



DIVISIÓN DE ESTUDIOS POSGRADO E INVESTIGACIÓN

Opción 1.- TESIS

TRABAJO PROFESIONAL

**Control por modos deslizantes sin modelo para la producción de
hidrógeno en CSTR: implementación, sintonización y evaluación de
robustez**

**QUE PARA OBTENER EL GRADO DE:
MAESTRA EN
INGENIERÍA ELECTRÓNICA**

PRESENTA:


ING. BRENDA SÁNCHEZ NEXTLE

DIRECTOR DE TESIS:

DR. JOSÉ PASTOR RODRÍGUEZ JARQUIN

CODIRECTOR DE TESIS:

DRA. OFELIA LANDETA ESCAMILLA





Educación

Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado

Orizaba, Veracruz, **22/octubre/2025**
Dependencia: **División de Estudios de
Posgrado e Investigación**
Asunto: **Autorización de Impresión**
OPCION: I

C. BRENDA SÁNCHEZ NEXTLE

Candidato(a) a Grado de Maestro(a) en:

INGENIERÍA ELECTRÓNICA

P R E S E N T E.-

De acuerdo con el Reglamento de Titulación vigente de los Centros e Institutos Tecnológicos Federales del Tecnológico Nacional de México, de la Secretaría de Educación Pública, y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:


**“CONTROL POR MODOS DESLIZANTES SIN MODELO PARA LA PRODUCCIÓN DE
HIDRÓGENO EN CSTR: IMPLEMENTACIÓN, SINTONIZACIÓN Y EVALUACIÓN DE
ROBUSTEZ”**

Comunico a Usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

A T E N T A M E N T E

Excelencia en Educación Tecnológica®
CIENCIA – TÉCNICA - CULTURA®

**DRA. OFELIA LANDETA ESCAMILLA
JEFA DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN**



OG-13-F06



2025
Año de
**La Mujer
Indígena**

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1105360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx





Orizaba, Veracruz, 20/octubre/2025
Asunto: **Revisión de trabajo escrito**

C. OFELIA LANDETA ESCAMILLA
JEFA DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
PRESENTE.-

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.

BRENDA SÁNCHEZ NEXTLE

La cual lleva el título de:

**“CONTROL POR MODOS DESLIZANTES SIN MODELO PARA LA PRODUCCIÓN DE
HIDRÓGENO EN CSTR: IMPLEMENTACIÓN, SINTONIZACIÓN Y EVALUACIÓN DE
ROBUSTEZ”**

Y concluyen que se acepta.

ATENTAMENTE

Excelencia en Educación Tecnológica®
CIENCIA – TÉCNICA - CULTURA®

PRESIDENTE: DR. JOSÉ PASTOR RODRÍGUEZ JARQUIN

SECRETARIO: DR. ALBINO MARTÍNEZ SIBAJA

VOCAL: DR. IGNACIO HERRERA AGUILAR

VOCAL SUP.: DRA. OFELIA LANDETA ESCAMILLA

FIRMA

FIRMA

FIRMA

FIRMA

TA-09-18



2025
Año de
**La Mujer
Indígena**

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320
Orizaba, Veracruz. Tel. 01 (272) 1106360
e-mail: info@orizaba.tecnm.mx www.orizaba.tecnm.mx



CONTENIDO

RESUMEN	12
ABSTRACT	14
INTRODUCCIÓN	16
PLANTEAMIENTO DEL PROBLEMA	18
JUSTIFICACIÓN	20
HIPÓTESIS	21
OBJETIVOS	22
LIMITACIONES Y ALCANCES	23
CAPÍTULO 1: ANTECEDENTES	25
1.1 Producción de Biohidrógeno.....	25
1.2 Control por Modos Deslizantes (SMC)	26
1.3 Simulación.....	27
CAPÍTULO 2: ESTADO DEL ARTE	30
2.1 Producción de hidrógeno	30
2.1.1 Optimización de Parámetros del Proceso	30
2.1.2 Pretratamiento de Sustratos	31
2.1.3 Mejoras Genéticas y Microbiología.....	31
2.1.4 Configuración de Reactores	32
2.2 Control por modos deslizantes para la producción de H ₂	33
2.2.1 SMC Clásico	33
2.2.2 SMC Adaptativo	34

