diferencias en la composición de las muestras, como la inclusión de aditivos o la variación en el tipo de leche utilizada. Estos factores son fundamentales para

entender el comportamiento cromático y deben ser considerados al interpretar los efectos de la proteína en productos lácteos.

Tabla 33

Análisis de varianza del valor b^ según las concentraciones proteicas*

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Proteína (%)	2	16.88	8.4404	25.95	0.000
Error	78	25.37	0.3253		
TOTAL	80	42.25			


Tabla 34

Análisis y comparación Tukey para la variación del valor b^ según las concentraciones proteicas*

Proteína (%)	N	Media	Agrupación
4.8	27	4.562	A
4.5	27	3.870	B
4.2	27	3.456	C

Figura 60

Intervalos del valor b^ en función a las concentraciones proteicas*



4.3.7.2. Efecto de la concentración de inóculo en valores de L^* , a^* y b^*

- **Efecto en L^***

Los diferentes porcentajes de inóculo aplicados para la fermentación de la leche, de acuerdo con el análisis de varianza (ANOVA) presentado en la Tabla 35, no muestran un efecto significativo ($p > 0.05$) sobre el valor L^* del color en la escala CIELab, con valores que oscilan entre 85.21 y 85.49. Este resultado fue corroborado por los hallazgos de Aldaw Ibrahim et al. (2019).

Mediante la prueba de Tukey se pudo verificar que para todas las concentraciones de inóculo el valor del componente L^* fue constante, estos datos comparativos se muestran en la Tabla 36. Mientras que en la Figura 61 se ilustra los intervalos de los valores de L^* para las diferentes concentraciones proteicas.

Al comparar los resultados obtenidos con estudios previos de Ścibisz et al. (2019b), quienes reportaron valores de luminosidad entre 72.3 y 76.3, los cuales son inferiores a los de este estudio. Por otro lado, Dimitreli et al. (2014), registraron valores de L^* entre 90.12 y 92.47 al utilizar un concentrado de inóculo al 1% y caseína de sodio, lo que resultó en valores significativamente más altos que los obtenidos en este estudio, probablemente debido a la adición de caseína. Asimismo, Du et al. (2021) informaron que el valor de luminosidad en un yogur convencional es de 77.44 ± 0.22 , también por debajo de los valores reportados en este trabajo. Esta diferencia podría atribuirse al efecto de otros parámetros que influyen en el valor de L^* .

La ausencia de un efecto significativo del inóculo sobre el valor L^* sugiere que, dentro de los rangos analizados, la concentración de inóculo no es un factor determinante en la luminosidad del yogur. Además, la variabilidad en los resultados de estudios previos indica que los métodos de producción, así como la calidad de los ingredientes utilizados, juegan un papel crucial en la determinación del color del yogur.

Tabla 35

Análisis de varianza del valor L^ según las concentraciones de inóculo*

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Inóculo (%)	2	1.182	0.5912	1.33	0.271
Error	78	34.780	0.4459		
TOTAL	80	35.962			


Tabla 36

Análisis y comparación Tukey para la variación del valor L^ según las concentraciones de inóculo*

Inóculo (%)	N	Media	Agrupación
1	27	85.491	A
2	27	85.456	A
3	27	85.219	A

Figura 61

Intervalos del valor L^ en función a las concentraciones de inóculo*



- **Efecto en a^***

El análisis de varianza (ANOVA) presentado en la Tabla 37 muestra que los diferentes porcentajes de inóculo utilizados en la fermentación de la leche no tienen un efecto significativo ($p > 0.05$) sobre el valor a^* del color en la escala CIELab. Sin embargo, la prueba de Tukey, reflejada en la Tabla 38, identificó que un 1% de inóculo permite alcanzar el valor máximo del componente a^* . La Figura 62 ilustra los intervalos de los valores de a^* para las distintas concentraciones proteicas.

Los valores de a^* obtenidos en este estudio (-2.86 a -2.34) son consistentes con los reportados por Wherry et al. (2019), quienes registraron valores entre -2.71 y -1.03 en yogures elaborados con un 1% de inóculo. Por el contrario, Aldaw Ibrahim et al. (2019) observaron una mayor variabilidad (-8.30 a 7.83) al emplear porcentajes de inóculo del 5, 10 y 15%, lo que sugiere que cantidades más elevadas de inóculo pueden influir significativamente en el componente a^* . Por otro lado, Du et al. (2021) reportaron valores (-2.99 ± 0.06) en yogures con colorantes naturales similares, lo que refuerza la similitud con los resultados obtenidos.

Guerra et al. (2022) documentaron variaciones en el valor a^* durante el almacenamiento de yogur natural, con cambios de -2.26 ± 0.306 a -2.105 ± 0.120 en un período de 21 días. Estos resultados coinciden con los obtenidos en este estudio, destacando que el porcentaje de inóculo no tiene un impacto significativo en el valor a^* , debido a que no afecta directamente las propiedades sensoriales relacionadas con el color. Las discrepancias observadas en estudios previos subrayan la complejidad de los factores que influyen en la coloración del yogur.

Tabla 37

Análisis de varianza del valor a^ según las concentraciones de inóculo*

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Inóculo (%)	2	0.8078	0.4039	3.01	0.050
Error	78	10.4558	0.1340		
TOTAL	80	11.2636			


Tabla 38

Análisis y comparación Tukey para la variación del valor a^ según las concentraciones de inóculo*

Inóculo (%)	N	Media	Agrupación
1	27	-2.4967	A
3	27	-2.5967	A B
2	27	-2.7400	B

Figura 62

Intervalos del valor a^ en función a las concentraciones de inóculo*



- **Efecto en b^***

Los diferentes porcentajes de inóculo empleados para la fermentación de la leche, según el análisis de varianza (ANOVA) presentado en la Tabla 39, no tienen un efecto significativo ($p > 0.05$) sobre el valor b^* del color en la escala CIELab, con valores que oscilan entre -2.74 y -2.49. Este resultado ha sido corroborado por Wherry et al. (2019).

La prueba comparativa de Tukey permitió ratificar que el yogur elaborado con diferentes concentraciones de inóculo tiene el mismo valor del componente b^* lo cual se muestra en la Tabla 40. Mientras que en la Figura 63 se ilustra los intervalos de los valores de b^* para las diferentes concentraciones de inóculo.

Al comparar los resultados obtenidos con los estudios de Akgun et al. (2018), quienes investigaron yogures con cultivos probióticos en leche de búfala y obtuvieron valores de b^* entre 12 y 14, se observa que la diferente composición química de la leche utilizada influye considerablemente en el color del yogur. En otro estudio, Aldaw Ibrahim

et al. (2019) reportaron valores de b^* que variaron entre 23.63 y 42.33 en yogures elaborados con leche de vaca y cabra, empleando diferentes porcentajes de inóculo, lo que demuestra un efecto claro del inóculo sobre las propiedades fisicoquímicas del yogur. Por otro lado, Pan-utai et al. (2020) encontraron valores de b^* entre 4 y 5 en yogur de leche fresca de vaca fermentada, sin aditivos, resultados que se asemejan más a los obtenidos en nuestro estudio.

Los resultados obtenidos indican que estadísticamente no existe una diferencia significativa entre los tratamientos, lo cual es comprensible, ya que se utilizaron inóculo de la misma especie. Las diferentes concentraciones de inóculo empleadas no afectaron al valor del componente b^* del producto final, lo que permite afirmar que los tratamientos son similares mas no idénticos de acuerdo con la Tabla 40.

Tabla 39

Intervalos valor b^ en función a las concentraciones de inóculo*

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Inóculo (%)	2	2.102	1.0512	2.04	0.137
Error	78	40.149	0.5147		
TOTAL	80	42.251			


Tabla 40

Análisis y comparación Tukey para la variación del valor b^ según las concentraciones de inóculo*

Inóculo (%)	N	Media	Agrupación
1	27	4.173	A
3	27	3.932	A
2	27	3.782	A

Figura 63

Intervalos del valor b^ en función a las concentraciones de inóculo*



4.3.7.3. Efecto de la temperatura en los valores de L^* , a^* y b^*

- **Efecto en L^***

Las diferentes variaciones de temperatura (36, 40 y 44°C) aplicadas durante la fermentación de la leche, de acuerdo con el análisis de varianza (ANOVA) presentado en la Tabla 41, muestran valores entre 85.07 y 85.79. Estos resultados evidencian un efecto significativo ($p < 0.05$) sobre el valor L^* del color en la escala CIELab, lo cual es consistente con lo reportado por Akgun et al. (2018).

Mediante la prueba de Tukey se determinó que, a una temperatura de 44°C, el valor L^* alcanzó su máximo, como se detalla en la Tabla 42. Además, en la Figura 64 se ilustran los intervalos de los valores de L^* para las diferentes concentraciones proteicas.

Al comparar nuestros resultados con los reportados en la literatura, se observa una coincidencia con los hallazgos de Akgun et al. (2018), quienes reportaron valores de L^* entre 84.77 y 85.45 para yogures fermentados a 42°C, valores comparables con los obtenidos en este



estudio. Por su parte, Aldaw Ibrahim et al. (2019) estudiaron los efectos de temperaturas de fermentación de 40, 43 y 46°C, obteniendo valores de luminosidad similares a los resultados obtenidos. Asimismo, la investigación de Wijesekara et al. (2022), que exploró el uso de pigmentos vegetales (cúrcuma, espinaca y guisante azul) en yogur fermentado a 44°C, reportó valores de luminosidad en el primer día de almacenamiento comparables a los obtenidos en el presente estudio.

Por otro lado, Ścibisz et al. (2019b) documentaron valores de luminosidad entre 72.3 y 76.3 a una temperatura de 37°C, cifras inferiores a las observadas en este trabajo. En cambio, Dimitreli et al. (2014), reportaron valores superiores, entre 90.12 y 92.47 a 42°C, posiblemente debido al uso de caseína de sodio, lo que incrementó la luminosidad del yogur fermentado. Finalmente, Du et al. (2021) informaron que un yogur convencional fermentado a 42°C tiene un valor de L^* de 77.44 ± 0.22 , por debajo de los valores obtenidos en este estudio, lo que podría explicarse por la influencia de la temperatura en los tratamientos. En general, todos los tratamientos estudiados muestran valores de luminosidad que se encuentran dentro del rango de las especificaciones mencionadas en las investigaciones citadas.

Por consiguiente, se puede afirmar que los tratamientos evaluados en este estudio muestran que las variaciones de temperatura aplicadas durante la fermentación afectan de manera significativa el valor L^* del yogur, encontrándose dentro del rango de las especificaciones reportadas en estudios previos. El incremento en la temperatura parece contribuir a

una mayor luminosidad del producto, lo que refleja el efecto directo de la temperatura de fermentación sobre las propiedades ópticas del yogur.

Tabla 41

Análisis de varianza del valor L^ según las temperaturas de fermentación*

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Temperatura (°C)	2	7.168	3.5842	9.71	0.000
Error	78	28.794	0.3692		
TOTAL	80	35.962			


Tabla 42

Análisis y comparación Tukey para la variación del valor L^ según las temperaturas de fermentación*

Temperatura (°C)	N	Media	Agrupación
44	27	85.790	A
40	27	85.297	B
36	27	85.079	B

Figura 64

Intervalos del valor L^ en función a las temperaturas de fermentación*



- **Efecto en a^***

El impacto de la temperatura de fermentación sobre el componente cromático a^* fue evaluado mediante un análisis de varianza (ANOVA), cuyos resultados se encuentran en la Tabla 43. Los valores observados, que varían entre -2.67 y -2.50, indican que la temperatura de fermentación no tiene un efecto significativo sobre el valor de a^* en la escala CIELab ($p > 0.05$). Estos resultados están alineados con los hallazgos de Wherry et al. (2019), quienes también reportaron una influencia limitada de la temperatura en este parámetro cromático bajo condiciones similares.

Además, la prueba de Tukey confirmó que las diferencias entre las temperaturas evaluadas no son estadísticamente significativas en términos del valor de a^* , reforzando la conclusión de que este atributo del color se mantiene estable frente a las variaciones de temperatura aplicadas. Los datos correspondientes a esta evaluación se presentan en la Tabla 44. Por otro lado, la Figura 65 ilustra los intervalos de los valores de a^* para las diferentes concentraciones proteicas, evidenciando que la variabilidad de este componente cromático podría estar más asociada a otros factores, como la composición inicial de la leche en lugar de la temperatura de fermentación.

Al comparar los resultados obtenidos en este estudio, con valores de a^* que varían entre -2.86 y -2.34, con los reportados en la literatura, se observa que Wherry et al. (2019) informaron valores de a^* entre -2.71 y -1.03 en yogures elaborados a una temperatura de 43°C, los cuales son comparables a los resultados obtenidos. Por su parte, Akgun et al. (2018) reportaron un rango de a^* entre -2.71 y -2.28 en un estudio de yogures



probióticos elaborados a temperaturas entre 43 y 45°C, lo que también es consistente con los datos de esta investigación. Además, Du et al. (2021), investigaron yogures con adición de colorantes naturales (cúrcuma, pulpa de fresa y una muestra natural) a 42°C, obteniendo valores de a^* cercanos (-2.99 ± 0.06), lo que refuerza la similitud de los resultados.

Por otro lado, Guerra et al. (2022) documentaron que, en yogures naturales almacenados durante 21 días, el valor de a^* fluctuó de -2.26 ± 0.306 el primer día a -2.105 ± 0.120 al final del periodo de almacenamiento. Al contrastar estos resultados con los obtenidos en esta investigación, se puede afirmar que los valores de a^* se encuentran dentro del rango esperado, lo cual respalda la consistencia de los datos. No obstante, a pesar de las variaciones de temperatura aplicadas en los tratamientos, no se observaron diferencias estadísticamente significativas, lo que sugiere que este parámetro es menos sensible a cambios de temperatura bajo las condiciones evaluadas. Estos hallazgos confirman que, aunque los valores de a^* son comparables con los reportados en estudios previos, los efectos de la temperatura no influyen de manera notable en este atributo cromático en los yogures analizados, evidenciando la estabilidad relativa de este parámetro durante el proceso.

Tabla 43

Análisis de varianza del valor a^ según las temperaturas de fermentación*

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Temperatura (°C)	2	0.4809	0.2404	1.74	0.182
Error	78	10.7828	0.1382		
TOTAL	80	11.2636			


Tabla 44

Análisis y comparación Tukey para la variación del valor a^ según las temperaturas de fermentación*

Temperatura (°C)	N	Media	Agrupación
44	27	-2.5033	A
36	27	-2.6511	A
40	27	-2.6789	A

Figura 65

Intervalos del valor a^ en función a las temperaturas de fermentación*



- **Efecto en b***

Las diferentes temperaturas aplicadas durante la fermentación de la leche, de acuerdo con el análisis de varianza ANOVA que se muestra en la Tabla 45, reportaron valores entre 3.82 y 4.20, sin tener un efecto significativo ($p > 0.05$) sobre el valor b* del color en la escala CIELab. Este resultado fue corroborado por Wherry et al. (2019).

Mediante la prueba de Tukey, se pudo reafirmar que las temperaturas de fermentación no influyen significativamente en el valor del componente b* del yogur. Estos resultados comparativos se presentan en la Tabla 46. Mientras que en la Figura 66 se ilustran los intervalos de los valores de b* para las diferentes concentraciones proteicas.

Al contrastar los resultados obtenidos para el valor b*, que oscilan entre 3.82 y 4.20, se observa una marcada diferencia con respecto a otros estudios. Guerra et al. (2022) reportaron valores considerablemente más altos, entre 6.178 ± 0.760 y 6.740 ± 0.490 , en yogures elaborados a 40°C. De manera similar, Dimitreli et al. (2014), en su estudio sobre yogur batido con orujo de morera a 42°C, obtuvieron valores entre 5.76 ± 0.03 y 6.22 ± 0.04 en muestras control, sin adición de colorantes ni saborizantes. Estos resultados también superan los obtenidos en este estudio, lo que sugiere que otros factores, como la adición de ingredientes adicionales o diferencias en la composición de la leche, podrían estar influyendo en el color.

Por otro lado, Akgun et al. (2018), investigaron yogures con cultivos probióticos en leche de búfala, encontrando valores de b* entre 12 y 14. Esta notable diferencia refleja el impacto que puede tener una leche

de composición química diferente en las propiedades cromáticas del yogur. Asimismo, Aldaw Ibrahim et al. (2019) reportaron valores que variaron entre 23.63 y 42.33 en yogures de leche de vaca y cabra, elaborados bajo diferentes condiciones de temperatura, lo que evidenció un claro efecto sobre las propiedades fisicoquímicas del yogur. Sin embargo, Pan-utai et al. (2020) obtuvieron valores de b^* entre 4 y 5 en yogures elaborados con leche fresca de vaca a 43°C, sin aditivos, resultados que se asemejan más a los obtenidos en este estudio.

Sobre la temperatura de fermentación se puede decir que no generan efectos significativos en el valor b^* del color del yogur. Esta falta de significancia puede deberse a la uniformidad en las condiciones de fermentación y la ausencia de aditivos o ingredientes que modifiquen las propiedades ópticas del producto. Comparando con otros estudios, es evidente que la composición de la leche, el uso de aditivos, y la adición de otros ingredientes pueden modificar considerablemente el valor b^* . Esto sugiere que, aunque la temperatura es un factor relevante en otros aspectos del proceso de fermentación, su influencia directa sobre el color b^* del yogur es limitada bajo las condiciones experimentales de este estudio.

Tabla 45

Análisis de varianza del valor b^ según las temperaturas de fermentación*

Nota	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Temperatura (°C)	2	2.336	1.1680	2.28	0.109
Error	78	39.915	0.5117		
TOTAL	80	42.251			


Tabla 46

Análisis y comparación Tukey para la variación del valor b^ según las temperaturas de fermentación*

Temperatura (°C)	N	Media	Agrupación
44	27	4.2022	A
40	27	3.857	A
36	27	3.829	A

Figura 66

Intervalos del valor b^ en función a las temperaturas de fermentación*



4.4. DESARROLLO DE MODELOS PREDICTIVOS DE LAS PROPIEDADES FÍSICOQUÍMICAS A PARTIR DE IMÁGENES TERMOGRÁFICAS Y DIGITALES

4.4.1. Métricas de desempeño de los modelos entrenados

Se entrenaron 2 modelos predictivos por cada una de las 3 variables de respuesta (acidez, pH y viscosidad), uno con los valores de RGB provenientes de la cámara fotográfica y el otro con los datos RGB de la cámara termográfica, en total se lograron entrenar 6 modelos predictivos.

A continuación, se muestran las mejores métricas de desempeño EAM, ECM y el R^2 alcanzados tras entrenar por cinco veces las diferentes arquitecturas estudiadas. En todos los casos para identificar la mejor arquitectura del modelo se empleó los criterios establecidos por Batista et al. (2021a), este criterio establece que el mejor modelo debe tener el máximo R^2 con los más bajos valores de EAM y ECM.

4.4.1.1. Métricas de desempeño de los modelos entrenados para predecir la acidez a partir de las imágenes digitales

Tras evaluar múltiples arquitecturas para predecir la acidez durante la fermentación a partir de valores RGB de imágenes digitales, se identificó que la arquitectura más adecuada consistía en una capa oculta con 24 neuronas, como se detalla en la Tabla 47. Este modelo destacó por cumplir con los criterios de ajuste establecidos, reflejando su capacidad para generalizar los datos sin comprometer el rendimiento.

Los resultados obtenidos subrayan un principio clave en el diseño de redes neuronales: un mayor número de capas y neuronas no garantiza un mejor ajuste. De hecho, en modelos más complejos, aumenta el riesgo de sobreajuste, donde el modelo aprende a memorizar las variables de salida en lugar de generalizarlas correctamente. Este fenómeno puede llevar a valores negativos de R^2 , lo que evidencia un desempeño inadecuado en la predicción.

Tras el entrenamiento, una arquitectura de menor complejidad fue la que optimizó la capacidad predictiva y minimizó el riesgo de sobreajuste que las demás arquitecturas más complejas. Esto evidencia la importancia

de equilibrar la complejidad del modelo con la calidad y cantidad de datos, asegurando un diseño robusto y confiable para aplicaciones reales.

Tabla 47

Métricas de desempeño registrados del entrenamiento de modelos predictivos de acidez a partir de valores RGB de las imágenes digitales

Número de neuronas	Métricas de desempeño	Número de capas ocultas				
		1	2	4	6	8
4	EAM	0.098	0.090	0.091	0.098	0.099
	ECM	0.018	0.018	0.018	0.018	0.018
	R ²	0.000	-0.018	-0.015	0.000	0.000
8	EAM	0.043	0.041	0.042	0.092	0.090
	ECM	0.004	0.003	0.003	0.018	0.018
	R ²	0.801	0.809	0.809	-0.010	-0.019
12	EAM	0.097	0.044	0.047	0.086	0.087
	ECM	0.018	0.004	0.004	0.019	0.019
	R ²	0.000	0.792	0.771	-0.084	-0.053
16	EAM	0.043	0.041	0.095	0.086	0.103
	ECM	0.004	0.003	0.018	0.019	0.018
	R ²	0.803	0.809	-0.002	-0.075	-0.008
20	EAM	0.085	0.043	0.093	0.086	0.085
	ECM	0.019	0.004	0.018	0.019	0.019
	R ²	-0.090	0.769	-0.007	-0.061	-0.089
24	EAM	0.040	0.044	0.097	0.088	0.085
	ECM	0.003	0.004	0.018	0.018	0.019
	R ²	0.811	0.753	0.000	-0.037	-0.098
28	EAM	0.044	0.092	0.109	0.103	0.096
	ECM	0.003	0.018	0.018	0.018	0.018
	R ²	0.804	-0.009	-0.029	-0.009	-0.001
32	EAM	0.041	0.093	0.104	0.097	0.095
	ECM	0.004	0.018	0.018	0.018	0.018
	R ²	0.799	-0.007	-0.013	0.000	-0.002

4.4.1.2. Métricas de desempeño de los modelos entrenados para predecir el pH a partir de las imágenes digitales

Las arquitecturas entrenadas con valores RGB de las imágenes digitales para predecir el pH durante la fermentación mostraron métricas de desempeño progresivamente mejores al incrementar el número de neuronas en una capa oculta, como se detalla en la Tabla 48. El mejor rendimiento se alcanzó con 24 neuronas en una única capa oculta, destacando la capacidad del modelo para capturar patrones complejos y mejorar su precisión predictiva. Este hallazgo subraya la importancia de optimizar la cantidad de neuronas, ya que un número adecuado maximiza el aprendizaje del modelo sin agregar complejidad innecesaria.

Sin embargo, un aumento en el número de capas ocultas produjo el efecto contrario. Aunque las arquitecturas con más capas suelen tener mayor capacidad de modelado, en este caso, resultaron en un desempeño inferior. Esto sugiere que las capas adicionales introdujeron complejidad excesiva, favoreciendo el sobreajuste y limitando la capacidad del modelo para generalizar los datos.

Estos resultados resaltan la necesidad de un equilibrio cuidadoso en el diseño de redes neuronales, ajustando tanto el número de neuronas como el de capas ocultas para evitar problemas de sobreajuste y garantizar un rendimiento óptimo. En conclusión, la arquitectura con 24 neuronas en una capa oculta demostró ser la más efectiva para predecir el pH durante la fermentación, logrando un equilibrio ideal entre simplicidad y precisión predictiva.

Tabla 48

Métricas de desempeño registrados del entrenamiento de modelos predictivos de pH a partir de valores RGB de las imágenes digitales

Número de neuronas	Métricas de desempeño	Número de capas ocultas				
		1	2	4	6	8
4	EAM	0.193	0.332	0.331	0.121	0.185
	ECM	0.067	0.213	0.213	0.050	0.058
	R ²	0.683	-0.005	-0.006	0.767	0.729
8	EAM	0.152	0.120	0.160	0.159	0.131
	ECM	0.042	0.037	0.054	0.048	0.040
	R ²	0.802	0.825	0.747	0.775	0.813
12	EAM	0.130	0.120	0.131	0.129	0.329
	ECM	0.037	0.036	0.041	0.038	0.215
	R ²	0.828	0.829	0.805	0.820	-0.012
16	EAM	0.122	0.119	0.129	0.121	0.320
	ECM	0.036	0.037	0.037	0.043	0.222
	R ²	0.830	0.826	0.825	0.797	-0.049
20	EAM	0.126	0.120	0.127	0.330	0.323
	ECM	0.036	0.034	0.039	0.214	0.219
	R ²	0.828	0.839	0.816	-0.009	-0.032
24	EAM	0.119	0.132	0.133	0.344	0.126
	ECM	0.034	0.042	0.045	0.212	0.050
	R ²	0.841	0.802	0.790	0.000	0.764
28	EAM	0.123	0.124	0.144	0.160	0.163
	ECM	0.036	0.037	0.046	0.045	0.051
	R ²	0.831	0.827	0.783	0.788	0.760
32	EAM	0.129	0.136	0.134	0.173	0.121
	ECM	0.037	0.041	0.041	0.059	0.036
	R ²	0.827	0.806	0.807	0.722	0.832

4.4.1.3. Métricas de desempeño de los modelos entrenados para predecir la viscosidad a partir de las imágenes digitales

Se entrenaron modelos para predecir la viscosidad a partir de los valores RGB obtenidos de imágenes digitales, cuyos resultados de desempeño se presentan en la Tabla 49. Las métricas reportan valores elevados de EAM y ECM, acompañados de un coeficiente de determinación R^2 de solo 0.5029. Este rendimiento indica que el modelo no logra capturar adecuadamente el comportamiento de la viscosidad durante la fermentación de la leche y su conversión en yogur.

Una posible explicación de estos resultados radica en la naturaleza no lineal del cambio de viscosidad durante el proceso. Hasta alcanzar un pH de 5, los valores de viscosidad registrados permanecen bajos, por debajo de 100 mPa·s. Sin embargo, al aproximarse al punto isoeléctrico de la leche (pH 4,6), la viscosidad experimenta un incremento abrupto, superando los 100 mPa·s. Este cambio repentino representa un desafío significativo para los modelos de predicción, que tienden a ser más efectivos cuando las variables presentan comportamientos continuos y predecibles.

Además, la relación entre los valores RGB de las imágenes digitales y los cambios estructurales que afectan la viscosidad puede no ser lo suficientemente fuerte o directa para capturar las dinámicas del proceso. Este resultado subraya la necesidad de explorar arquitecturas más complejas o considerar variables complementarias, como la dinámica del pH o la concentración de sólidos, para mejorar la precisión del modelo. En conclusión, la complejidad inherente al comportamiento de la viscosidad

requiere enfoques más robustos y adaptativos para lograr predicciones confiables.

Tabla 49

Métricas de desempeño registrados del entrenamiento de modelos predictivos de viscosidad a partir de valores RGB de las imágenes digitales

Número de neuronas	Métricas de desempeño	Número de capas ocultas				
		1	2	4	6	8
4	EAM	141	151	151	151	151
	ECM	132191	185420	185433	185430	185445
	R ²	0.190	-0.136	-0.136	-0.136	-0.137
8	EAM	136	151	151	151	151
	ECM	137211	185469	185466	185450	185469
	R ²	0.159	-0.137	-0.137	-0.137	-0.137
12	EAM	139	151	151	152	151
	ECM	135585	185458	185426	185417	185426
	R ²	0.169	-0.137	-0.136	-0.136	-0.136
16	EAM	134	151	151	151	151
	ECM	133995	185440	185475	185445	185459
	R ²	0.179	-0.136	-0.137	-0.137	-0.137
20	EAM	138	151	151	151	151
	ECM	132342	185450	185451	185467	185443
	R ²	0.189	-0.137	-0.137	-0.137	-0.137
24	EAM	128	151	152	151	151
	ECM	135226	185432	185388	185440	185437
	R ²	0.171	-0.136	-0.136	-0.136	-0.136
28	EAM	89	151	151	151	151
	ECM	81118	185448	185472	185449	185457
	R ²	0.503	-0.137	-0.137	-0.137	-0.137
32	EAM	133	151	151	152	151
	ECM	134161	185444	185444	185405	185423
	R ²	0.178	-0.137	-0.137	-0.136	-0.136



4.4.1.4. Métricas de desempeño de los modelos entrenados para predecir la acidez a partir de las imágenes termográficas

Los modelos de predicción se desarrollaron utilizando valores RGB derivados de imágenes termográficas. La Tabla 50 presenta las métricas de desempeño de los modelos entrenados para estimar la acidez. Se empleó una capa oculta con 12 neuronas, logrando un ajuste superior al modelo basado en imágenes digitales. Esto podría atribuirse a que las imágenes termográficas revelan un patrón secuencial en los momentos finales de fermentación, donde el color azul ocupa progresivamente mayor área, lo que favorece la precisión del modelo en esta etapa crítica.

Tabla 50

Métricas de desempeño registrados del entrenamiento de modelos predictivos de acidez a partir de valores RGB de las imágenes termográficas

Número de neuronas	Métricas de desempeño	Número de capas ocultas				
		1	2	4	6	8
4	EAM	0.091	0.041	0.091	0.091	0.100
	ECM	0.019	0.003	0.016	0.016	0.017
8	EAM	-0.205	0.789	-0.008	-0.011	-0.039
	ECM	0.046	0.043	0.042	0.043	0.092
8	R ²	0.003	0.003	0.003	0.003	0.016
	EAM	0.799	0.786	0.809	0.809	0.000
12	ECM	0.040	0.040	0.045	0.091	0.092
	R ²	0.003	0.003	0.003	0.016	0.016
12	EAM	0.825	0.812	0.785	-0.003	0.000
	ECM	0.043	0.046	0.090	0.090	0.091
16	R ²	0.003	0.004	0.019	0.016	0.016
	EAM	0.815	0.780	-0.178	-0.021	-0.003
20	ECM	0.053	0.044	0.090	0.091	0.091
	R ²	0.004	0.003	0.016	0.016	0.016
20	EAM	0.732	0.786	-0.025	-0.008	-0.006
	ECM	0.042	0.044	0.048	0.094	0.091
24	R ²	0.003	0.003	0.004	0.016	0.016
	EAM	0.815	0.802	0.763	-0.002	-0.004
28	ECM	0.042	0.041	0.051	0.089	0.090
	R ²	0.003	0.003	0.005	0.017	0.016
28	EAM	0.816	0.811	0.683	-0.082	-0.021
	ECM	0.043	0.056	0.090	0.092	0.092
32	R ²	0.003	0.006	0.018	0.016	0.016
	EAM	0.801	0.624	-0.153	0.000	-0.001

4.4.1.5. Métricas de desempeño de los modelos entrenados para predecir el pH a partir de las imágenes termográficas

Los valores RGB obtenidos de las imágenes termográficas fueron utilizados para entrenar modelos con el objetivo de predecir el pH durante la fermentación de la leche. Las métricas de desempeño de las diferentes



arquitecturas evaluadas se presentan en la Tabla 51. De todas las arquitecturas probadas, el modelo con dos capas ocultas y 16 neuronas por capa logró un mejor ajuste en comparación con los modelos entrenados con valores RGB de imágenes digitales. Este mejor desempeño se puede atribuir a la mayor correlación entre los datos térmicos de las imágenes termográficas y el comportamiento dinámico del pH durante la fermentación.

Las cámaras termográficas permiten registrar variaciones precisas en la distribución de la temperatura sobre la superficie de la leche, lo cual influye directamente en las reacciones metabólicas de los microorganismos involucrados en la fermentación. Estas variaciones térmicas están relacionadas con la producción de ácido láctico, responsable de la disminución progresiva del pH. En cambio, las imágenes digitales no capturan esta información térmica, limitándose a representar solo cambios visuales, lo que podría explicar su menor capacidad para predecir el pH.

La estructura continua de las imágenes termográficas proporciona un patrón secuencial más robusto para los modelos de predicción, lo que es especialmente útil en las etapas finales de la fermentación, donde los cambios térmicos reflejan un mayor avance en la acidificación. Así, los valores RGB de las imágenes termográficas ofrecen una Nota de información más precisa y adecuada para modelar el comportamiento del pH, lo que refuerza su aplicación en la agroindustria.

Tabla 51

Métricas de desempeño registrados del entrenamiento de modelos predictivos de pH a partir de valores RGB de las imágenes termográficas

Número de neuronas	Métricas de desempeño	Número de capas ocultas				
		1	2	4	6	8
4	EAM	0.168	0.115	0.095	0.154	0.131
	ECM	0.052	0.024	0.016	0.039	0.025
	R ²	0.786	0.903	0.933	0.840	0.897
8	EAM	0.120	0.089	0.106	0.091	0.134
	ECM	0.026	0.018	0.023	0.018	0.030
	R ²	0.893	0.926	0.905	0.925	0.878
12	EAM	0.114	0.102	0.105	0.133	0.095
	ECM	0.023	0.026	0.018	0.029	0.019
	R ²	0.905	0.894	0.927	0.882	0.923
16	EAM	0.118	0.349	0.086	0.115	0.345
	ECM	0.025	0.016	0.249	0.024	0.267
	R ²	0.897	0.935	-0.021	0.902	-0.093
20	EAM	0.129	0.099	0.103	0.149	0.346
	ECM	0.026	0.018	0.024	0.039	0.254
	R ²	0.895	0.927	0.901	0.839	-0.042
24	EAM	0.108	0.097	0.142	0.120	0.345
	ECM	0.020	0.016	0.036	0.027	0.258
	R ²	0.918	0.933	0.853	0.889	-0.056
28	EAM	0.116	0.098	0.105	0.345	0.349
	ECM	0.028	0.020	0.023	0.258	0.278
	R ²	0.887	0.919	0.905	-0.056	-0.138
32	EAM	0.118	0.088	0.134	0.345	0.345
	ECM	0.020	0.017	0.035	0.266	0.265
	R ²	0.916	0.929	0.857	-0.089	-0.086

4.4.1.6. Métricas de desempeño de los modelos entrenados para predecir la viscosidad a partir de las imágenes termográficas

El estudio de la predicción de la viscosidad a partir de los valores RGB de las imágenes termográficas también fue realizado, y las métricas de desempeño de las diversas arquitecturas entrenadas se presentan en la Tabla 52. De estas, la mejor arquitectura entrenada consistió en una capa



oculta con 16 neuronas por capa. Al comparar las métricas obtenidas del entrenamiento de los modelos con imágenes digitales con las de los modelos entrenados utilizando los valores RGB de las imágenes termográficas, se observa una mejora significativa en el desempeño de los modelos basados en imágenes termográficas. Esto sugiere que la termografía tiene la capacidad de percibir con mayor precisión los cambios que ocurren durante la fermentación de la leche, lo que contribuye a un ajuste más adecuado de los modelos. A diferencia de las imágenes digitales, que solo capturan información visual, las imágenes termográficas ofrecen datos relacionados con la distribución de la temperatura en la superficie de la leche, lo cual está directamente vinculado a los procesos metabólicos que afectan la viscosidad. La capacidad de la termografía para resaltar estas variaciones térmicas permite un modelado más preciso del comportamiento de la viscosidad durante la fermentación, lo que explica el mejor rendimiento de los modelos entrenados con este tipo de imágenes. Por lo tanto, los resultados obtenidos demuestran que la termografía es una herramienta más efectiva para predecir la viscosidad en comparación con las imágenes digitales.

Tabla 52

Métricas de desempeño registrados del entrenamiento de modelos predictivos de viscosidad a partir de valores RGB de las imágenes termográficas

Número de neuronas	Métricas de desempeño	Número de capas ocultas				
		1	2	4	6	8
4	EAM	59	58	57	58	58
	ECM	58672	58096	57350	74111	74115
	R ²	0.174	0.182	0.193	-0.044	-0.044
8	EAM	40	58	58	58	58
	ECM	20582	58281	74125	74117	74120
	R ²	0.710	0.179	-0.044	-0.044	-0.044
12	EAM	36	56	58	58	58
	ECM	14798	57845	74115	9323	74117
	R ²	0.792	0.186	-0.044	-0.044	-0.044
16	EAM	27	57	57	58	58
	ECM	74128	56930	55157	74120	74110
	R ²	0.869	0.199	0.223	-0.044	-0.043
20	EAM	59	58	58	58	58
	ECM	31852	58885	56472	74113	74121
	R ²	0.552	0.171	0.205	-0.044	-0.044
24	EAM	36	57	58	58	58
	ECM	11024	56613	74119	74108	74115
	R ²	0.845	0.203	-0.044	-0.043	-0.044
28	EAM	45	58	58	58	58
	ECM	21033	57628	74115	74108	74119
	R ²	0.704	0.189	-0.044	-0.043	-0.044
32	EAM	35	56	58	58	58
	ECM	12979	55792	57318	74116	74109
	R ²	0.817	0.215	0.193	-0.044	-0.043

En general, los modelos entrenados con imágenes termográficas lograron las mejores métricas de desempeño. Las limitaciones observadas en los modelos basados en imágenes digitales pueden atribuirse a varios factores. Uno de los principales es la formación de películas en la superficie de la leche, lo que dificulta el monitoreo preciso de sus



características superficiales. Además, las oscilaciones en la iluminación causadas por el uso de corriente alternan en la Nota de luz pueden generar interferencias, afectando la calidad de las imágenes.

Por otro lado, las cámaras termográficas tienen la ventaja de detectar la radiación infrarroja emitida por los cuerpos, lo que les permite estimar de manera precisa el comportamiento térmico de la leche. A diferencia de las cámaras fotográficas convencionales, las cámaras termográficas no requieren iluminación adicional, eliminando así las posibles interferencias derivadas de condiciones de luz cambiantes. Esta capacidad para percibir variaciones térmicas de manera independiente de la luz visible puede explicar por qué los modelos entrenados con imágenes termográficas mostraron un rendimiento superior en la predicción de las propiedades fisicoquímicas durante la fermentación de la leche. En resumen, el uso de imágenes termográficas proporciona datos más fiables y menos susceptibles a interferencias externas, lo que mejora la precisión y la capacidad predictiva del modelo.

4.4.2. Ajuste de los modelos seleccionados en función a su métrica de desempeño

Los tratamientos planteados para el desarrollo de los modelos predictivos se muestran en la Tabla 53, el proceso de fermentación se realizó a tres diferentes temperaturas de fermentación empleando tres niveles de concentración de inóculo y proteína, cada tratamiento empleó el tiempo necesario para alcanzar el pH de 4.6.

Tabla 53*Condiciones de cada tratamiento y el tiempo total de fermentación de la leche*

Secuencia de tratamientos (T)	Temperatura (°C)	Inóculo (%)	Proteína (%)	Tiempo de fermentación (min)
T_1	36	1	4.2	360
T_2	36	2	4.2	335
T_3	36	3	4.2	320
T_4	40	1	4.2	290
T_5	40	2	4.2	290
T_6	40	3	4.2	275
T_7	44	1	4.2	290
T_8	44	2	4.2	230
T_9	44	3	4.2	240
T_10	36	1	4.5	405
T_11	36	2	4.5	420
T_12	36	3	4.5	380
T_13	40	1	4.5	335
T_14	40	2	4.5	270
T_15	40	3	4.5	260
T_16	44	1	4.5	270
T_17	44	2	4.5	224
T_18	44	3	4.5	210
T_19	36	1	4.8	410
T_20	36	2	4.8	380
T_21	36	3	4.8	370
T_22	40	1	4.8	290
T_23	40	2	4.8	345
T_24	40	3	4.8	330
T_25	44	1	4.8	265
T_26	44	2	4.8	230
T_27	44	3	4.8	280

El modelo seleccionado con el mejor desempeño en la predicción de acidez a partir de los valores de RGB de las imágenes digitales se volvió a cargar al entorno virtual de Google Colab. Luego se empleó los datos de entrenamiento (90%) y de validación (10%) para evaluar el funcionamiento del modelo, los valores reales de acidez y los valores predichos por el modelo entrenado para los

27 tratamientos se muestran en la Figura 60. Además, se muestra el comportamiento de los valores RGB de las imágenes digitales que se emplearon para predecir el comportamiento de la acidez durante el proceso de fermentación.