2.2.3	Evolución del SMC.....	34
2.2.4	Control por Modos Deslizantes sin Modelo (MF-SMC)	35
2.2.5	Aplicación en biohidrógeno.....	35
2.3	Simulación sobre producción de H ₂	36
CAPÍTULO 3: MARCO TEÓRICO		39
3.1	Producción Biológica de Hidrógeno.....	39
3.1.1	Fermentación oscura	39
3.1.1.1	Ventajas.....	39
3.1.2	Factores Clave que Influyen en el Rendimiento	40
3.1.3	Reactor de Tanque Agitado (CSTR)	41
3.1.3.1	Principio de Funcionamiento	41
3.1.3.2	Ventajas en el Contexto de la Fermentación Oscura.....	42
3.1.3.3	Desafíos Operacionales.....	43
3.1.4	Modelos pseudo-estequiométricos	43
3.1.4.1	Importancia y Ventajas para el Control de Procesos.....	44
3.1.4.2	Supuestos y limitaciones	45
3.1.4.3	Cinética del Proceso.....	45
3.2	Control por Modos Deslizantes Sin Modelo (MF-SMC).....	46
3.2.1	Principio de Funcionamiento	46
3.2.2	La Transición al Enfoque Sin Modelo (MF-SMC).....	47
3.2.3	Construcción de un Controlador MF-SMC	48

3.3	Optimización y evaluación de estrategias de control	49
3.3.1	Optimización por Algoritmos Genéticos (AG).....	49
3.3.1.1	Funcionamiento.....	50
3.3.1.2	Componentes clave	50
3.3.2	Simulación y Métricas de evaluación.....	51
3.3.2.1	Métricas de desempeño.....	51
3.3.2.2	Elección de ventanas temporales para evaluación de métricas.....	53
3.3.3	Análisis estadísticos.....	54
3.3.3.1	Datos heterogpeneos en simulaciones	54
3.3.3.2	Herramientas principales para determinar grados de similitud.....	54
3.3.3.3	Estadísticas descriptivas.....	56
3.3.3.4	Supuestos estadísticos	57
3.3.3.5	Pruebas paramétricas.....	58
3.3.3.6	Pruebas no paramétricas.....	59
3.3.3.7	Análisis post-hoc	59
CAPÍTULO 4: METODOLOGÍA		61
4.1	Modelo matemático de la producción de hidrógeno.....	61
4.1.1	Proceso de migración	61
4.2	Análisis de sensibilidad	62
4.2.1	Caracterización de la superficie de respuesta.....	62
4.2.2	Implementación del algoritmo de optimización	62
4.3	Caracterización del comportamiento del sistema.....	63

4.4	Linealización por tramos del modelo.....	64
4.4.1	Implementación	64
4.4.2	Formulación matemática:.....	64
4.4.3	Determinación de caudales equivalentes:.....	65
4.4.4	Validación del modelo linealizado por tramos	65
4.4.4.1	Evaluación cuantitativa de la precisión.....	65
4.4.4.2	Métricas de evaluación	66
4.4.4.3	Procedimiento de validación	66
4.5	Diseño de controladores por modos deslizantes sin modelo	67
4.5.1	Componentes fundamentales del controlador	67
4.5.1.1	Superficie deslizante	67
4.5.1.2	Leyes de Control y Funciones de Conmutación	68
4.5.1.3	Estrategia de Conmutación entre Zonas.....	69
4.5.1.4	Ley de Adaptación para Ganancias Variables	70
4.6	Sintonización de Parámetros mediante Algoritmo Genético	71
4.6.1	Configuración del Algoritmo:	72
4.7	Contrucción de escenarios individuales y combinados	72
4.7.1	Modelo de referencia	73
4.7.2	Escenarios individuales.....	73
4.7.3	Escenarios combinados.....	75
4.7.4	Denificación de las perturbaciones.....	76

4.8	Configuración de las Simulaciones	77
4.8.1	Plataforma de simulación	77
4.8.2	Condiciones de simulación estandarizadas.....	78
4.8.3	Protocolo de Simulación diferenciado.....	79
4.8.4	Gestión de Parámetros	79
4.8.5	Métricas de Evaluación del Desempeño	79
4.8.5.1	Definiciones matemáticas.....	80
4.8.6	Tasa de éxito del controlador	80
4.8.7	Ventanas de evaluación adaptadas	81
4.8.8	Gestión y almacenamiento de datos.....	83
4.9	Evaluación de robustez para casos determinísticos	83
4.9.1	Identificación de patrones de similitud	84
4.9.1.1	Identificación visual	84
4.9.1.2	Clasificación mediante reglas estadísticas	84
4.9.2	Evaluación de Representante vs C4.....	85
4.9.3	Casos especiales.....	86
4.9.3.1	Casos diferenciados	86
4.9.3.2	Casos agrupados.....	87
4.10	Evaluación de robustez para casos estocásticos.....	88
4.10.1	Configuración Experimental	88
4.10.2	Análisis de confiabilidad por Coeficiente de Variación	88