4.4.2.1. Nivel de ajuste del modelo de predicción de acidez basado en valores de RGB de imágenes digitales


En las curvas de acidez que se muestran en la Figura 67, cada cresta corresponde a un tratamiento por lo que está rotulado con la letra T seguida de un número, las condiciones de cada tratamiento se detallan en la Tabla 53. El comportamiento oscilante de los valores RGB se debe al uso de luminarias de corriente alterna de 50 Hz, por lo que Minz & Saini (2021b) recomienda el uso de luz fluorescente de con flujo de corriente de alta frecuencia (>40kHz) para evitar el efecto de latido por fluctuaciones de intensidad de corriente.

Los valores RGB se emplearon para el entrenamiento de varias arquitecturas y mediante el cual se logró finalmente identificar el modelo con las mejores métricas desempeño ($R^2 = 0.811$, $ECM = 0.0033$). La arquitectura de este modelo consta de una capa oculta y 24 neuronas por capa. Su capacidad predictiva de la acidez de la leche durante su fermentación a partir de los valores de RGB y las condiciones de tratamiento se ilustran en la Figura 67.

El modelo desarrollado ajustó la acidez predicha a la real con más del 80% de precisión usando valores RGB. Estudios previos (Cimander et al., 2002; Sofu & Ekinci, 2007) destacan que los modelos basados en RNA mejoran el monitoreo de propiedades fisicoquímicas, microbiológicas y sensoriales en alimentos fermentados.

Figura 67

Curvas de comportamiento de la acidez real y predicha en función a los valores RGB de las imágenes digitales



4.4.2.2. Nivel de ajuste del modelo de predicción del pH basado en valores de RGB de imágenes digitales


Se evaluó el desempeño de un modelo entrenado con valores RGB de imágenes digitales para predecir el pH de la leche durante su fermentación. Además de los valores RGB, se utilizaron otras variables de entrada, como la temperatura de fermentación, concentración de inóculo, proteína y el minuto de muestreo para las mediciones de pH, mientras que el valor de salida fue el pH real. Así, el modelo se entrenó para ajustar sus predicciones a estos valores reales.

Después de un extenso período de entrenamiento con diversas arquitecturas, se identificó la configuración óptima, que consistió en una capa oculta con 24 neuronas, alcanzando métricas de desempeño de $R^2 = 0.8411$ y $ECM = 0.0337$. Este resultado es comparable a los modelos desarrollados por da Cruz et al. (2009), quienes lograron una eficiencia del 100% para monitorear el pH de yogur bajo en grasa, y Pallavi & Sukumar (2020), quienes también alcanzaron una eficiencia del 100% en la clasificación de yogures según su color, pH y porcentaje de Carbohidrato utilizando una densa neuronal roja.

El modelo presenta limitaciones para predecir el pH, especialmente en las etapas finales de la fermentación. Las curvas de pH real y predicho muestran discrepancias en estas fases, como se observa en la Figura 68. Esta diferencia podría deberse a que el modelo fue entrenado con diversas condiciones de tratamiento, lo que podría restringir su capacidad para generalizar y lograr mayor precisión en las fases finales del proceso.

Figura 68

Curvas de comportamiento del pH real y predicha en función a los valores RGB de las imágenes digitales






4.4.2.3. Nivel de ajuste del modelo de predicción de la viscosidad basado en valores de RGB de imágenes digitales

Durante todos los tratamientos de fermentación, la viscosidad mostró un patrón de comportamiento similar, con un incremento repentino en los últimos 30 a 40 minutos del proceso. Los datos recopilados mediante técnicas convencionales fueron utilizados para entrenar múltiples arquitecturas de modelos, y, tras el proceso de entrenamiento, se identificó la arquitectura con las mejores métricas de desempeño. La mejor arquitectura entrenada consta de una capa oculta con 28 neuronas, pero presenta valores elevados de EAM (89) y ECM (81118), mientras que su R^2 apenas supera 0.5. Este rendimiento es inferior al reportado por Batista et al. (2021b) quienes alcanzaron un R^2 superior a 0.95 y un ECM bajo al predecir la viscosidad a partir de formulaciones y condiciones de procesamiento. A pesar de esto, el modelo entrenado mostró un ajuste moderado en la curva de regresión construida con los datos de viscosidad predicha, como se observa en la Figura 69. Sin embargo, el modelo no logró predecir adecuadamente la viscosidad en los tratamientos T_1, T_14, T_15, T_21 y T_22, lo que se refleja en una línea de regresión plana por debajo de los valores reales. Este comportamiento puede explicarse por la falta de datos que describan con precisión los cambios de viscosidad durante las fases finales de la fermentación, debido al cambio abrupto de la viscosidad, que ocurre cuando la leche alcanza su punto isoeléctrico ($\text{pH} < 5.2$) y experimenta una disminución acelerada.

Figura 69

Curvas de comportamiento de la viscosidad real y predicha en función a los valores RGB de las imágenes digitales



4.4.2.4. Nivel de ajuste del modelo de predicción de la acidez basado en valores de RGB de imágenes termográficas

El comportamiento de la acidez durante la fermentación sigue una tendencia creciente, lo que refleja el aumento progresivo en la concentración de ácido láctico en la leche. Este fenómeno es una característica fundamental del proceso de fermentación, ya que el ácido láctico se produce como resultado de la acción de los microorganismos sobre la lactosa presente en la leche. A medida que la fermentación avanza, la acidez de la leche aumenta, lo que afecta sus propiedades fisicoquímicas y, por ende, su calidad. Para estudiar este comportamiento, los patrones de acidez fueron obtenidos mediante técnicas convencionales de medición de acidez, como la titulación, lo que proporcionó una base sólida de datos para el análisis.

Además, se incorporaron los valores RGB obtenidos de imágenes termográficas, que fueron utilizados como variables adicionales en el entrenamiento de varias arquitecturas de redes neuronales. Las imágenes termográficas permiten observar el comportamiento térmico de la leche durante la fermentación, ofreciendo información adicional que puede ser relevante para predecir el comportamiento de la acidez, ya que los cambios en la temperatura de la leche están estrechamente relacionados con los procesos metabólicos de los microorganismos que producen ácido láctico. Esta combinación de datos convencionales y termográficos permitió entrenar modelos más robustos y con una mayor capacidad predictiva.

La arquitectura que presentó las mejores métricas de desempeño se caracteriza por una red neuronal con una capa oculta que contiene 12




neuronas, y alcanzó un coeficiente de determinación (R^2) de 0.8252 y un error cuadrático medio (ECM) de 0.0028. Estos resultados indican que el modelo tiene un buen ajuste con los datos de acidez observados, aunque aún hay margen de mejora. En la Figura 70 se puede apreciar el ajuste del modelo, mostrando cómo las predicciones se alinean con los valores reales de acidez a medida que avanza el proceso de fermentación.

Al principio del proceso de fermentación, el aumento de la acidez es relativamente lento, lo que genera un fenómeno de sobreajuste en el modelo. Este sobreajuste ocurre cuando el modelo es incapaz de reconocer las pequeñas variaciones iniciales en los datos, interpretándolas como patrones no generalizables. Sin embargo, a medida que la fermentación progresa, el modelo ajusta sus parámetros y mejora su precisión en las predicciones. Este ajuste permite que el modelo sea más efectivo a medida que se acumulan datos y se comprende mejor la dinámica del proceso. La mejora en la precisión del modelo en las fases posteriores de la fermentación refleja la capacidad de la red neuronal para identificar los patrones clave que afectan la formación de ácido láctico y el cambio en la acidez de la leche. En general, los resultados obtenidos subrayan la importancia de utilizar múltiples Notas de datos y métodos de modelado avanzados para predecir comportamientos complejos en procesos como la fermentación láctica, mejorando así la comprensión y control de dichos procesos en aplicaciones industriales.

Figura 70

Curvas de comportamiento de acidez real y predicha en función a los valores RGB de las imágenes termográficas





4.4.2.5. Nivel de ajuste del modelo de predicción del pH basado en valores de RGB de imágenes termográficas

El valor del pH de la leche disminuye a medida que aumenta la concentración de ácido láctico durante la fermentación, lo que provoca que los patrones de pH formen curvas descendentes. El monitoreo del descenso del pH mediante la cámara termográfica muestra que el valor B en las imágenes termográficas aumenta en las etapas finales de la fermentación. Este aumento se debe al enfriamiento de la superficie central de la leche, lo cual refleja un cambio térmico asociado al proceso de fermentación y a las variaciones en la temperatura de la leche a medida que avanza el proceso.

El descenso térmico detectado por la cámara térmica en las etapas finales de la fermentación fue un patrón que se observó en todos los tratamientos. Este efecto térmico puede explicarse, en parte, por la producción de ácido láctico, lo que reduce el pH y provoca la precipitación y gelificación de las proteínas lácteas, (Akarca & Denizkara, 2024; Du et al., 2023; Ouyang et al., 2024; Zang et al., 2023). La gelificación de la leche es el resultado de la disminución de la repulsión electrostática entre las micelas de caseína (Akarca & Denizkara, 2024; Bowler et al., 2023; Zang et al., 2023), lo que aumenta la afinidad y estabilidad coloidal de los componentes estructurales de la leche, facilitando su conversión en yogur (Castillo, 2002; Zang et al., 2023). Esta red tridimensional actúa como una barrera térmica, impidiendo el flujo de calor desde las paredes del reactor hacia el centro superficial de la leche. Esto puede afectar negativamente la




producción de acidez y, en última instancia, la aceptabilidad sensorial del yogur (Yang et al., 2021a).

Los patrones del descenso térmico durante la fermentación fueron registrados mediante una cámara termográfica, que permitió capturar la radiación infrarroja emitida por la superficie de la leche a lo largo del proceso. Este enfoque es útil debido a la capacidad de las cámaras termográficas para detectar variaciones térmicas sin la necesidad de iluminación adicional, a diferencia de las imágenes convencionales. El procesamiento de las imágenes permitió extraer los valores RGB, que se utilizaron como variables de entrada para entrenar modelos de redes neuronales con diversas arquitecturas. Al integrar estos datos térmicos con otras variables del proceso, como la temperatura y el tiempo, se proporcionó al modelo una mayor capacidad para predecir el comportamiento del pH en tiempo real.

Tras el entrenamiento, se identificó la arquitectura más eficiente para predecir el pH. Esta arquitectura consta de dos capas ocultas, con 16 neuronas en cada capa, lo que permitió capturar las complejidades del comportamiento térmico y químico del proceso. El modelo entrenado presentó métricas de ajuste significativamente mejores que aquellos basados en imágenes digitales convencionales. El coeficiente de determinación (R^2) alcanzó un valor de 0.9354, indicando un fuerte ajuste entre las predicciones y los valores reales de pH, mientras que el error cuadrático medio (ECM) fue de 0.0158, lo que refleja una alta precisión en las predicciones.

Figura 71

Curvas de comportamiento de pH real y predicha en función a los valores RGB de las imágenes termográficas





4.4.2.6. Nivel de ajuste del modelo de predicción de la viscosidad basado en valores de RGB de imágenes termográficas

Como se ha observado previamente, la viscosidad durante el proceso de fermentación de la leche se mantiene prácticamente constante durante gran parte del tiempo. Esto se debe a la naturaleza del proceso, donde los cambios en las propiedades de la leche son lentos y progresivos en las primeras fases de la fermentación. Sin embargo, en los últimos minutos de la fermentación, la viscosidad experimenta un cambio repentino y significativo, lo que se refleja en un aumento drástico en su valor, tal como se evidencia en la Figura 72. Este comportamiento abrupto representa un reto importante para los modelos de predicción convencionales que se entrenan con datos obtenidos de imágenes digitales. En estos modelos, la variabilidad en los datos no fue capturada adecuadamente, lo que resultó en una inadecuada representación de las fases finales del proceso de fermentación.

Una de las principales razones de estas limitaciones es la naturaleza no lineal y escalonada del incremento en la viscosidad durante las etapas finales de la fermentación. Este tipo de comportamiento, donde se producen cambios súbitos en una variable, es difícil de modelar correctamente con técnicas convencionales, ya que los modelos entrenados con datos de imágenes digitales no son lo suficientemente sensibles para captar este tipo de transiciones abruptas. El comportamiento de la viscosidad en esta fase es tan drástico que las técnicas de predicción estándar no pueden ajustarse adecuadamente a los valores reales de la variable.




En contraste, al entrenar las mismas arquitecturas de modelos utilizando los valores RGB extraídos de imágenes termográficas, se alcanzaron métricas de desempeño notablemente superiores. Las imágenes termográficas, al ser capaces de captar variaciones térmicas en tiempo real, ofrecen una representación más precisa de los cambios rápidos en la superficie de la leche, lo que a su vez mejora la capacidad del modelo para predecir la viscosidad. El modelo con el mejor ajuste, entrenado con imágenes termográficas, presentó un coeficiente de determinación (R^2) de 0.8687, lo que indica una relación fuerte entre las predicciones y los valores reales de viscosidad. Además, el error cuadrático medio (ECM) fue de 74128, y el error absoluto medio (EAM) alcanzó un valor de 27, lo que demuestra una mejora significativa en la capacidad predictiva del modelo. La arquitectura correspondiente a este desempeño consistió en una capa oculta con 16 neuronas, lo que proporcionó un equilibrio adecuado entre simplicidad y capacidad predictiva, mejorando la precisión sin introducir complejidad innecesaria.

A pesar de las mejoras, el modelo entrenado con imágenes termográficas enfrenta limitaciones debido a la falta de datos sobre el comportamiento gradual de la viscosidad durante la fermentación. Las fases intermedias, donde la viscosidad cambia de forma más suave, están poco representadas en los datos utilizados. Esta escasez impide que el modelo capture con precisión estas etapas, limitando su capacidad de generalizar. Es crucial aumentar la recopilación de datos en momentos de cambio gradual, optimizando el modelo y mejorando la precisión y el control en la producción láctea.

Figura 72

Curvas de comportamiento de la viscosidad real y predicha en función a los valores RGB de las imágenes termográficas



4.4.3. Descripción de la función matricial de los modelos seleccionados

En el proceso de desarrollo de los modelos, se exploraron diversas arquitecturas, las cuales fueron seleccionadas en función de sus métricas de desempeño. Los modelos se desarrollaron en entornos virtuales, lo que ocasionó que su estructura fuera poco ilustrativo. Por esta razón, se optó por representarlos gráficamente, lo que permitió una mejor visualización y comprensión de la distribución de su arquitectura.

Asimismo, se describieron los parámetros y factores que componen la estructura interna de los modelos. Con el objetivo de proporcionar una mayor claridad sobre su funcionamiento, también se detallaron las operaciones que realizan sus componentes, permitiendo comprender cómo estiman las variables de respuesta a partir de las variables de estudio.

4.4.3.1. Modelo para la predicción de acidez a partir de imágenes digitales

En la Figura 73 se presenta la arquitectura del modelo diseñado para predecir la acidez de la leche durante la fermentación, empleando una red neuronal artificial (ARN). La capa de entrada cuenta con siete neuronas, cada una representando variables clave: temperatura de fermentación, concentración de inóculo, concentración de proteínas, tiempo transcurrido de fermentación, y los valores promedio de los canales rojo (R), verde (G) y azul. (B) de las imágenes capturadas.


La capa oculta está compuesta por 24 neuronas completamente conectadas, asegurando una transmisión eficiente de información hacia la capa de salida, que contiene una única neurona destinada a predecir la

acidez de la leche. Este diseño integra variables físicas, como temperatura y tiempo, con datos ópticos derivados de las imágenes RGB, lo que permite al modelo capturar tanto interacciones bioquímicas como cambios visuales relacionados con la fermentación.

La inclusión de valores RGB amplía la capacidad del modelo para identificar patrones no lineales, mejorando la comprensión de las dinámicas del proceso. La elección de una capa oculta con 24 neuronas equilibra la complejidad del modelo, evitando problemas de sobreajuste y asegurando predicciones más precisas. Este diseño ha demostrado ser eficiente en el análisis multifactorial, optimizando la relación entre las variables experimentales y la acidez.

Figura 73

Representación de la arquitectura del modelo desarrollado para la predicción de la acidez



En la Tabla 54 se muestra los hiperparámetros de la función matricial del modelo desarrollado para la predicción de la acidez, a partir de los datos de las 7 variables de entrada ($x_i, i=1, 2, \dots, 7$). Antes de ingresar a la red neuronal, los datos se escalaron (X_{esc}) entre 0 y 1, utilizando la Ecuación 7, y posteriormente se normalizaron (X_{norm}) mediante la Ecuación 8.

$$X_{esc} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad \text{Ec. (7)}$$

$$X_{norm} = \frac{X_{esc} - \mu}{\sigma} \quad \text{Ec. (8)}$$

Cada una de las 24 neuronas ($z_j, j=1, 2, \dots, 24$) de la capa oculta recibe como entradas las 7 variables, que se multiplican por sus respectivos pesos asignados ($w_{ij}, i=1, 2, \dots, 7$) y, al resultado, se le suma un sesgo (b_j). Esto se expresa en la Ecuación 9.

$$z_j = \sum_{i=1}^7 w_{ij} \cdot x_i + b_j \quad \text{Ec. (9)}$$

Donde z_j es el valor calculado para la neurona j , w_{ij} son los pesos que conectan las entradas x_i con la neurona j , b_j es el sesgo de la neurona j , x_i representa las 7 entradas.

Una vez calculado z_j , la neurona aplica la función de activación *ReLU* (Ecuación 10) para introducir no linealidad en la red, permitiendo que el modelo capture patrones complejos de los datos. *ReLU* convierte los valores negativos en 0 y deja intactos los valores positivos:

$$f(z_j) = \max(0, z_j) \quad \text{Ec. (10)}$$

Esto implica que, si el valor z_j es positivo, $f(z_j) = z_j$ y si es negativo $f(z_j) = 0$.

En la capa de salida, las 24 neuronas de la capa oculta se conectan a una única neurona, que representa la predicción final de acidez. Esta

neurona recibe como entradas los valores $f(z_1), f(z_1), \dots, f(z_{24})$, cada uno de ellos multiplicado por un peso (w_{oj} , $j = 1, 2, \dots, 24$) para cada entra, además, ajusta un único valor de sesgo (b_o). El valor de salida (y) se calcula mediante la Ecuación 11.

$$y = \sum_{j=1}^{24} w_{oj} \cdot f(z_j) + b_o \quad \text{Ec. (11)}$$

Donde y es el valor predicho de acidez, w_{oj} son los pesos que conectan los valores $f(z_j)$ de la capa oculta con la neurona de la capa de salida, b_o es el sesgo asignado por la neurona de salida, $f(z_j)$ son los valores de las neuronas de la capa oculta que pasaron por la función *ReLU*.

En la capa de salida no se aplicó ninguna función de activación, ya que la tarea es una regresión, y se busca predecir un valor continuo de acidez.

El procedimiento descrito sobre el funcionamiento de la RNA hace referencia al aprendizaje supervisado, donde cada capa y operación tiene un rol bien definido para optimizar el aprendizaje. El escalado y la normalización de los datos de entrada son pasos esenciales para asegurar que las magnitudes de las variables no afecten de manera desbalanceada el proceso de aprendizaje. Esto es especialmente importante en la RNA, donde las diferencias en la escala de las variables pueden causar dificultades durante el ajuste de los pesos.

La función de activación *ReLU* permite eliminar valores negativos, induciendo la no linealidad necesaria para modelar relaciones complejas, manteniendo un bajo costo computacional.

La capa de salida, al no tener una función de activación, permite que el valor de predicción sea continuo, lo cual es coherente con el objetivo del modelo: predecir la acidez de la leche, que es una variable cuantitativa.

El cálculo de los hiperparámetros siguió el enfoque propuesto por Burkov (2019), quien recomienda inicializar los pesos con valores pequeños aleatorios para evitar problemas de simetría y permitir que las neuronas aprendan patrones distintos. Por otro lado, los sesgos se inicializan en cero, lo que permite ajustar la activación sin afectar los gradientes iniciales. Tras el primer entrenamiento, se calcula el ECM utilizando la Ecuación 12, con el fin de evaluar la discrepancia entre las predicciones y los valores reales. Este enfoque asegura una convergencia eficiente hacia óptimos cercanos, minimizando los errores y mejorando la precisión del modelo, logrando un equilibrio entre eficiencia y capacidad de aprendizaje.

$$ECM = \frac{1}{N} \sum_{i=1}^N (y_i - (wx_i + b))^2 \quad \text{Ec. 12}$$

Luego, se calcula el descenso gradiente utilizando la Ecuación 13 para el peso y la Ecuación 14 para el sesgo:

$$\frac{\partial ECM}{\partial w} = \frac{1}{N} \sum_{i=1}^N -2x_i (y_i - (wx_i + b)) \quad \text{Ec. 13}$$

$$\frac{\partial ECM}{\partial b} = \frac{1}{N} \sum_{i=1}^N -2(y_i - (wx_i + b)) \quad \text{Ec. 14}$$

Donde: N es el número de predicciones, y_i es la salida real, w es el peso asignado, x_i es la variable de entrada, b es el sesgo asignado y $(wx_i + b)$ es la salida predicha

A continuación, se calculan los pesos (w) (Ecuación 15) y sesgos (b) (Ecuación 16):



$$w_i = \alpha \frac{-2x_i(y_i - (w_{i-1}x_i + b_{i-1}))}{N} \text{ Ec. 15}$$

$$b_i = \alpha \frac{-2(y_i - (w_{i-1}x_i + b_{i-1}))}{N} \text{ Ec. 16}$$

Donde: N es el número de predicciones, y_i es la salida real, w_i es el nuevo peso calculado, w_{i-1} es el peso anterior, x_i es la variable de entrada, b_i es el nuevo sesgo calculado, b_{i-1} es el sesgo anterior y $(w_{i-1}x_i + b_{i-1})$ es la salida predicha con los pesos y sesgos anteriores

Tabla 54

Hiperparámetros (w: pesos y b: sesgos) del modelo desarrollado para la predicción de la acidez

Capa de entrada (x_i)	Neuronas		Hiperparámetros de la función matricial de una capa oculta													Capa de salida	
	(j)	w_{ij}	w_{2j}	w_{3j}	w_{4j}	w_{5j}	w_{6j}	w_{7j}	b_j	w_{ol}	b_o	(y)					
(x ₁) Temperatura (°C)	1	-0.212	-0.788	-0.791	-0.985	-0.695	-0.192	-0.243	-0.571	-0.123							
(x ₂) Inóculo (%)	2	-0.355	-0.118	-0.791	-0.826	-0.668	-0.517	-0.394	-0.505	0.246							
(x ₃) Proteína (%)	3	-0.398	-0.151	0.298	-0.575	-0.231	0.046	-0.489	-0.345	0.112							
(x ₄) Tiempo (min)	4	-0.111	-0.181	-0.835	-0.275	-0.842	-1.214	-1.057	-0.768	0.162							
(x ₅) Red (R)	5	0.071	-0.344	-0.902	0.464	-0.043	-0.426	-0.793	-0.336	-0.187							
(x ₆) Green (G)	6	-0.934	-1.027	-0.213	-0.164	-0.112	-0.640	-0.535	-0.640	0.582							
(x ₇) Blue (B)	7	0.646	-0.329	-0.622	-0.476	-0.592	-1.100	-0.425	-0.662	0.681							
	8	-0.238	-0.974	-0.875	-0.828	-0.343	-0.930	-0.949	-0.607	0.175							
	9	-0.050	-0.499	-0.376	-0.859	-0.156	-0.215	-0.289	-0.440	0.288							
	10	-0.668	-0.772	-0.458	-0.818	-0.136	-0.467	-0.215	-0.499	0.212							
	11	-0.277	-0.871	-0.936	0.118	-0.119	-0.234	-0.552	-0.417	-0.376							
	12	-0.125	-0.272	-0.414	-0.080	0.151	-0.235	-0.186	0.000	0.485							
	13	-0.750	-1.148	-0.377	-0.532	-0.516	-0.701	-0.787	-0.495	-0.242							
	14	-0.236	-0.712	-0.869	-0.581	-0.929	-0.793	-0.307	-0.520	0.488							
	15	-0.815	-0.418	-0.779	0.466	-0.473	-0.472	-0.660	-0.600	-0.542							
	16	-0.425	-0.641	-0.051	-0.641	-0.994	-0.715	-0.850	-0.508	0.109							
	17	-0.274	-0.392	-0.139	-0.721	-0.427	-0.096	-0.944	-0.535	0.386							
	18	1.238	0.117	0.208	4.606	2.998	0.424	-2.862	-2.650	0.194							
	19	-0.358	-0.468	-0.581	0.674	-0.329	-0.439	-0.998	-0.530	-0.347							
	20	-0.063	-0.423	-0.512	-0.362	-0.361	-0.313	-0.178	-0.475	-0.476							
	21	-0.991	-0.435	-0.213	0.192	-0.495	-0.442	-0.303	-0.494	-0.312							
	22	-0.751	-0.705	-0.668	-0.686	-0.155	-0.482	-0.283	-0.715	0.251							
	23	-0.578	-0.372	-0.817	0.505	-0.926	-0.185	-0.606	-0.601	-0.319							
	24	-0.156	-0.531	0.265	-0.398	-0.285	0.117	-0.056	-0.277	0.141							


Acidez
(% Ác. Láct.)
0.195

4.4.3.2. Modelo para la predicción del pH a partir de imágenes digitales

En la Figura 74, se ilustra la estructura del modelo desarrollado para predecir el pH de la leche durante su fermentación, como en el modelo anterior, las variables de entrada se encuentran en la capa de entrada, en este modelo también fue necesario 24 neuronas en la capa oculta para alcanzar las mejores métricas de desempeño entre el conjunto de arquitecturas entrenados.

Figura 74

Representación de la arquitectura del modelo desarrollado para la predicción del pH



En la Tabla 55 se describen los parámetros estructurales de la función matricial del modelo diseñado para predecir el pH, empleando datos de 7 variables de entrada ($x_i, i= 1, 2, \dots, 7$). Al igual que en el modelo para la predicción de acidez, los datos de las variables de entrada se



escalaron previamente entre 0 y 1 y se normalizaron, asegurando un rendimiento óptimo del modelo.

Este modelo sigue la misma estructura que el utilizado para predecir la acidez, aplicando procedimientos de cálculo equivalentes en ambos casos. La única diferencia radica en los valores de los parámetros que definen las ecuaciones, los cuales se especifican en la Tabla 55. Esta consistencia estructural se basa en la relación proporcional observada entre la formación de acidez y la disminución del pH, dos fenómenos estrechamente interrelacionados durante la fermentación, lo que justifica su tratamiento mediante modelos similares.

La similitud entre los modelos no solo refuerza la coherencia metodológica, sino que también facilita una interpretación conjunta de los resultados, permitiendo una comparación más clara entre las variables involucradas. Dada la fuerte correlación entre la acidez y el pH, ambos modelos pueden capturar de manera eficiente los patrones subyacentes del proceso fermentativo. Esta capacidad de modelar fenómenos interrelacionados mejora la predicción de los resultados, maximizando la capacidad del modelo para generalizar a diferentes condiciones y contextos. Además, fortalece su aplicabilidad en escenarios de análisis y control industrial, donde es crucial contar con herramientas predictivas precisas. En resumen, este enfoque destaca la importancia de un diseño estructurado y basado en principios coherentes que favorezca la integración y comparación entre modelos relacionados, asegurando su efectividad y flexibilidad.

Tabla 55

Hiperparámetros (w: pesos y b: sesgos) del modelo desarrollado para la predicción del pH

Capa de entrada (x_i)	Neuronas (j)	Hiperparámetros de la función matricial de una capa oculta												Capa de salida (y)
		w_{1j}	w_{2j}	w_{3j}	w_{4j}	w_{5j}	w_{6j}	w_{7j}	b_j	w_{o1}	b_o			
	1	-0.351	-0.387	-0.675	-0.476	-0.951	-0.469	-0.539	-0.601	0.196				
	2	-1.015	-0.824	-0.196	-0.787	-0.469	-1.009	-0.328	-0.601	0.128				
	3	-0.367	-0.194	-0.504	-0.974	-0.750	-0.556	-0.960	-0.601	0.115				
	4	-3.889	-1.912	-1.048	2.460	-1.289	-0.898	-1.177	-1.716	-0.348				
	5	-1.699	-0.562	-0.226	-5.779	-0.076	-2.293	2.097	6.006	0.621				
	6	-1.648	-1.025	0.410	-0.090	-0.343	-0.613	-0.571	0.131	0.090				
	7	-3.117	0.992	-1.965	-0.245	-0.711	-0.176	-0.375	-1.168	-0.452				
	8	-0.317	-0.966	-0.699	-0.966	-0.214	-0.574	-0.290	-0.580	0.586				
	9	-2.124	-0.711	-0.098	-7.136	-2.836	1.324	1.155	4.776	-0.416				
	10	0.026	-0.206	0.072	-0.263	0.097	-0.361	-0.016	0.000	0.365				
	11	-0.672	-2.180	-0.579	4.341	-2.353	-1.921	-1.813	-2.735	0.074				
	12	-0.364	-0.578	-0.876	-0.763	-0.913	-0.201	-0.648	-0.601	0.483				
	13	-0.268	-0.303	-1.028	-1.008	-0.420	-0.840	-0.607	-0.619	0.425				
	14	-0.973	-0.543	-0.762	-1.016	-0.866	-0.172	-0.167	-0.601	0.235				
	15	-0.685	-1.545	-0.655	0.948	-1.280	-1.492	-1.317	-0.472	-0.485				
	16	-0.690	-0.572	-0.719	-0.634	-0.372	-0.719	-0.339	-0.601	0.114				
	17	-0.561	-1.300	-0.388	-0.170	-0.766	-0.820	-1.014	-0.624	0.001				
	18	0.707	-0.800	-1.075	-0.590	-1.080	-0.903	-0.899	0.121	-0.076				
	19	-0.387	-0.953	-0.354	-0.955	-0.836	-0.741	-0.294	-0.656	0.152				
	20	-0.307	-13.664	-7.119	9.505	1.117	1.003	1.234	-6.023	-0.405				
	21	-0.521	-0.448	-0.322	-0.621	-0.491	-0.237	-0.977	-0.616	0.461				
	22	-1.704	-2.437	-1.836	-7.249	-0.981	-0.677	0.194	0.221	0.376				
	23	-0.378	-0.861	-0.313	-0.485	-1.032	-0.344	-0.560	-0.638	0.384				
	24	-1.790	-0.969	-0.780	-1.448	-0.700	-1.252	-0.988	0.426	-0.079				

(x_1) Temperatura (°C)

(x_2) Inóculo (%)

(x_3) Proteína (%)

(x_4) Tiempo (min)

(x_5) Red (R)

(x_6) Green (G)

(x_7) Blue (B)

4.763
pH


4.4.3.3. Modelo para la predicción de la viscosidad a partir de imágenes digitales

En la Figura 75 se muestra la estructura del modelo desarrollado, que utiliza los valores RGB de las imágenes digitales y los parámetros de producción del yogur. La arquitectura consta de una capa oculta con 28 neuronas, lo que resultó ser la mejor configuración en comparación con otras durante el entrenamiento. Sin embargo, su precisión, de aproximadamente el 50%, indica que el modelo no logró un ajuste adecuado. Esto sugiere que, aunque intenta capturar la relación entre los valores RGB y la viscosidad del yogur, se requieren mejoras en la estructura y los datos de entrenamiento para obtener mejores resultados.

El nivel de precisión alcanzado podría explicarse por el comportamiento relativamente estable de la viscosidad durante la mayor parte de la fermentación, con un aumento abrupto en los últimos 30 a 40 minutos del proceso. Este patrón podría dificultar el aprendizaje del modelo, ya que se requiere una mayor capacidad para capturar estas variaciones repentinas. Además, las oscilaciones en los valores RGB, provocadas por las luminarias LED de 50 Hz, podrían haber influido negativamente en el ajuste y desempeño de los modelos entrenados. Este comportamiento oscilante añade ruido a las imágenes y complica la correcta identificación de patrones relevantes para predecir la viscosidad. En consecuencia, es necesario explorar nuevas arquitecturas o mejorar la calidad de los datos para lograr un mejor desempeño del modelo en la predicción de la viscosidad del yogur.

Figura 75

Representación de la arquitectura del modelo desarrollado para la predicción de la viscosidad



Los factores de la función matricial correspondientes a la arquitectura con la mejor métrica de desempeño se muestran en la Tabla 56. Los valores de las variables de entrada fueron previamente escalados y normalizados antes de ser procesados por el modelo. Cada una de las 28 neuronas de la capa oculta calculó un valor z_j , que fue sometido a la función de activación $ReLU f(z_j)$. Esta función neutraliza los valores negativos asignándoles un valor de 0, mientras que los positivos permanecen inalterados. Luego, el valor transformado $f(z_j)$ se introdujo en la neurona de salida, multiplicado por su peso w_{oj} , y sumándole el sesgo b_o . para así poder estimar el valor de salida y , que viene a ser el valor de la viscosidad predicha.

Tabla 56

Hiperparámetros (w: pesos y b: sesgos) del modelo desarrollado para la predicción de la viscosidad

Capa de entrada (xi)	Neurona													Capa de salida (y)
	Hiperparámetros de la función matricial de una capa oculta													
(j)	w _{1j}	w _{2j}	w _{3j}	w _{4j}	w _{5j}	w _{6j}	w _{7j}	b _j	w _{o1}	b _o				
1	3.443	-1.834	-0.880	11.998	2.612	0.361	-3.169	-11.457	52.098					
2	-0.378	-0.467	-0.582	-0.289	-0.914	-0.723	-0.562	-0.613	0.323					
3	12.912	9.139	-3.052	46.663	10.276	16.095	-20.851	-48.790	439.553					
4	-0.749	-0.360	-0.828	0.489	-0.685	-0.453	-0.898	-0.396	-0.315					
5	-0.530	-0.368	-1.000	-0.517	-0.630	-0.404	-0.952	-0.601	0.242					
6	-2.647	-1.426	0.352	0.884	-1.024	-1.339	-1.798	-0.996	-0.087					
7	-1.574	-1.064	-2.799	3.122	-0.692	-1.742	-2.387	-3.055	1.045					
8	-0.467	-0.416	-0.304	-0.266	-0.720	-0.860	-0.733	-0.531	0.410					
9	-3.908	2.253	-27.091	56.673	-33.200	-28.505	3.100	-25.241	-134.270					
10	-0.321	-0.400	-0.858	-0.602	-0.718	-0.526	-0.648	-0.601	0.231			6.058		
11	-0.597	-0.256	-0.641	-0.391	-0.925	-0.428	-0.607	-0.512	-0.343					
12	-0.301	-0.409	-0.800	-0.897	-0.190	-0.931	-0.539	-0.601	0.369					
13	14.755	10.053	-5.647	53.371	-20.028	-29.699	-38.612	-23.020	155.725					
14	1.453	-0.206	-0.653	8.856	-0.812	-1.506	-4.383	-7.943	10.594					
15	-0.837	-0.868	-0.963	-0.419	-0.293	-0.281	-0.291	-0.627	0.495					
16	-0.665	-0.667	-0.399	-0.969	-0.893	-0.383	-0.595	-0.600	0.291					
17	-0.899	-0.188	-0.815	-0.915	-0.555	-0.827	-0.722	-0.508	0.414					
18	-0.266	-0.565	-0.508	-0.878	-0.274	-0.944	-0.543	-0.601	0.366					
19	1.480	1.312	2.466	15.321	19.201	-18.716	-0.229	-7.222	0.926					

(x₁) Temperatura (°C)
(x₂) Inóculo (%)
(x₃) Proteína (%)
(x₄) Tiempo (min)
(x₅) Red (R)
(x₆) Green (G)
(x₇) Blue (B)

Hiperparámetros de la función matricial de una capa oculta

Neurona (j)	w_{1j}	w_{2j}	w_{3j}	w_{4j}	w_{5j}	w_{6j}	w_{7j}	w_{8j}	w_{9j}	w_{10j}	b_j	w_{o1}	b_o
20	0.813	-1.387	-1.568	8.003	1.244	-0.657	-4.948	-0.657	-0.910	-0.332	-0.601	9.334	9.334
21	-0.665	-0.386	-0.774	-0.438	-0.887	-0.910	-0.332	-0.820	-0.667	0.404	0.326	0.581	0.581
22	-0.995	-0.354	-0.813	-0.352	-0.703	-0.352	-0.820	-0.667	0.404	0.326	0.581	0.581	0.581
23	-0.670	-0.506	-0.546	-0.989	-0.507	-0.725	-0.743	-0.821	0.326	0.581	0.581	0.581	0.581
24	-0.382	-0.801	-0.228	-0.576	-0.962	-0.928	-0.794	-0.599	0.581	0.581	0.581	0.581	0.581
25	-0.033	-1.796	-3.673	2.795	-0.545	-0.635	-1.565	-2.029	0.444	0.444	0.444	0.444	0.444
26	-2.242	35.285	-14.640	18.225	-69.555	-29.923	-79.413	-5.570	-37.196	-37.196	-37.196	-37.196	-37.196
27	-0.482	-1.378	-2.470	2.289	0.241	-0.073	-1.110	-1.765	0.581	0.581	0.581	0.581	0.581
28	15.914	-11.100	-1.504	37.433	39.557	13.783	-47.953	-34.470	266.712	266.712	266.712	266.712	266.712

Capa de entrada (xi)

Capa de salida (y)

4.4.3.4. Modelo para la predicción de acidez a partir de imágenes termográficas

En la Figura 76 se presenta la arquitectura del modelo desarrollado para predecir la acidez de la leche a partir de los valores RGB obtenidos de las imágenes termográficas. Esta estructura consta de una capa de entrada con 7 neuronas, correspondientes a las variables de entrada, seguida por una capa oculta con 12 neuronas interconectadas y una capa de salida con una neurona. La precisión alcanzada por esta arquitectura fue del 82,52%, ligeramente superior a la obtenida con el modelo basado en imágenes digitales. Este aumento resalta el potencial de la cámara termográfica para captar variaciones en las propiedades del sistema a través de la medición de emisiones infrarrojas, y la capacidad de la red neuronal densa para identificar patrones complejos, logrando predecir con alta precisión el comportamiento de la formación de ácido láctico durante la fermentación de la leche.

La estructura de la red neuronal muestra una integración eficiente entre la información proporcionada por las imágenes termográficas y el modelado mediante redes neuronales. El uso de 12 neuronas en la capa oculta permite un equilibrio adecuado entre la extracción de patrones relevantes y la prevención de problemas de sobreajuste. La precisión del 82.52% indica que la red está capturando bien las variaciones en los datos de entrada, lo que refleja una correcta interpretación de los fenómenos térmicos que ocurren durante la fermentación.

El uso de imágenes termográficas ofrece una ventaja significativa sobre las digitales, ya que estas imágenes pueden detectar cambios sutiles




en la emisión de calor, los cuales están directamente relacionados con el comportamiento físico y químico del sistema de fermentación. A diferencia de las imágenes digitales, las termográficas no dependen de la iluminación visible, lo que permite un monitoreo más preciso sin interferencias externas. Combinado con una red neuronal bien entrenada, este tipo de datos permite una predicción más precisa de la acidez, facilitando la optimización de procesos como la fermentación de la leche. Además, la capacidad de identificar patrones térmicos, junto con la potencia predictiva de la red, abre nuevas posibilidades para mejorar el control de calidad y la eficiencia en la producción industrial de productos lácteos, asegurando un producto final con características consistentes y de alta calidad.

En la Tabla 57 se presentan los parámetros de la función matricial del modelo desarrollado para la predicción de la acidez. Como en los casos anteriores, los valores de las variables de entrada ($x_i, i = 1, 2, \dots, 7$) fueron sometidos a un proceso de escalado y normalización antes de ser ingresados en la arquitectura del modelo. Cada una de las 12 neuronas de la capa oculta asigna un peso estimado ($w_{oj}, j = 1, 2, \dots, 12$) a cada una de las 7 variables de entrada y se le suma un sesgo único (b_j). Con estos valores se calcula el valor z_j , el cual es procesado por todas las neuronas de la capa oculta.

Figura 76

Representación de la arquitectura del modelo desarrollado para la predicción de la acidez



Los valores z_j resultantes se someten a una función de activación de tipo $ReLU f(z_j)$, cuya finalidad es neutralizar los valores negativos y conservar los valores positivos, asegurando una mayor estabilidad en el comportamiento del modelo. Posteriormente, los valores $f(z_1), f(z_2), \dots, f(z_{12})$ se conectan a la única neurona de la capa de salida a través de los pesos asignados ($w_{oj}, j = 1, 2, \dots, 12$) para cada valor de entrada. Finalmente, la acidez estimada (y) se obtiene como resultado del producto entre los valores $f(z_1), f(z_2), \dots, f(z_{12})$ y ($w_{oj}, j = 1, 2, \dots, 12$) y los pesos correspondientes, al cual se le suma el sesgo de la capa de salida (b_0).

En el modelo, la función de activación $ReLU$ permite manejar de manera eficiente valores no lineales y evitar que las neuronas se saturen.



La capa de entrada está bien definida con 7 variables claves que representan diferentes factores experimentales, mientras que la capa oculta con 12 neuronas es el que demostró mejores métricas de desempeño relacionando datos complejos de entrada para predecir una única variable (acidez).

Tabla 57

Hiperparámetros (w : pesos y b : sesgos) del modelo desarrollado para la predicción de la acidez

Capa de entrada (x_i)	Neurona (j)	Hiperparámetros de la función matricial de una capa oculta							Capa de salida (y)		
		w_{1j}	w_{2j}	w_{3j}	w_{4j}	w_{5j}	w_{6j}	w_{7j}	b_j	w_{oj}	b_o
	1	-0.848	-1.088	-0.789	-0.485	-0.899	-1.179	-0.747	-1.007	0.544	
	2	-1.015	-0.617	-0.194	-0.593	-0.993	-0.461	-0.806	-0.600	0.594	
	3	0.999	0.047	0.547	3.979	0.986	-3.013	-1.300	-0.215	0.192	
(x_1) Temperatura (°C)	4	-0.451	-0.491	-0.605	-0.684	-0.836	-0.480	-1.066	-0.601	0.291	
(x_2) Inóculo (%)	5	-0.741	-0.895	-1.111	-0.906	-0.575	-0.392	-0.085	-0.501	0.295	
(x_3) Proteína (%)	6	0.049	0.101	-0.963	-0.347	0.119	-0.475	-0.139	-0.430	0.016	0.22
(x_4) Tiempo (min)	7	-0.074	-0.978	-0.796	-0.923	0.020	-0.436	-0.265	-0.489	0.316	
(x_5) Red (R)	8	-0.670	-1.053	-0.545	-1.004	-0.131	-0.487	-0.321	-0.536	0.088	
(x_6) Green (G)	9	-0.232	-0.486	-0.540	-0.516	-0.261	-0.278	0.294	0.000	0.107	
(x_7) Blue (B)	10	-0.165	0.065	-1.059	0.926	-0.215	-0.711	-0.431	-0.456	-0.040	
	11	-0.217	-0.744	-0.037	-0.952	-0.973	-0.913	-0.476	-0.596	0.475	
	12	-0.684	-1.009	-0.518	-0.370	-0.175	-0.637	-0.755	-0.601	0.118	




4.4.3.5. Modelo para la predicción del pH a partir de imágenes termográficas

En la Figura 77 se muestra la arquitectura del modelo desarrollado para predecir el pH de la leche durante el proceso de fermentación, utilizando los valores RGB extraídos de las imágenes termográficas. Al igual que en los modelos anteriores, la capa de entrada está compuesta por 7 neuronas, cada una representando una de las variables de entrada. La estructura interna del modelo está formada por dos capas ocultas, cada una con 16 neuronas completamente conectadas, lo que permite una interacción eficiente entre las variables. La capa de salida tiene una única neurona encargada de calcular y devolver los valores estimados del pH.

Esta arquitectura alcanzó una precisión del 93,58%, significativamente superior a la del modelo basado en imágenes digitales. Este alto rendimiento destaca el potencial de las cámaras termográficas, que permiten captar variaciones en las propiedades ópticas a través de la cuantificación de emisiones infrarrojas. Además, demuestra la capacidad de la red neuronal densa para identificar patrones complejos en el proceso de fermentación. El modelo es capaz de monitorear con alta precisión la disminución del pH, lo que lo convierte en una herramienta eficaz para la optimización de procesos industriales relacionados con la producción de productos lácteos.

Figura 77

Representación de la arquitectura del modelo desarrollado para la predicción del pH



En la Tabla 58 se presentan los parámetros de la función matricial que constituyen el modelo desarrollado para la predicción del pH en función de los parámetros RGB extraídos de las imágenes digitales. Este modelo está compuesto por dos capas ocultas, lo que incrementa la cantidad de neuronas, o pericariones, pero esta mayor complejidad permite una estimación más precisa de los valores de pH.

El proceso comienza con la normalización y escalado de los datos de entrada (x_i , $i= 1, 2, \dots, 7$). Cada una de las 16 neuronas de la primera capa oculta calcula un valor (z_j) a partir de los pesos asignados (w_{ij} ; $i=1, 2, \dots, 7$) y los sesgos asociados (b_j). Estos valores (z_j) son filtrados mediante una función de activación del tipo *ReLU*, que elimina los valores

negativos y mantiene los positivos. Los resultados obtenidos de la primera capa oculta, $f(z_1), f(z_2), \dots, f(z_{16})$ se convierten en las variables de entrada para la segunda capa oculta

Dado que esta segunda capa también tiene 16 neuronas, se calculan 16 pesos ($w_{01j}, w_{02j}, \dots, w_{016j}$) y un sesgo (b_{0j}) para cada una de las neuronas. Posteriormente, los valores calculados en esta capa, (z_{0j}) se someten de nuevo a la función de activación *ReLU*, con el mismo objetivo de eliminar valores negativos y continuar con los positivos.

Finalmente, los valores $f(z_{01}), f(z_{02}), \dots, f(z_{016})$ se conectan con la neurona de salida a través de sus correspondientes pesos ($w_{p1}, w_{p2}, \dots, w_{p16}$) y un único sesgo (b_p) de la neurona de salida. La predicción del valor de pH se obtiene al multiplicar los valores de entrada por los pesos asignados a la capa de salida, sumando el sesgo correspondiente.

La estructura descrita refleja una arquitectura de la RNA densa adecuada para capturar relaciones no lineales complejas entre las variables RGB y el valor de pH. La utilización de dos capas ocultas con funciones de activación *ReLU* optimiza la capacidad del modelo para manejar la complejidad de los datos, eliminando entradas irrelevantes o valores negativos y centrando el aprendizaje en las relaciones más significativas.

El escalado y normalización de los datos asegura que todas las entradas tengan el mismo rango, evitando que las neuronas se vean influenciadas por variables con valores más altos. El uso de múltiples capas ocultas indica que el modelo está diseñado para captar patrones más complejos, lo que explica el alto nivel de precisión en las predicciones del pH basadas en imágenes termográficas.

Tabla 58

Hiperparámetros (w : pesos y b : sesgos) del modelo desarrollado para la predicción del pH

Capa de entrada (x_i)	Neurona (j)	Hiperparámetros de la función matricial de la primera capa oculta																
		w_{1j}	w_{2j}	w_{3j}	w_{4j}	w_{5j}	w_{6j}	w_{7j}	w_{8j}	w_{9j}	w_{10j}	w_{11j}	w_{12j}	w_{13j}	w_{14j}	w_{15j}	w_{16j}	b_j
	1	-0.5452	-0.9349	-0.2100	-0.2082	-0.4768	-0.7144	-0.7126	-0.6185									
	2	-3.0487	-0.8276	0.1552	-7.4740	-0.8695	2.8699	1.7830	3.9352									
	3	-0.4903	-0.6850	-0.3793	-2.6997	-0.4750	-0.1161	-0.2059	0.1409									
	4	0.3118	0.1538	-1.0012	-0.3773	-1.4285	-0.1535	-0.5111	-0.1221									
	5	-0.0286	-1.2408	-0.1385	-0.6694	-0.1215	-0.5017	-0.9037	-0.5488									
	6	3.8146	1.5203	0.5111	13.8138	4.6769	-7.9794	-2.2069	-5.7791									
	7	3.0772	0.4235	-3.8711	-6.4154	2.4725	-5.8000	-2.9873	5.3704									
	8	-0.9776	-0.5954	-0.1781	-0.2958	-1.0162	-0.4878	-0.4726	-0.6504									
	9	-0.5718	0.0076	-0.0140	-0.5802	-0.3228	-0.4950	-0.9674	-0.4662									
	10	-0.4880	-0.2662	-0.2817	-1.0023	-0.6081	-0.9789	-0.6562	-0.6191									
	11	-0.6817	-0.9263	-1.0391	-1.0041	-0.1920	-0.3078	-0.2436	-0.6005									
	12	-0.0579	-0.2757	-0.1841	-0.4657	-0.3292	0.0706	-0.1795	0.0000									
	13	-4.0824	1.6329	-10.9121	11.8702	-4.6995	6.1106	0.6417	-10.3264									
	14	-0.8671	-0.8293	0.2022	-0.1399	-0.5744	-0.5169	-0.2980	-0.2528									
	15	0.7052	-0.9548	-0.5932	0.1561	-0.6715	-0.1807	-0.1477	-0.7969									
	16	-0.8822	-0.4680	-0.3150	-0.3799	-0.4465	-0.7706	-0.8955	-0.6986									
(x_1)	Temperatura (°C)																	
(x_2)	Inóculo (%)																	
(x_3)	Proteína (%)																	
(x_4)	Tiempo (min)																	
(x_5)	Red (R)																	
(x_6)	Green (G)																	
(x_7)	Blue (B)																	

Hiperparámetros de la función matricial de la segunda capa oculta

W_{01j}	W_{02j}	W_{03j}	W_{04j}	W_{05j}	W_{06j}	W_{07j}	W_{08j}	W_{09j}	W_{010j}	W_{011j}	W_{012j}	W_{013j}	W_{014j}	W_{015j}	W_{016j}	b_{0j}
-0.414	-2.005	-0.376	-0.078	0.980	-2.008	-0.393	0.549	0.864	0.352	0.221	0.117	-0.361	-0.185	-0.190	1.068	-0.009
0.230	-1.443	-0.726	0.801	-0.147	-1.338	-1.692	0.056	-0.390	-0.234	0.402	-0.145	-1.376	0.930	-0.691	0.246	-0.991
-0.198	-0.836	-0.765	-0.809	-0.577	-0.184	-0.892	-0.561	-0.683	-0.768	-0.523	0.145	-0.673	-0.235	-0.192	-0.556	-0.601
-0.552	-0.704	-0.293	-0.162	-0.310	-0.779	-0.130	-0.383	-0.483	-0.909	-0.589	-0.047	-0.262	-0.683	-0.494	-0.369	-0.476
0.029	-0.408	-0.221	0.382	0.245	0.754	-0.351	0.395	0.591	0.683	0.827	0.394	0.926	-0.046	-0.066	1.061	1.680
-0.246	-1.532	-0.184	0.127	0.089	-1.156	-0.884	0.785	0.957	0.455	0.413	-0.335	-0.152	0.345	-0.585	0.394	0.000
-0.223	-0.831	-0.419	-0.396	-0.460	-0.118	-0.826	-0.979	-1.025	-0.148	-0.333	-0.405	-0.388	0.265	-0.638	-0.409	-0.601
-0.209	-0.423	-0.321	0.003	-0.280	-0.396	-0.085	0.260	-0.301	-0.425	0.063	0.204	-1.816	-0.052	-0.315	-0.072	-2.035
-0.898	-0.452	-0.450	-0.609	-0.698	-0.686	-0.563	-0.878	-0.535	0.008	-0.416	0.149	-0.097	-0.845	-0.341	0.311	-0.396
-0.042	-1.812	-0.080	0.218	0.583	-1.792	-0.693	0.826	0.251	0.206	0.172	0.017	-1.128	0.341	0.327	0.563	-0.114
0.026	-0.597	-0.957	-0.356	-0.362	-0.404	-0.619	-0.139	-0.251	0.422	0.427	0.261	-0.357	0.315	-0.561	-0.258	-0.556
-0.349	-1.085	-0.252	-0.416	0.826	-0.898	-0.395	0.701	0.095	0.930	0.589	-0.062	0.027	-0.471	0.185	0.702	-0.388
-0.368	0.070	-0.189	0.044	0.596	-4.190	0.039	0.464	0.439	0.667	0.351	-0.390	-1.725	-0.288	-0.025	0.468	-0.828
-0.343	-0.642	-0.760	-0.984	-0.812	-1.071	-0.462	-0.260	-0.470	-0.254	-0.600	-0.337	-0.789	-0.878	-0.277	-0.254	-0.698
-0.419	-0.716	-0.687	-0.440	-0.059	-7.243	-0.584	0.774	0.975	0.318	0.668	0.006	-0.216	-0.091	-0.553	0.450	-1.251
-0.588	-0.793	-0.296	-0.908	-0.773	-0.813	-0.242	-0.397	-0.787	-0.417	-0.371	-0.145	-0.455	-0.407	-0.817	-0.968	-0.601




Hiperparámetros de la función matricial de una capa oculta	
w_{pj}	b_p
-0.027	
-1.111	
0.055	
0.042	
-0.309	
0.017	
0.405	
-1.960	
-0.194	
0.028	
0.387	
-0.318	
-0.019	
0.401	
-1.001	
0.532	
	6.418
	pH

4.4.3.6. Modelo para la predicción de la viscosidad a partir de imágenes termográficas

En la Figura 78 se presenta la arquitectura del modelo desarrollado para la predicción de la viscosidad a partir de los valores RGB obtenidos de las imágenes termográficas. A diferencia del modelo previo desarrollado con el mismo propósito, este modelo cuenta con una única capa oculta conformada por 16 neuronas. Además, logró alcanzar un nivel de precisión significativamente superior, con un valor del 86.87%. Estos resultados refuerzan el potencial de la termografía infrarroja como herramienta para la monitorización precisa del proceso de fermentación de la leche.

Figura 78

Representación de la arquitectura del modelo desarrollado para la predicción de la viscosidad





Durante la etapa de entrenamiento, a cada neurona de la capa oculta se le asigna un peso ($w_j, j = 1, 2, \dots, 7$) correspondiente a cada una de las variables de entrada, además de un sesgo único por neurona (b_j). Con estos valores, la neurona calcula un resultado intermedio (z_j), el cual es procesado mediante una función de activación *ReLU*. Esta función tiene como objetivo principal transformar cualquier valor negativo en cero, mientras que mantiene inalterados los valores positivos. Este mecanismo de activación es fundamental, ya que no solo optimiza el flujo de información al reducir la propagación de valores negativos, sino que también introduce no linealidad en el modelo, lo que le permite capturar patrones más complejos en los datos. De esta manera, la función *ReLU* facilita la continuidad y eficiencia del procesamiento de los datos dentro del modelo, permitiendo que las neuronas en la capa oculta aprendan representaciones más efectivas de las relaciones entre las variables de entrada y las predicciones de salida.

Los resultados de la capa oculta, $f(z_1), f(z_2), \dots, f(z_{16})$, se conectan a la capa de salida mediante los pesos correspondientes (w_{oj}) y un único sesgo asociado a dicha capa (b_{oj}). Esta conexión garantiza que la información procesada por las neuronas ocultas sea adecuadamente ponderada antes de llegar a la neurona de salida. Esta neurona realiza una combinación final de los factores, aplicando los pesos y el sesgo, para generar el valor estimado de viscosidad. Este resultado es proviene de la interacción de los parámetros ajustados durante el entrenamiento, lo cual permite la estimación del valor de la viscosidad.

Tabla 59

Hiperparámetros (w : pesos y b : sesgos) del modelo desarrollado para la predicción de la viscosidad

Capa de entrada (x_i)	Neurona (j)	Hiperparámetros de la función matricial de una capa oculta										Capa de salida (y)
		w_{1j}	w_{2j}	w_{3j}	w_{4j}	w_{5j}	w_{6j}	w_{7j}	b_j	w_{oj}	b_o	
(x_1) Temperatura (°C)	1	-0.848	-1.088	-0.789	-0.485	-0.899	-1.179	-0.747	-1.007	0.544		
(x_2) Inóculo (%)	2	-1.015	-0.617	-0.194	-0.593	-0.993	-0.461	-0.806	-0.600	0.594		
(x_3) Proteína (%)	3	0.999	0.047	0.547	3.979	0.986	-3.013	-1.300	-0.215	0.192		
(x_4) Tiempo (min)	4	-0.451	-0.491	-0.605	-0.684	-0.836	-0.480	-1.066	-0.601	0.291		
(x_5) Red (R)	5	-0.741	-0.895	-1.111	-0.906	-0.575	-0.392	-0.085	-0.501	0.295		
(x_6) Green (G)	6	0.049	0.101	-0.963	-0.347	0.119	-0.475	-0.139	-0.430	0.016		0.22
(x_7) Blue (B)	7	-0.074	-0.978	-0.796	-0.923	0.020	-0.436	-0.265	-0.489	0.316		
	8	-0.670	-1.053	-0.545	-1.004	-0.131	-0.487	-0.321	-0.536	0.088		
	9	-0.232	-0.486	-0.540	-0.516	-0.261	-0.278	0.294	0.000	0.107		
	10	-0.165	0.065	-1.059	0.926	-0.215	-0.711	-0.431	-0.456	-0.040		
	11	-0.217	-0.744	-0.037	-0.952	-0.973	-0.913	-0.476	-0.596	0.475		
	12	-0.684	-1.009	-0.518	-0.370	-0.175	-0.637	-0.755	-0.601	0.118		



V. CONCLUSIONES

- Las técnicas ópticas contactless han mostrado gran potencial para monitorear propiedades fisicoquímicas de la leche, como viscosidad, acidez y pH, durante la fermentación del yogur. Aunque la visión por computadora alcanzó una precisión de hasta 84.11%, la termografía superó el 82.58%, gracias a su mayor sensibilidad en el espectro infrarrojo, lo que permite una detección más precisa de las variaciones térmicas. Estos resultados destacan la termografía como la tecnología preferida para el monitoreo de este proceso.
- El sistema de monitorización mediante técnicas ópticas está conformado por un equipo de fermentación que demostró ser eficaz al mantener las temperaturas la fermentación a excepción a 36°C, en la que se registró mayor desviación estándar en la temperatura de fermentación. Además, el sistema de monitorización en especial cuenta con equipos ópticos que incluye cámara fotográfica, termográfica e iluminación que fue acoplado sobre el equipo de fermentación para registrar los cambios tanto en el espectro visible (imagen fotográfica) como en el infrarrojo (imagen termográfica) durante todo el proceso de fermentación del yogur.
- A través de técnicas convencionales de análisis fisicoquímico del yogur se reveló que las concentraciones de proteína de 4.2% y 4.8% fueron óptimas para alcanzar valores adecuados de acidez y pH. Sin embargo, la concentración de 4.8% destacó por proporcionar mejores propiedades en términos de viscosidad y en los componentes a^* y b^* de la escala CIELab. Por otro lado, las concentraciones de inóculo del 2% y 3% favorecieron una mayor viscosidad, mientras que las concentraciones del 1% y 3% alcanzaron valores máximos en el componente a^* . Además, la temperatura afectó considerablemente la duración del proceso de fermentación: a mayor temperatura se registró mayor valor L^* pero menor tiempo de fermentación y viscosidad.



- Se desarrollaron y entrenaron modelos predictivos basados en Redes Neuronales Artificiales Densas, explorando diversas arquitecturas compuestas por capas ocultas y diferentes cantidades de neuronas por capa, para predecir las propiedades fisicoquímicas de la leche durante la fermentación del yogur: viscosidad, acidez y pH. Estos modelos fueron construidos a partir de los valores RGB extraídos de imágenes digitales y termográficas, y se seleccionaron un total de seis modelos finales, dos para cada variable de respuesta. En el caso de las imágenes digitales, las arquitecturas seleccionadas que demostraron el mejor desempeño incluyeron modelos con una sola capa oculta y entre 24 y 28 neuronas para predecir la viscosidad, acidez y pH. De forma similar, los modelos basados en imágenes termográficas incluyeron arquitecturas con una sola capa oculta con 12 y 16 neuronas para predecir viscosidad y acidez, respectivamente, mientras que para el pH se seleccionó un modelo con dos capas ocultas y 16 neuronas por capa, que mostró métricas superiores. En términos generales, los modelos basados en imágenes termográficas lograron precisiones superiores al 82.58%, superando a los desarrollados con imágenes digitales, cuya precisión osciló entre 50.3% y 84.11%. Estos resultados confirman el potencial de combinar imágenes termográficas y redes neuronales para un monitoreo más preciso y eficiente de las propiedades fisicoquímicas del yogur durante el proceso de fermentación.



VI. RECOMENDACIONES

- La cámara fotográfica es un dispositivo óptico diseñado para capturar y registrar imágenes visibles. Sin embargo, la utilización de Notas de luz de corriente alterna introduce fluctuaciones en estos valores, afectando la homogeneidad de la imagen. Por consiguiente, se recomienda emplear sistemas de iluminación de corriente continua, los cuales garantizan una iluminación estable y uniforme, ideal para aplicaciones que demandan una alta precisión colorimétrica.
- Para garantizar la eficacia de los procesos de tratamiento térmico de la leche, como la pasteurización, se recomienda el empleo de equipos especializados, tales como la autoclave. Estos dispositivos permiten llevar a cabo la pasteurización de manera óptima, minimizando el riesgo de daños térmicos que podrían afectar significativamente las propiedades organolépticas del producto, específicamente en lo que respecta a las mediciones de color en la escala CIELab.
- Para una monitorización precisa de la viscosidad de la leche durante su transformación en yogur, se sugiere emplear un reómetro de alta sensibilidad. Que permitirá cuantificar con exactitud las mínimas variaciones en el esfuerzo de corte. Además, para preservar la integridad de la muestra y evitar la pérdida de la fuerza de gelificación, se recomienda realizar las mediciones directamente en el reactor de fermentación.
- Para una medición precisa del color durante la fermentación, se sugiere emplear un cubo de cristal con un volumen de muestra estandarizado. Experimentos previos han demostrado que las variaciones en el volumen de la muestra pueden influir significativamente en los resultados colorimétricos.



VII. REFERENCIAS BIBLIOGRÁFICAS

- Abanto, K., Aguilar, J., Amaya, C., Castillo, S., & Chacón, J. (2022). Sorting task de yogures de fresa aplicados a consumidores de la provincia de trujillo (2022): estudio de características sensoriales y análisis multivariante. *Journal of Neuroscience and Public Health*, 3, 265–272.
<https://doi.org/10.46363/jnph.v2i3.3>
- Addanki, M., Patra, P., & Kandra, P. (2022). Recent advances and applications of artificial intelligence and related technologies in the food industry. *Applied Food Research*, 2(2), 100126. <https://doi.org/10.1016/j.afres.2022.100126>
- Akarca, G., & Denizkara, A. J. (2024). Changes of quality in yoghurt produced under magnetic field effect during fermentation and storage processes. *International Dairy Journal*, 150, 105841. <https://doi.org/10.1016/j.idairyj.2023.105841>
- Akgun, A., Yazici, F., & Gulec, H. A. (2018). The combined effect of probiotic cultures and incubation final pH on the quality of buffalo milk yogurt during cold storage. *Food Science & Nutrition*, 6(2), 492–502.
<https://doi.org/10.1002/fsn3.580>
- Alcivar Pelaez, O. A. (2016). *Evaluacion de la acidez titulable en la elaboracion de yoguren base a la norma INEN 2395 en lacteos nacionales.*
- Aldaw Ibrahim, I., Naufalin, R., Erminawati, & Dwiyantri, H. (2019). Effect of fermentation temperature and culture concentration on microbial and physicochemical properties of cow and goat milk yogurt. *IOP Conference Series: Earth and Environmental Science*, 406(1), 012009.
<https://doi.org/10.1088/1755-1315/406/1/012009>
- Alfaro, A. D. J., & Ospina, J. V. D. (2021). Revisión sistemática de literatura: Técnicas de aprendizaje automático (machine learning). *Cuaderno Activa*, 13(1), 113–121.
- Ali, A. H., Alsalmi, M., Alshamsi, R., Tarique, M., Bamigbade, G., Zahid, I., Nazir, M. H., Waseem, M., Abu-Jdayil, B., Kamal-Eldin, A., Huppertz, T., & Ayyash, M. (2023). Effect of whey protein isolate addition on set-type camel milk



- yogurt: Rheological properties and biological activities of the bioaccessible fraction. *Journal of Dairy Science*, *106*(12), 8221–8238.
<https://doi.org/10.3168/jds.2023-23421>
- Alvarado, U., Zamora, A., Arango, O., Saldo, J., & Castillo, M. (2022a). Prediction of riboflavin and ascorbic acid concentrations in skimmed heat-treated milk using front-face fluorescence spectroscopy. *Journal of Food Engineering*, *318*, 110869. <https://doi.org/10.1016/j.jfoodeng.2021.110869>
- Alvarado, U., Zamora, A., Arango, O., Saldo, J., & Castillo, M. (2022b). Prediction of riboflavin and ascorbic acid concentrations in skimmed heat-treated milk using front-face fluorescence spectroscopy. *Journal of Food Engineering*, *318*, 110869. <https://doi.org/10.1016/j.jfoodeng.2021.110869>
- Arab, M., Yousefi, M., Khanniri, E., Azari, M., Ghasemzadeh-Mohammadi, V., & Mollakhalili-Meybodi, N. (2023). A comprehensive review on yogurt syneresis: effect of processing conditions and added additives. *Journal of Food Science and Technology*, *60*(6), 1656–1665.
<https://doi.org/10.1007/s13197-022-05403-6>
- Arango, O., Trujillo, A. J., & Castillo, M. (2020). Influence of fat substitution by inulin on fermentation process and physical properties of set yoghurt evaluated by an optical sensor. *Food and Bioproducts Processing*, *124*, 24–32.
<https://doi.org/10.1016/j.fbp.2020.07.020>
- Aryana, K. J., & Olson, D. W. (2017). A 100-Year Review: Yogurt and other cultured dairy products. *Journal of Dairy Science*, *100*(12), 9987–10013.
<https://doi.org/10.3168/jds.2017-12981>
- Atamian, S., Olabi, A., Kebbe Baghdadi, O., & Toufeili, I. (2014). The characterization of the physicochemical and sensory properties of full-fat, reduced-fat and low-fat bovine, caprine, and ovine Greek yogurt (Labneh). *Food Science & Nutrition*, *2*(2), 164–173. <https://doi.org/10.1002/fsn3.89>
- Bahmani, L., Minaei, S., Banakar, A., Mahdavian, A., & Soltani Firouz, M. (2024). Thermography and deep learning for detection of ground beef adulteration.



Microchemical Journal, 205, 111174.

<https://doi.org/10.1016/j.microc.2024.111174>

Baranowski, P., Mazurek, W., Wozniak, J., & Majewska, U. (2012). Detection of early bruises in apples using hyperspectral data and thermal imaging. *Journal of Food Engineering*, 110(3), 345–355.

<https://doi.org/10.1016/j.jfoodeng.2011.12.038>

Barros, R. F., Cutrim, C. S., Costa, M. P. da, Conte Junior, C. A., & Cortez, M. A. S. (2019). Lactose hydrolysis and organic acids production in yogurt prepared with different onset temperatures of enzymatic action and fermentation. *Ciência Animal Brasileira*, 20, e43549.

Batista, L. F., Marques, C. S., Pires, A. C. dos S., Minim, L. A., Soares, N. de F. F., & Vidigal, M. C. T. R. (2021a). Artificial neural networks modeling of non-fat yogurt texture properties: effect of process conditions and food composition. *Food and Bioproducts Processing*, 126, 164–174.

<https://doi.org/10.1016/j.fbp.2021.01.002>

Batista, L. F., Marques, C. S., Pires, A. C. dos S., Minim, L. A., Soares, N. de F. F., & Vidigal, M. C. T. R. (2021b). Artificial neural networks modeling of non-fat yogurt texture properties: effect of process conditions and food composition. *Food and Bioproducts Processing*, 126, 164–174.

<https://doi.org/10.1016/j.fbp.2021.01.002>

Bosakova-Ardenska, A. (2024). Recent Trends in Computer Vision for Cheese Quality Evaluation. *CIEES 2023*, 12.

<https://doi.org/10.3390/engproc2024060012>

Bowler, A., Ozturk, S., di Bari, V., Glover, Z. J., & Watson, N. J. (2023). Machine learning and domain adaptation to monitor yoghurt fermentation using ultrasonic measurements. *Food Control*, 147, 109622.

<https://doi.org/10.1016/j.foodcont.2023.109622>

Burkov, A. (2019). *The Hundred-Page Machine Learning* (I). Leanpub.

Caccamo, M., Melilli, C., Barbano, D. M., Portelli, G., Marino, G., & Licitra, G. (2004). Measurement of Gas Holes and Mechanical Openness in Cheese by



- Image Analysis. *Journal of Dairy Science*, 87(3), 739–748.
[https://doi.org/10.3168/jds.S0022-0302\(04\)73217-8](https://doi.org/10.3168/jds.S0022-0302(04)73217-8)
- Castillo, M. (2002). *Predicción del tiempo de corte en la elaboración de queso mediante dispersión de radiación de infrarrojo próximo*. Universidad de Murcia.
- Chacaguasay Lobato, E. M., & Picho Barrionuevo, C. E. (2016). *DISEÑO Y CONSTRUCCIÓN DE UNA MARMITA CILÍNDRICA CON AGITADOR Y FONDO ESFÉRICO CON RANGO DE TEMPERATURA DE 70°C A 80°C PARA PRODUCCIÓN DE 50 LITROS DE ADEREZOS*.
- Chen, C., Zhao, S., Hao, G., Yu, H., Tian, H., & Zhao, G. (2017). Role of lactic acid bacteria on the yogurt flavour: A review. *International Journal of Food Properties*, 20(sup1), S316–S330.
<https://doi.org/10.1080/10942912.2017.1295988>
- Chen, J., Huang, R., Chen, Z., Mao, W., & Li, W. (2023). Transfer learning algorithms for bearing remaining useful life prediction: A comprehensive review from an industrial application perspective. *Mechanical Systems and Signal Processing*, 193, 110239. <https://doi.org/10.1016/j.ymssp.2023.110239>
- Chowdhury, Y. S., Dasgupta, R., & Nanda, S. (2021). Analysis of Various Optimizer on CNN model in the Application of Pneumonia Detection. *2021 3rd International Conference on Signal Processing and Communication (ICSPC)*, 417–421. <https://doi.org/10.1109/ICSPC51351.2021.9451768>
- Clark, S., Michael, M., & Schmidt, K. A. (2019). Rheological properties of yogurt: effects of ingredients, processing and handling. *Rheology of Semisolid Foods*, 203–229.
- Costa, M. P., Frasao, B. S., Silva, A. C. O., Freitas, M. Q., Franco, R. M., & Conte-Junior, C. A. (2015). Cupuassu (*Theobroma grandiflorum*) pulp, probiotic, and prebiotic: Influence on color, apparent viscosity, and texture of goat milk yogurts. *Journal of Dairy Science*, 98(9), 5995–6003.
<https://doi.org/10.3168/jds.2015-9738>



- Costa, R. A., Morais, C. L. M., Rosa, T. R., Filgueiras, P. R., Mendonça, M. S., Pereira, I. E. S., Vittorazzi, B. V., Lyra, M. B., Lima, K. M. G., & Romão, W. (2020). Quantification of milk adulterants (starch, H₂O₂, and NaClO) using colorimetric assays coupled to smartphone image analysis. *Microchemical Journal*, *156*, 104968. <https://doi.org/10.1016/j.microc.2020.104968>
- Courtin, P., Monnet, V., & Rul, F. (2002). Cell-wall proteinases PrtS and PrtB have a different role in *Streptococcus thermophilus*/*Lactobacillus bulgaricus* mixed cultures in milk. *Microbiology*, *148*(11), 3413–3421.
- Cruz Amaro, L. (2022). *Procedimiento para el funcionamiento de una marmita a vapor de volteo y su aplicacion en el area de alimentos*.
- Cuibus, L. (2013). *Applications of infrared thermography in the food industry*.
- Cuibus, L., Castro-Giráldez, M., Fito, P. J., & Fabbri, A. (2014). Application of infrared thermography and dielectric spectroscopy for controlling freezing process of raw potato. *Innovative Food Science & Emerging Technologies*, *24*, 80–87. <https://doi.org/10.1016/j.ifset.2013.11.007>
- da Cruz, A. G., Walter, E. H. M., Cadena, R. S., Faria, J. A. F., Bolini, H. M. A., & Frattini Fileti, A. M. (2009). Monitoring the authenticity of low-fat yogurts by an artificial neural network. *Journal of Dairy Science*, *92*(10), 4797–4804. <https://doi.org/10.3168/jds.2009-2227>
- Dash, K. K., Fayaz, U., Dar, A. H., Shams, R., Manzoor, S., Sundarsingh, A., Deka, P., & Khan, S. A. (2022). A comprehensive review on heat treatments and related impact on the quality and microbial safety of milk and milk-based products. *Food Chemistry Advances*, *1*, 100041. <https://doi.org/10.1016/j.focha.2022.100041>
- Daszkiewicz, T., Michalak, M., & Śmiecińska, K. (2024). A comparison of the quality of plain yogurt and its analog made from coconut flesh extract. *Journal of Dairy Science*, *107*(6), 3389–3399. <https://doi.org/10.3168/jds.2023-24060>
- Deeth, H. (2017). Optimum thermal processing for extended shelf-life (ESL) milk. *Foods*, *6*(11), 102.



- Dimitreli, G., Petridis, D., Akakiadou, P., & Chrysalidou, S. (2014). Effect of protein supplementation, fat globule size and storage time on the rheological and sensory properties of buffalo milk stirred yogurt. *Journal of Food Research*, 3(5), 31.
- Du, H., Wang, X., Yang, H., Zhu, F., Cheng, J., Peng, X., Lin, Y., & Liu, X. (2023). Effects of mulberry pomace polysaccharide addition before fermentation on quality characteristics of yogurt. *Food Control*, 153, 109900. <https://doi.org/10.1016/j.foodcont.2023.109900>
- Du, H., Yang, H., Wang, X., Zhu, F., Tang, D., Cheng, J., & Liu, X. (2021). Effects of mulberry pomace on physicochemical and textural properties of stirred-type flavored yogurt. *Journal of Dairy Science*, 104(12), 12403–12414. <https://doi.org/10.3168/jds.2020-20037>
- Emteborg, H., Zeleny, R., Charoud-Got, J., Martos, G., Lüddeke, J., Schellin, H., & Teipel, K. (2014). Infrared Thermography for Monitoring of Freeze-Drying Processes: Instrumental Developments and Preliminary Results. *Journal of Pharmaceutical Sciences*, 103(7), 2088–2097. <https://doi.org/10.1002/jps.24017>
- Everard, C., O'Donnell, C., Fagan, C., Sheehan, E., Delahunty, C., & O'Callaghan, D. (2005). Correlation Between Process Cheese Meltability Determined by Sensory Analysis, Computer Vision Method and Olson and Price Test. *International Journal of Food Properties*, 8(2), 267–275. <https://doi.org/10.1081/JFP-200060241>
- Fernandes, A. F. A., Dórea, J. R. R., & Rosa, G. J. de M. (2020). Image Analysis and Computer Vision Applications in Animal Sciences: An Overview. *Frontiers in Veterinary Science*, 7. <https://doi.org/10.3389/fvets.2020.551269>
- Freire, P., Freire, D., & Licon, C. C. (2024). A comprehensive review of machine learning and its application to dairy products. *Critical Reviews in Food Science and Nutrition*, 1–16. <https://doi.org/10.1080/10408398.2024.2312537>



- Funes, E., Allouche, Y., Beltrán, G., & Jiménez, A. (2015). A Review: Artificial Neural Networks as Tool for Control Food Industry Process. *Journal of Sensor Technology*, 05(01), 28–43. <https://doi.org/10.4236/jst.2015.51004>
- Gilbert, A., & Turgeon, S. L. (2021). Studying stirred yogurt microstructure and its correlation to physical properties: A review. *Food Hydrocolloids*, 121, 106970. <https://doi.org/10.1016/j.foodhyd.2021.106970>
- Gonçalves, I. C., Fernandes, G. M., & Rocha, F. R. P. (2024). Exploiting digital images and videos for urea determination in milk based on enzymatic hydrolysis monitoring. *Journal of Food Composition and Analysis*, 125, 105745. <https://doi.org/10.1016/j.jfca.2023.105745>
- Gonzalez, R. C., & Woods, R. E. (Richard E. (2008). *Digital image processing* (p. 954). Prentice Hall. chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://sde.uoc.ac.in/sites/default/files/sde_videos/Digital%20Image%20Processing%203rd%20ed.%20-%20R.%20Gonzalez,%20R.%20Woods-ilovepdf-compressed.pdf
- Guerra, A. S., Hoyos, C. G., Velásquez-Cock, J., Vélez, L., Gañán, P., & Zuluaga, R. (2022). The Effects of Adding a Gel-Alike Curcuma longa L. Suspension as Color Agent on Some Quality and Sensory Properties of Yogurt. *Molecules*, 27(3), 946. <https://doi.org/10.3390/molecules27030946>
- Haque, A., Richardson, R. K., & Morris, E. R. (2001). Effect of fermentation temperature on the rheology of set and stirred yogurt. *Food Hydrocolloids*, 15(4–6), 593–602.
- He, Y., Deng, B., Wang, H., Cheng, L., Zhou, K., Cai, S., & Ciampa, F. (2021). Infrared machine vision and infrared thermography with deep learning: A review. In *Infrared Physics and Technology* (Vol. 116). Elsevier B.V. <https://doi.org/10.1016/j.infrared.2021.103754>
- Huang, Y., Kangas, L. J., & Rasco, B. A. (2007). Applications of Artificial Neural Networks (ANNs) in Food Science. *Critical Reviews in Food Science and Nutrition*, 47(2), 113–126. <https://doi.org/10.1080/10408390600626453>



- Jakubowska, M., & Karamucki, T. (2020). The effect of storage time and temperature on the quality of natural yoghurt. *Acta Scientiarum Polonorum Zootechnica*, 18(4), 29–38. <https://doi.org/10.21005/asp.2019.18.4.04>
- JAMES, R., & Charlotte, N. C. (2019). *TRACING THE CAUSES OF HEAT MAINTENANCE ISSUES*.
- Janke, J., Castelli, M., & Popovič, A. (2019). Analysis of the proficiency of fully connected neural networks in the process of classifying digital images. Benchmark of different classification algorithms on high-level image features from convolutional layers. *Expert Systems with Applications*, 135, 12–38. <https://doi.org/10.1016/j.eswa.2019.05.058>
- Javaid, M., Haleem, A., Singh, R. P., Rab, S., & Suman, R. (2022). Exploring impact and features of machine vision for progressive industry 4.0 culture. *Sensors International*, 3, 100132. <https://doi.org/10.1016/j.sintl.2021.100132>
- Javanmardi, S., Miraei Ashtiani, S.-H., Verbeek, F. J., & Martynenko, A. (2021). Computer-vision classification of corn seed varieties using deep convolutional neural network. *Journal of Stored Products Research*, 92, 101800. <https://doi.org/10.1016/j.jspr.2021.101800>
- Jiménez, B. D., Morales, M. E. S., & Ruiz, J. F. V. (2004). Efecto de la adición de fibra y la disminución de grasa en las propiedades fisicoquímicas del yogur. *Revista Mexicana de Ingeniería Química*, 3(3), 287–305.
- Jørgensen, C. E., Abrahamsen, R. K., Rukke, E.-O., Hoffmann, T. K., Johansen, A.-G., & Skeie, S. B. (2019). Processing of high-protein yoghurt—A review. *International Dairy Journal*, 88, 42–59.
- Jørgensen, C. E., Abrahamsen, R. K., Rukke, E.-O., Johansen, A.-G., Schüller, R. B., & Skeie, S. B. (2015). Improving the structure and rheology of high protein, low fat yoghurt with undenatured whey proteins. *International Dairy Journal*, 47, 6–18. <https://doi.org/10.1016/j.idairyj.2015.02.002>
- Kayacan Çakmakoğlu, S., Dere, S., Bekiroğlu, H., Bozkurt, F., Karasu, S., Dertli, E., Türker, M., & Sagdic, O. (2024). Production of bioactive peptides during



- yogurt fermentation, their extraction and functional characterization. *Food Bioscience*, *61*, 104805. <https://doi.org/10.1016/j.fbio.2024.104805>
- Kim, G., Kim, G.-H., Park, J., Kim, D.-Y., & Cho, B.-K. (2014). Application of infrared lock-in thermography for the quantitative evaluation of bruises on pears. *Infrared Physics & Technology*, *63*, 133–139. <https://doi.org/10.1016/j.infrared.2013.12.015>
- Konstantinidis, F. K., Balaska, V., Symeonidis, S., Tsilis, D., Mouroutsos, S. G., Bampis, L., Psomoulis, A., & Gasteratos, A. (2023). Automating dairy production lines with the yoghurt cups recognition and detection process in the Industry 4.0 era. *Procedia Computer Science*, *217*, 918–927. <https://doi.org/10.1016/j.procs.2022.12.289>
- Konstantinidis, F. K., Myrillas, N., Mouroutsos, S. G., Koulouriotis, D., & Gasteratos, A. (2022). Assessment of Industry 4.0 for Modern Manufacturing Ecosystem: A Systematic Survey of Surveys. *Machines*, *10*(9), 746. <https://doi.org/10.3390/machines10090746>
- Kříž, P., Horčíčková, M., Bumbálek, R., Bartoš, P., Smutný, L., Stehlík, R., Zoubek, T., Černý, P., Vochozka, V., & Kuneš, R. (2021). Application of the Machine Vision Technology and Infrared Thermography to the Detection of Hoof Diseases in Dairy Cows: A Review. *Applied Sciences*, *11*(22), 11045. <https://doi.org/10.3390/app112211045>
- Lee, W.-J., & Lucey, J. A. (2006). Impact of Gelation Conditions and Structural Breakdown on the Physical and Sensory Properties of Stirred Yogurts. *Journal of Dairy Science*, *89*(7), 2374–2385. [https://doi.org/10.3168/jds.S0022-0302\(06\)72310-4](https://doi.org/10.3168/jds.S0022-0302(06)72310-4)
- Lima, M. J. A., Sasaki, M. K., Marinho, O. R., Freitas, T. A., Faria, R. C., Reis, B. F., & Rocha, F. R. P. (2020). Spot test for fast determination of hydrogen peroxide as a milk adulterant by smartphone-based digital image colorimetry. *Microchemical Journal*, *157*, 105042. <https://doi.org/10.1016/j.microc.2020.105042>



- Lindsay, D., Robertson, R., Fraser, R., Engstrom, S., & Jordan, K. (2021). Heat induced inactivation of microorganisms in milk and dairy products. *International Dairy Journal*, *121*, 105096.
- Liu, S., Contreras, F., Alemán, R. S., Notas, J. M., Arango, O., & Castillo, M. (2024). Validation of an Optical Technology for the Determination of pH in Milk during Yogurt Manufacture. *Foods*, *13*(17), 2766.
<https://doi.org/10.3390/foods13172766>
- Lobato-Calleros, C., Ramírez-Santiago, C., Vernon-Carter, E. J., & Alvarez-Ramirez, J. (2014). Impact of native and chemically modified starches addition as fat replacers in the viscoelasticity of reduced-fat stirred yogurt. *Journal of Food Engineering*, *131*, 110–115. <https://doi.org/10.1016/j.jfoodeng.2014.01.019>
- Loddo, A., Di Ruberto, C., Armano, G., & Manconi, A. (2022). Automatic Monitoring Cheese Ripeness Using Computer Vision and Artificial Intelligence. *IEEE Access*, *10*, 122612–122626.
<https://doi.org/10.1109/ACCESS.2022.3223710>
- Loesdau, M., Chabrier, S., & Gabillon, A. (2014a). *Hue and Saturation in the RGB Color Space* (pp. 203–212). https://doi.org/10.1007/978-3-319-07998-1_23
- Loesdau, M., Chabrier, S., & Gabillon, A. (2014b). *Hue and Saturation in the RGB Color Space* (pp. 203–212). https://doi.org/10.1007/978-3-319-07998-1_23
- Lopes, R. P., Mota, M. J., Sousa, S., Gomes, A. M., Delgadillo, I., & Saraiva, J. A. (2019). Combined effect of pressure and temperature for yogurt production. *Food Research International*, *122*, 222–229.
<https://doi.org/10.1016/j.foodres.2019.04.010>
- Ma, P., Zhang, Z., Jia, X., Peng, X., Zhang, Z., Tarwa, K., Wei, C.-I., Liu, F., & Wang, Q. (2024). Neural network in food analytics. *Critical Reviews in Food Science and Nutrition*, *64*(13), 4059–4077.
- Mahaut, M., Jeantet, R., Brule, G., & Schuck, P. (2003). *Productos lácteos industriales*. Acribia, Editorial, SA.



- Marete, P. K., Mariga, A. M., Huka, G., Musalia, L., Marete, E., Mathara, J. M., & Arimi, J. M. (2024). Effects of optimizing fermentation time and stabilizers using response surface methodology on physicochemical properties of camel milk yoghurt. *Applied Food Research*, 4(2), 100469. <https://doi.org/10.1016/j.afres.2024.100469>
- Maroubo, L. A., Pedrina, G., & Melchert, W. R. (2021). Total sulfonamides determination in bovine milk using smartphone-based digital images. *Microchemical Journal*, 170, 106657. <https://doi.org/10.1016/j.microc.2021.106657>
- Masawat, P., Harfield, A., & Namwong, A. (2015). An iPhone-based digital image colorimeter for detecting tetracycline in milk. *Food Chemistry*, 184, 23–29. <https://doi.org/10.1016/j.foodchem.2015.03.089>
- Mazzeo, M. (2007). Tecnología de lácteos. *Editorial Universidad de Los Caldos*.
- Mendoza, R., Guerrero, S., & Herrera-Chávez, B. (2021). Reología del yogur: efectos de las operaciones unitarias en el procesamiento y uso de aditivos. *Revista Digital Novasinergia*, 4(1), 151–163.
- Menichetti, G., Ravandi, B., Mozaffarian, D., & Barabási, A.-L. (2023). Machine learning prediction of the degree of food processing. *Nature Communications*, 14(1), 2312. <https://doi.org/10.1038/s41467-023-37457-1>
- Milovanovic, B., Tomovic, V., Djekic, I., Miocinovic, J., Solowiej, B. G., Lorenzo, J. M., Barba, F. J., & Tomasevic, I. (2021a). Colour assessment of milk and milk products using computer vision system and colorimeter. *International Dairy Journal*, 120, 105084. <https://doi.org/10.1016/j.idairyj.2021.105084>
- Milovanovic, B., Tomovic, V., Djekic, I., Miocinovic, J., Solowiej, B. G., Lorenzo, J. M., Barba, F. J., & Tomasevic, I. (2021b). Colour assessment of milk and milk products using computer vision system and colorimeter. *International Dairy Journal*, 120, 105084. <https://doi.org/10.1016/j.idairyj.2021.105084>
- Minz, P. S., & Saini, C. S. (2021a). Comparison of computer vision system and colour spectrophotometer for colour measurement of mozzarella cheese.



- Applied Food Research*, 1(2), 100020.
<https://doi.org/10.1016/j.afres.2021.100020>
- Minz, P. S., & Saini, C. S. (2021b). RGB camera-based image technique for color measurement of flavored milk. *Measurement: Food*, 4, 100012.
<https://doi.org/10.1016/j.meafoo.2021.100012>
- Miranda Mejía, G. A. (2022). *Impact of pulsed electric fields on fermentation process during yogurt production*.
- Muncan, J., Tei, K., & Tsenkova, R. (2020). Real-Time Monitoring of Yogurt Fermentation Process by Aquaphotomics Near-Infrared Spectroscopy. *Sensors*, 21(1), 177. <https://doi.org/10.3390/s21010177>
- Najgebauer-Lejko, D., Witek, M., Żmudziński, D., & Ptaszek, A. (2020). Changes in the viscosity, textural properties, and water status in yogurt gel upon supplementation with green and Pu-erh teas. *Journal of Dairy Science*, 103(12), 11039–11049. <https://doi.org/10.3168/jds.2020-19032>
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons. b*, 4(51–62), 56.
- Navarro, E. F., Faure, G., Cortijo, E., De Nys, E., Bogue, J., Gomez, C., Mercado, W., Gamboa, C., & Le Gal, P.-Y. (2015). The impacts of differentiated markets on the relationship between dairy processors and smallholder farmers in the Peruvian Andes. *Agricultural Systems*, 132, 145–156.
- Nixon, M., & Aguado, A. (2019). *Feature extraction and image processing for computer vision*. Academic press.
- Novac, O.-C., Chirodea, M. C., Novac, C. M., Bizon, N., Oproescu, M., Stan, O. P., & Gordan, C. E. (2022). Analysis of the Application Efficiency of TensorFlow and PyTorch in Convolutional Neural Network. *Sensors*, 22(22), 8872.
<https://doi.org/10.3390/s22228872>
- Nugroho, A. D. W., Kleerebezem, M., & Bachmann, H. (2021). Growth, dormancy and lysis: the complex relation of starter culture physiology and cheese



- flavour formation. *Current Opinion in Food Science*, 39, 22–30.
<https://doi.org/10.1016/j.cofs.2020.12.005>
- Oliveira, R. P. de S., Torres, B. R., Perego, P., Oliveira, M. N. de, & Converti, A. (2012). Co-metabolic models of *Streptococcus thermophilus* in co-culture with *Lactobacillus bulgaricus* or *Lactobacillus acidophilus*. *Biochemical Engineering Journal*, 62, 62–69. <https://doi.org/10.1016/j.bej.2012.01.004>
- Osintsev, A.-. (2014). Theoretical and Practical Aspects of the Thermographic Method for Milk Coagulation Research. *Foods and Raw Materials*, 2(2), 147–155. <https://doi.org/10.12737/5473>
- Ouyang, K., Xie, H., Wu, K., Xiong, H., & Zhao, Q. (2024). Improving fermented milk products using pH-responsive whey protein fibrils: A case study on stirred yogurt. *Food Bioscience*, 60, 104507.
<https://doi.org/10.1016/j.fbio.2024.104507>
- Pallavi, J., & Sukumar, M. (2020). Categorizing Functional Yoghurt using Artificial Neural Network. *Asian Journal of Biological and Life Sciences*, 9(2), 129–138. <https://doi.org/10.5530/ajbls.2020.9.20>
- Pan-utai, W., Atkonghan, J., Onsamark, T., & Imthalay, W. (2020). Effect of *Arthrospira* Microalga Fortification on Physicochemical Properties of Yogurt. *Current Research in Nutrition and Food Science Journal*, 531–540.
<https://doi.org/10.12944/CRNFSJ.8.2.19>
- Pérez, C. (2014). Técnicas Estadísticas Predictivas con IBM SPSS Modelos. *Garceta: Madrid, Spain*, 1–474.
- Pérez-Calabuig, A. M., Pradana-López, S., Lopez-Ortega, S., Otero, L., Cancilla, J. C., & Torrecilla, J. S. (2023). Residual neural networks to quantify traces of melamine in yogurts through image deconvolution. *Journal of Food Composition and Analysis*, 118, 105197.
<https://doi.org/10.1016/j.jfca.2023.105197>
- Pradana, L. S., Pérez Calabuig, A. M., Cancilla, J. C., Otero, L., & Torrecilla, J. S. (2022). Single-digit ppm quantification of melamine in powdered milk driven



- by computer vision. *Food Control*, 131, 108424.
<https://doi.org/10.1016/j.foodcont.2021.108424>
- Prasad, K. (2015). Non-destructive Quality Analysis of Fruits. In *Postharvest Quality Assurance of Fruits* (pp. 239–258). Springer International Publishing.
https://doi.org/10.1007/978-3-319-21197-8_14
- Reiser, P., Eberhard, A., & Friederich, P. (2021). Graph neural networks in TensorFlow-Keras with RaggedTensor representation (kgcnn). *Software Impacts*, 9, 100095. <https://doi.org/10.1016/j.simpa.2021.100095>
- Rivero Martin, J. M., Jaramillo Romero, J., & Montero Garcia, J. (2020). *Variacion de la acidez y el pH de la leche al fabricar yogur*. www.meridies.info
- Rodriguez, R., Vargas, S., Estevez, M., Quintanilla, F., Trejo-Lopez, A., & Hernández-Martínez, A. R. (2013). Use of Raman spectroscopy to determine the kinetics of chemical transformation in yogurt production. *Vibrational Spectroscopy*, 68, 133–140. <https://doi.org/10.1016/j.vibspec.2013.06.004>
- Rodríguez, R., Vargas, S., Quintanilla, F., Trejo, A., Regalado, C., García, B., & González-Torres, M. (2015). Transformation Kinetics During Fermented Milk Production Using *Lactobacillus Johnsonii* (La1) and *Streptococcus Thermophilus*: A Comparison With Yogurt Inoculum. *Food Biophysics*, 10(3), 375–384. <https://doi.org/10.1007/s11483-015-9406-3>
- Rodríguez-Bernal, J. M., Serna-Jiménez, J. A., Uribe-Bohórquez, M. A., Klotz, B., & Quintanilla-Carvajal, M. X. (2014). Aplicación de la metodología de superficie de respuesta para evaluar el efecto de la concentración de azúcar y de cultivos iniciadores comerciales sobre la cinética de fermentación del yogurt. *Revista Mexicana de Ingeniería Química*, 13(1), 213–225.
- Ruales, B. V. (2012). *APLICACIÓN DE ANÁLISIS DE COMPONENTES PRINCIPALES EN LA EVALUACIÓN DE LA PRODUCCIÓN DE AROMA DURANTE LA FERMENTACIÓN DE YOGURT A DOS TEMPERATURAS DE INCUBACIÓN*.
- Sah, B. N. P., Vasiljevic, T., McKechnie, S., & Donkor, O. N. (2016a). Physicochemical, textural and rheological properties of probiotic yogurt



- fortified with fibre-rich pineapple peel powder during refrigerated storage. *LWT*, 65, 978–986. <https://doi.org/10.1016/j.lwt.2015.09.027>
- Sah, B. N. P., Vasiljevic, T., McKechnie, S., & Donkor, O. N. (2016b). Physicochemical, textural and rheological properties of probiotic yogurt fortified with fibre-rich pineapple peel powder during refrigerated storage. *LWT*, 65, 978–986. <https://doi.org/10.1016/j.lwt.2015.09.027>
- Salas, J., de Barros Vidal, F., & Martinez-Trinidad, F. (2019). Deep Learning: Current State. *IEEE Latin America Transactions*, 17(12), 1925–1945. <https://doi.org/10.1109/TLA.2019.9011537>
- Saravanan, R., & Sujatha, P. (2018). A state of art techniques on machine learning algorithms: a perspective of supervised learning approaches in data classification. *2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, 945–949.
- Schütterle, D. M., Hegner, R., Temovska, M., Ortiz-Ardila, A. E., & Angenent, L. T. (2024). Exclusive D-lactate-isomer production during a reactor-microbiome conversion of lactose-rich waste by controlling pH and temperature. *Water Research*, 250, 121045. <https://doi.org/10.1016/j.watres.2023.121045>
- Schwartz, Marco. (2014). *Arduino home automation projects : automate your home using the powerful Arduino platform*. Packt Pub.
- Ścibisz, I., Ziarno, M., & Mitek, M. (2019a). Color stability of fruit yogurt during storage. *Journal of Food Science and Technology*, 56(4), 1997–2009. <https://doi.org/10.1007/s13197-019-03668-y>
- Ścibisz, I., Ziarno, M., & Mitek, M. (2019b). Color stability of fruit yogurt during storage. *Journal of Food Science and Technology*, 56(4), 1997–2009. <https://doi.org/10.1007/s13197-019-03668-y>
- Sepúlveda Giraldo, A. (2007). *Procesamiento de imágenes por medio de filtros acusto-ópticos*.
- Seyrek, E. C., & Uysal, M. (2023). A comparative analysis of various activation functions and optimizers in a convolutional neural network for hyperspectral



- image classification. *Multimedia Tools and Applications*, 83(18), 53785–53816. <https://doi.org/10.1007/s11042-023-17546-5>
- Sfakianakis, P., Topakas, E., & Tzia, C. (2015). Comparative Study on High-Intensity Ultrasound and Pressure Milk Homogenization: Effect on the Kinetics of Yogurt Fermentation Process. *Food and Bioprocess Technology*, 8(3), 548–557. <https://doi.org/10.1007/s11947-014-1412-9>
- Sfakianakis, P., & Tzia, C. (2014a). Conventional and Innovative Processing of Milk for Yogurt Manufacture; Development of Texture and Flavor: A Review. *Foods*, 3(1), 176–193. <https://doi.org/10.3390/foods3010176>
- Sfakianakis, P., & Tzia, C. (2014b). Conventional and Innovative Processing of Milk for Yogurt Manufacture; Development of Texture and Flavor: A Review. *Foods*, 3(1), 176–193. <https://doi.org/10.3390/foods3010176>
- Sharma, S., Sharma, S., & Athaiya, A. (2020). ACTIVATION FUNCTIONS IN NEURAL NETWORKS. In *International Journal of Engineering Applied Sciences and Technology* (Vol. 4). <http://www.ijeast.com>
- Shori, A. B., & Baba, A. S. (2014). Comparative antioxidant activity, proteolysis and in vitro α -amylase and α -glucosidase inhibition of *Allium sativum*-yogurts made from cow and camel milk. *Journal of Saudi Chemical Society*, 18(5), 456–463.
- Silva, A. F. S., Gonçalves, I. C., & Rocha, F. R. P. (2021). Smartphone-based digital images as a novel approach to determine formaldehyde as a milk adulterant. *Food Control*, 125, 107956. <https://doi.org/10.1016/j.foodcont.2021.107956>
- Silva, A. F. S., & Rocha, F. R. P. (2022). Innovative prediction of milk microbiological quality from pH measurements by digital imaging photometry. *Journal of Food Composition and Analysis*, 114, 104715. <https://doi.org/10.1016/j.jfca.2022.104715>
- Sodini, I., Remeuf, F., Haddad, S., & Corrieu, G. (2004). The relative effect of milk base, starter, and process on yogurt texture: a review. *Critical Reviews in Food Science and Nutrition*, 44(2), 113–137.



- Sofu, A., & Ekinçi, F. Y. (2007). Estimation of Storage Time of Yogurt with Artificial Neural Network Modeling. *Journal of Dairy Science*, 90(7), 3118–3125. <https://doi.org/10.3168/jds.2006-591>
- Sofyan, A., Ikhsani, A. Y., Purwani, E., Hasanah, L. E. N., & Febriyadin, F. (2022a). The effect of suweg (*Amorphophallus paeoniifolius*) flour and incubation temperature on characteristics of yogurt with the addition of *Bifidobacterium bifidum* as probiotic. *Materials Today: Proceedings*, 63, S507–S512. <https://doi.org/10.1016/j.matpr.2022.04.538>
- Sofyan, A., Ikhsani, A. Y., Purwani, E., Hasanah, L. E. N., & Febriyadin, F. (2022b). The effect of suweg (*Amorphophallus paeoniifolius*) flour and incubation temperature on characteristics of yogurt with the addition of *Bifidobacterium bifidum* as probiotic. *Materials Today: Proceedings*, 63, S507–S512. <https://doi.org/10.1016/j.matpr.2022.04.538>
- Sözeri Atik, D., Öztürk, H. İ., Akın, N., & Özer, B. (2023). Textural and rheological characterisation of yoghurts produced with cultures isolated from traditional back-slopped yoghurts. *International Dairy Journal*, 138, 105557. <https://doi.org/10.1016/j.idairyj.2022.105557>
- Sun, H., Wang, L., Zhang, H., Wu, A., Zhu, J., Zhang, W., & Hu, J. (2019). Evaluation of Yogurt Quality during Storage by Fluorescence Spectroscopy. *Applied Sciences*, 9(1), 131. <https://doi.org/10.3390/app9010131>
- Tala Orrillo, N. A. (2023). *Evaluación de la influencia del encapsulamiento de cepas homofermentativas en la obtención del ácido láctico a partir de lactosuero.*
- Tan, P. Y., Tan, T. B., Chang, H. W., Tey, B. T., Chan, E. S., Lai, O. M., Baharin, B. S., Nehdi, I. A., & Tan, C. P. (2018). Effects of storage and yogurt matrix on the stability of tocotrienols encapsulated in chitosan-alginate microcapsules. *Food Chemistry*, 241, 79–85. <https://doi.org/10.1016/j.foodchem.2017.08.075>
- Tangorra, F. M., Redaelli, V., Luzi, F., & Zaninelli, M. (2019). The Use of Infrared Thermography for the Monitoring of Udder Teat Stress Caused by Milking Machines. *Animals*, 9(6), 384. <https://doi.org/10.3390/ani9060384>



- Taqi, A. M., Awad, A., Al-Azzo, F., & Milanova, M. (2018). The Impact of Multi-Optimizers and Data Augmentation on TensorFlow Convolutional Neural Network Performance. *2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*, 140–145.
<https://doi.org/10.1109/MIPR.2018.00032>
- Torres, I. C., Amigo, J. M., Knudsen, J. C., Tolkach, A., Mikkelsen, B. Ø., & Ipsen, R. (2018). Rheology and microstructure of low-fat yoghurt produced with whey protein microparticles as fat replacer. *International Dairy Journal*, *81*, 62–71.
- Tribby, D., & Teter, V. (2023). Yogurt. In *The Sensory Evaluation of Dairy Products* (pp. 199–234). Springer International Publishing. https://doi.org/10.1007/978-3-031-30019-6_8
- Urapen, R., & Masawat, P. (2015). Novel method for the determination of tetracycline antibiotics in bovine milk based on digital-image-based colorimetry. *International Dairy Journal*, *44*, 1–5.
<https://doi.org/10.1016/j.idairyj.2014.12.002>
- Vadivambal, R., & Jayas, D. S. (2011). Applications of Thermal Imaging in Agriculture and Food Industry-A Review. In *Food and Bioprocess Technology* (Vol. 4, Issue 2, pp. 186–199). <https://doi.org/10.1007/s11947-010-0333-5>
- Valentina, A., & Fierro, R. (2020). *Efecto de la adición de fibras para la producción y enriquecimiento de yogur*.
- Vasilev, I., Slater, D., Spacagna, G., Roelants, P., & Zocca, V. (2019). *Python Deep Learning: Exploring deep learning techniques and neural network architectures with Pytorch, Keras, and TensorFlow*. Packt Publishing Ltd.
- Vedamuthu, E. R. (2013). Starter cultures for yogurt and fermented milks. *Manufacturing Yogurt and Fermented Milks*, 115–148.
- Velho, L., Frery, A. C., & Gomes, J. (2009). *Image processing for computer graphics and vision*. Springer Science & Business Media.



- Verdú, S., Barat, J. M., & Grau, R. (2019). Non destructive monitoring of the yoghurt fermentation phase by an image analysis of laser-diffraction patterns: Characterization of cow's, goat's and sheep's milk. *Food Chemistry*, 274, 46–54. <https://doi.org/10.1016/j.foodchem.2018.08.091>
- Vieira, P., Pinto, C. A., James Goodfellow, B., Gomes, A. M., Sousa, S., Machado, M., Delgadillo, I., & Saraiva, J. A. (2023). A chemical study of yoghurt produced under isostatic pressure during storage. *Food Chemistry*, 425, 136434. <https://doi.org/10.1016/j.foodchem.2023.136434>
- Walsh, K. B., Blasco, J., Zude-Sasse, M., & Sun, X. (2020). Visible-NIR 'point' spectroscopy in postharvest fruit and vegetable assessment: The science behind three decades of commercial use. *Postharvest Biology and Technology*, 168, 111246. <https://doi.org/10.1016/j.postharvbio.2020.111246>
- Walstra, P., Wouters, J. T. M., & Geurts, T. J. (2005). Fermented milks. *Dairy Science and Technology*, 808.
- Wang, H.-H., & Sun, D.-W. (2001). Evaluation of the functional properties of Cheddar Cheese using a computer vision method. *Journal of Food Engineering*, 49(1), 49–53. [https://doi.org/10.1016/S0260-8774\(00\)00183-7](https://doi.org/10.1016/S0260-8774(00)00183-7)
- Wang, X., Liu, J., Ma, Y., Huo, J., Dai, C., & Fang, L. (2023). Development of Viscosity Real-Time Measurement System Based on Capillary Method. *IEEE Sensors Journal*, 23(20), 25451–25459. <https://doi.org/10.1109/JSEN.2023.3311008>
- Wherry, B., Barbano, D. M., & Drake, M. A. (2019). Use of acid whey protein concentrate as an ingredient in nonfat cup set-style yogurt. *Journal of Dairy Science*, 102(10), 8768–8784. <https://doi.org/10.3168/jds.2019-16247>
- Wijesekara, A., Weerasingha, V., Jayarathna, S., & Priyashantha, H. (2022). Quality parameters of natural phenolics and its impact on physicochemical, microbiological, and sensory quality attributes of probiotic stirred yogurt during the storage. *Food Chemistry: X*, 14, 100332. <https://doi.org/10.1016/j.fochx.2022.100332>



- Wilson, A. N., Gupta, K. A., Koduru, B. H., Kumar, A., Jha, A., & Cenkeramaddi, L. R. (2023). Recent Advances in Thermal Imaging and its Applications Using Machine Learning: A Review. *IEEE Sensors Journal*, 23(4), 3395–3407. <https://doi.org/10.1109/JSEN.2023.3234335>
- Yang, S., Yan, D., Zou, Y., Mu, D., Li, X., Shi, H., Luo, X., Yang, M., Yue, X., Wu, R., & Wu, J. (2021a). Fermentation temperature affects yogurt quality: A metabolomics study. *Food Bioscience*, 42, 101104. <https://doi.org/10.1016/j.fbio.2021.101104>
- Yang, S., Yan, D., Zou, Y., Mu, D., Li, X., Shi, H., Luo, X., Yang, M., Yue, X., Wu, R., & Wu, J. (2021b). Fermentation temperature affects yogurt quality: A metabolomics study. *Food Bioscience*, 42, 101104. <https://doi.org/10.1016/j.fbio.2021.101104>
- Yankey, S., Mensah, E. O., Ankar-Brewoo, G. M., & Ellis, W. O. (2023). Optimized fermentation conditions for dragon fruit yogurt. *Food and Humanity*, 1, 343–348. <https://doi.org/10.1016/j.foohum.2023.06.012>
- Zang, J., Pan, X., Zhang, Y., Tu, Y., Xu, H., Tang, D., Zhang, Q., Chen, J., & Yin, Z. (2023). Mechanistic insights into gel formation of egg-based yogurt: The dynamic changes in physicochemical properties, microstructure, and intermolecular interactions during fermentation. *Food Research International*, 172, 113097. <https://doi.org/10.1016/j.foodres.2023.113097>
- Zaninelli, M., Redaelli, V., Luzi, F., Bronzo, V., Mitchell, M., Dell’Orto, V., Bontempo, V., Cattaneo, D., & Savoini, G. (2018). First Evaluation of Infrared Thermography as a Tool for the Monitoring of Udder Health Status in Farms of Dairy Cows. *Sensors*, 18(3), 862. <https://doi.org/10.3390/s18030862>
- Zhang, L., Zhou, S., Zhang, A., Zhang, H., Wang, R., Wang, X., Hu, Y., Ma, H., & Zhou, C. (2024a). Green efficient preparation and on-line monitoring: Hybrid effect of okra pectin and controlled-temperature ultrasound on physicochemical properties of low-fat yogurt. *Journal of Food Engineering*, 370, 111963. <https://doi.org/10.1016/j.jfoodeng.2024.111963>



- Zhang, L., Zhou, S., Zhang, A., Zhang, H., Wang, R., Wang, X., Hu, Y., Ma, H., & Zhou, C. (2024b). Green efficient preparation and on-line monitoring: Hybrid effect of okra pectin and controlled-temperature ultrasound on physicochemical properties of low-fat yogurt. *Journal of Food Engineering*, *370*, 111963. <https://doi.org/10.1016/j.jfoodeng.2024.111963>
- Zhang, X., Zheng, Y., Zhou, C., Cao, J., Zhang, Y., Wu, Z., Pan, D., Cai, Z., & Xia, Q. (2024). Combining thermosonication microstress and pineapple peel extract addition to achieve quality and post-acidification control in yogurt fermentation. *Ultrasonics Sonochemistry*, *105*, 106857. <https://doi.org/10.1016/j.ultsonch.2024.106857>
- Zhao, L. L., Wang, X. L., Tian, Q., & Mao, X. Y. (2016a). Effect of casein to whey protein ratios on the protein interactions and coagulation properties of low-fat yogurt. *Journal of Dairy Science*, *99*(10), 7768–7775. <https://doi.org/10.3168/jds.2015-10794>
- Zhao, L. L., Wang, X. L., Tian, Q., & Mao, X. Y. (2016b). Effect of casein to whey protein ratios on the protein interactions and coagulation properties of low-fat yogurt. *Journal of Dairy Science*, *99*(10), 7768–7775. <https://doi.org/10.3168/jds.2015-10794>
- Zhao, Y., Khalesi, H., He, J., & Fang, Y. (2023). Application of different hydrocolloids as fat replacer in low-fat dairy products: Ice cream, yogurt and cheese. *Food Hydrocolloids*, *138*, 108493. <https://doi.org/10.1016/j.foodhyd.2023.108493>
- Zhu, L., Spachos, P., Pensini, E., & Plataniotis, K. N. (2021). Deep learning and machine vision for food processing: A survey. *Current Research in Food Science*, *4*, 233–249. <https://doi.org/10.1016/j.crfs.2021.03.009>
- Zolfagharnassab, S., Shariff, A. R. B. M., Ehsani, R., Jaafar, H. Z., & Aris, I. Bin. (2022). Classification of Oil Palm Fresh Fruit Bunches Based on Their Maturity Using Thermal Imaging Technique. *Agriculture*, *12*(11), 1779. <https://doi.org/10.3390/agriculture12111779>



ANEXOS


ANEXO 1. Promedio de las estimaciones de las variables de respuesta de los tratamientos

% Proteína	% Inóculo	Temp. (°C)	% Ac. Lac.	Viscosidad (mPa/s)	pH	L*	a*	b*
4.2	1	36	0.63	1433.79	4.57	85.72	-2.42	3.08
4.2	1	40	0.60	1348.10	4.62	85.39	-3.02	3.3
4.2	1	44	0.61	1285.18	4.6	86.72	-2.72	3.94
4.2	2	36	0.78	1426.62	4.59	86.09	-2.76	3
4.2	2	40	0.65	1394.92	4.66	85.01	-3.11	3.41
4.2	2	44	0.60	1359.92	4.6	85.52	-2.91	4.24
4.2	3	36	0.72	1450.37	4.65	85.23	-2.92	3
4.2	3	40	0.54	1427.21	4.63	85.39	-3.02	3.17
4.2	3	44	0.56	1365.11	4.57	86.2	-2.89	3.96
4.5	1	36	0.70	1533.95	4.58	84.65	-2.63	3.9
4.5	1	40	0.65	1363.84	4.49	86.15	-2.48	4.37
4.5	1	44	0.66	1347.83	4.46	85.77	-2.6	4.17
4.5	2	36	0.60	1564.23	4.57	85.29	-2.99	3.33
4.5	2	40	0.60	1492.28	4.59	85.93	-2.84	3.57
4.5	2	44	0.69	1436.76	4.52	86.24	-2.57	3.61
4.5	3	36	0.53	1598.87	4.63	84.67	-2.55	4.2
4.5	3	40	0.54	1506.93	4.6	84.63	-2.6	3.4
4.5	3	44	0.65	1474.55	4.52	85.97	-2.41	4.28
4.8	1	36	0.73	1636.56	4.64	84.7	-2.47	4.93
4.8	1	40	0.68	1576.53	4.63	85.5	-1.96	5.45
4.8	1	44	0.62	1515.23	4.57	84.82	-2.17	4.42
4.8	2	36	0.62	1691.33	4.63	84.36	-2.68	4.23
4.8	2	40	0.74	1581.40	4.57	85.09	-2.56	4.02
4.8	2	44	0.65	1523.53	4.55	85.57	-2.24	4.63
4.8	3	36	0.71	1862.91	4.6	85	-2.44	4.79
4.8	3	40	0.70	1624.37	4.45	84.58	-2.52	4.02
4.8	3	44	0.66	1582.34	4.55	85.3	-2.02	4.57

ANEXO 2. Implementación de los tubos para la circulación del fluido térmico




ANEXO 3. Implementación de los sensores y controladores del Arduino para el control automático de la temperatura en los reactores de fermentación




ANEXO 4. Construcción de la cabina de captura de imágenes



ANEXO 5. Implementación de las luminarias en la cabina de captura de imágenes y control inalámbrico de la cámara fotográfica (A) y termográfica (B)



ANEXO 6. Implementación de cámara fotográfica (A) y termográfica (B) para la monitorización del proceso de fermentación




ANEXO 7. Captura de imágenes con la cámara fotográfica y termográfica



ANEXO 8. Muestreo (A), medición de acidez titulable (B), pH (C), color (D) y viscosidad (E) mediante técnicas convencionales



ANEXO 9. Descenso del error de predicción de los modelos en su entrenamiento durante las 500 épocas





ANEXO 10. Declaración jurada de autenticidad de tesis



Universidad Nacional
del Altiplano Puno



Vicerrectorado
de Investigación



Repositorio
Institucional

DECLARACIÓN JURADA DE AUTENTICIDAD DE TESIS

Por el presente documento, Yo Ana Erica Pani Curo,
identificado con DNI 74376710 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado
Ingeniería Agroindustrial

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:
" Monitoreo del proceso de fermentación de la
leche mediante técnicas ópticas contactless: visión
por computador y termografía "

Es un tema original.


Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, me someto a las disposiciones legales vigentes y a las sanciones correspondientes de igual forma me someto a las sanciones establecidas en las Directivas y otras normas internas, así como las que me alcancen del Código Civil y Normas Legales conexas por el incumplimiento del presente compromiso

Puno 05 de Diciembre del 2024


FIRMA (obligatoria)



Huella



DECLARACIÓN JURADA DE AUTENTICIDAD DE TESIS

Por el presente documento, Yo Jhon Tasuri Moyhua,
identificado con DNI 75811322 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado
Ingeniería Agroindustrial

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:
" Monitorización del proceso de fermentación de la
leche mediante técnicas ópticas contactless : visión
por computador y termografía. "

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, me someto a las disposiciones legales vigentes y a las sanciones correspondientes de igual forma me someto a las sanciones establecidas en las Directivas y otras normas internas, así como las que me alcancen del Código Civil y Normas Legales conexas por el incumplimiento del presente compromiso

Puno 05 de Diciembre del 2024


FIRMA (obligatoria)



Huella



ANEXO 11. Autorización para el depósito de tesis en el Repositorio Institucional



Universidad Nacional
del Altiplano Puno



Vicerrectorado
de Investigación



Repositorio
Institucional

AUTORIZACIÓN PARA EL DEPÓSITO DE TESIS O TRABAJO DE INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL

Por el presente documento, Yo Ana Erica Pani Curo
identificado con DNI 74376410 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado

Ingeniería Agroindustrial
informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

" Monitoreo del proceso de fermentación de la
leche mediante técnicas ópticas contactless : visión
por computador y termografía "

para la obtención de Grado, Título Profesional o Segunda Especialidad.

Por medio del presente documento, afirmo y garantizo ser el legítimo, único y exclusivo titular de todos los derechos de propiedad intelectual sobre los documentos arriba mencionados, las obras, los contenidos, los productos y/o las creaciones en general (en adelante, los "Contenidos") que serán incluidos en el repositorio institucional de la Universidad Nacional del Altiplano de Puno.

También, doy seguridad de que los contenidos entregados se encuentran libres de toda contraseña, restricción o medida tecnológica de protección, con la finalidad de permitir que se puedan leer, descargar, reproducir, distribuir, imprimir, buscar y enlazar los textos completos, sin limitación alguna.

Autorizo a la Universidad Nacional del Altiplano de Puno a publicar los Contenidos en el Repositorio Institucional y, en consecuencia, en el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto, sobre la base de lo establecido en la Ley N° 30035, sus normas reglamentarias, modificatorias, sustitutorias y conexas, y de acuerdo con las políticas de acceso abierto que la Universidad aplique en relación con sus Repositorios Institucionales. Autorizo expresamente toda consulta y uso de los Contenidos, por parte de cualquier persona, por el tiempo de duración de los derechos patrimoniales de autor y derechos conexos, a título gratuito y a nivel mundial.

En consecuencia, la Universidad tendrá la posibilidad de divulgar y difundir los Contenidos, de manera total o parcial, sin limitación alguna y sin derecho a pago de contraprestación, remuneración ni regalía alguna a favor mío; en los medios, canales y plataformas que la Universidad y/o el Estado de la República del Perú determinen, a nivel mundial, sin restricción geográfica alguna y de manera indefinida, pudiendo crear y/o extraer los metadatos sobre los Contenidos, e incluir los Contenidos en los índices y buscadores que estimen necesarios para promover su difusión.

Autorizo que los Contenidos sean puestos a disposición del público a través de la siguiente licencia:

Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional. Para ver una copia de esta licencia, visita: <https://creativecommons.org/licenses/by-nc-sa/4.0/>

En señal de conformidad, suscribo el presente documento.

Puno 05 de Diciembre del 2024


FIRMA (obligatoria)



Huella



AUTORIZACIÓN PARA EL DEPÓSITO DE TESIS O TRABAJO DE INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL

Por el presente documento, Yo Jhon Tacuri Mayhua,
identificado con DNI 75811322 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado
Ingeniería Agroindustrial

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

" Monitoreo del proceso de fermentación de la leche mediante técnicas ópticas contactless : visión por computador y termografía "

para la obtención de Grado, Título Profesional o Segunda Especialidad.

Por medio del presente documento, afirmo y garantizo ser el legítimo, único y exclusivo titular de todos los derechos de propiedad intelectual sobre los documentos arriba mencionados, las obras, los contenidos, los productos y/o las creaciones en general (en adelante, los "Contenidos") que serán incluidos en el repositorio institucional de la Universidad Nacional del Altiplano de Puno.

También, doy seguridad de que los contenidos entregados se encuentran libres de toda contraseña, restricción o medida tecnológica de protección, con la finalidad de permitir que se puedan leer, descargar, reproducir, distribuir, imprimir, buscar y enlazar los textos completos, sin limitación alguna.

Autorizo a la Universidad Nacional del Altiplano de Puno a publicar los Contenidos en el Repositorio Institucional y, en consecuencia, en el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto, sobre la base de lo establecido en la Ley N° 30035, sus normas reglamentarias, modificatorias, sustitutorias y conexas, y de acuerdo con las políticas de acceso abierto que la Universidad aplique en relación con sus Repositorios Institucionales. Autorizo expresamente toda consulta y uso de los Contenidos, por parte de cualquier persona, por el tiempo de duración de los derechos patrimoniales de autor y derechos conexos, a título gratuito y a nivel mundial.

En consecuencia, la Universidad tendrá la posibilidad de divulgar y difundir los Contenidos, de manera total o parcial, sin limitación alguna y sin derecho a pago de contraprestación, remuneración ni regalía alguna a favor mío; en los medios, canales y plataformas que la Universidad y/o el Estado de la República del Perú determinen, a nivel mundial, sin restricción geográfica alguna y de manera indefinida, pudiendo crear y/o extraer los metadatos sobre los Contenidos, e incluir los Contenidos en los índices y buscadores que estimen necesarios para promover su difusión.

Autorizo que los Contenidos sean puestos a disposición del público a través de la siguiente licencia:

Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional. Para ver una copia de esta licencia, visita: <https://creativecommons.org/licenses/by-nc-sa/4.0/>

En señal de conformidad, suscribo el presente documento.

Puno 05 de Diciembre del 2024


Firma (obligatoria)



Huella