4.10.3	Verificación de supuestos estadísticos	89
4.10.3.1	Estrategia de Análisis Estadístico	89
4.10.3.2	Análisis de Rankings y Desempeño Global	89
CAPÍTULO 5: RESULTADOS		90
5.1	Validación de la migración del modelo	90
5.1.1	Explicación de las diferencias	90
5.1.2	Validación cuantitativa.....	92
5.2	Análisis de sensibilidad	92
5.2.1	Diagrama de calor	93
5.2.2	Optimización de variables	94
5.3	Caracterización del comportamiento del sistema.....	95
5.3.1	Curva característica del sistema.....	95
5.4	Linealización por tramos.....	95
5.4.1	Caudales equivalentes para control.....	96
5.4.2	Validación visual	97
5.4.3	Validación cuantitativa.....	97
5.5	Sintonización de parámetros mediante AG	98
5.5.1	Parámetros Óptimos de los Controladores	98
5.5.2	Evaluación del desempeño de optimización.....	99
5.6	Evaluación de robustez para casos determinísticos	101
5.6.1	Análisis de la tasa de éxito	101
5.6.1.1	ESS	101

5.6.1.2	Amplitud máxima del error.....	102
5.6.1.3	<i>Chattering</i>	102
5.6.2	Identificación de patrones de comportamiento.....	103
5.6.2.1	Clasificación visual.....	103
5.6.2.2	Clasificación automática.....	104
5.6.2.3	Clasificación mediante dendrogramas.....	106
5.6.2.4	Clasificación final.....	108
5.6.3	Representante vs C4.....	108
5.6.3.1	Verificación de supuestos estadísticos.....	109
5.6.3.2	Pruebas estadísticas (Cinéticos y Alimentación).....	111
5.6.3.3	Análisis de las categorías Ambiental y Fugas.....	112
5.6.4	Casos diferenciados.....	113
5.6.5	Casos agrupados.....	114
5.7	Evaluación de robustes para casos estocásticos.....	116
5.7.1	Caracterización de confiabilidad por controlador.....	116
5.7.2	Verificación de supuestos estadísticos.....	116
5.7.2.1	Normalidad (Shapiro-Wilk).....	116
5.7.2.2	Homocedasticidad (Levene).....	117
5.7.3	Resultados de pruebas estadísticas.....	118
5.7.3.1	Desempeño por caso y métrica.....	119
5.7.3.2	Síntesis del análisis estadístico y rankings globales.....	121
CONCLUSIONES.....		123

REFERENCIAS BIBLIOGRÁFICAS.....	127
ANEXO A: Clasificación de patrones de comportamiento.....	145
ANEXO B: Análisis descriptivo para categorías especiales.....	147
ANEXO C: Análisis de normalidad para casos con ruido	148

LISTA DE FIGURAS

Figura 1.	Producción de hidrógeno con el modelo original (MATLAB)	91
Figura 2.	Producción de hidrógeno con el modelo migrado a Python.....	91
Figura 3.	Producción de hidrógeno en función del caudal y concentración de glucosa	93
Figura 4.	Curva característica y puntos de transición de la producción de H_2	95
Figura 5.	Zonas de operación linealizadas. Glucosa fija a 20 g/L	97
Figura 6.	Comparación de la producción de hidrógeno bajo diferentes escenarios.....	103
Figura 7.	Dendrogramas representativos de patrones de agrupamiento.....	107

LISTA DE TABLAS

Tabla 1.	Ventanas de evaluación empleadas para cada tipo de perturbación.....	82
Tabla 2.	Comparación cuantitativa de los modelos (MATLAB y Python)	92
Tabla 3.	Métricas de desempeño por zona.	97
Tabla 4.	Resultados de desempeño de los controladores tras la optimización.....	100
Tabla 5.	Tasa de éxito global por controlador.....	101
Tabla 6.	Tasa de éxito por categoría de perturbación	101
Tabla 7.	Estadísticas descriptivas para la Amplitud en casos de éxito.....	102
Tabla 8.	Estadísticas descriptivas para el Chattering en casos de éxito	103
Tabla 9.	Resumen de la clasificación visual	104
Tabla 10.	Estadísticos de distancia Manhattan para casos representativos	105
Tabla 11.	Resumen de la clasificación mediante reglas de clasificación.....	106
Tabla 12.	Porcentajes de clasificación mediante dendrogramas.....	108
Tabla 13.	Distribución de selección como controlador representante	109
Tabla 14.	Análisis de normalidad (Shapiro-Wilk) para la categoría de Cinéticos	110
Tabla 15.	Análisis de normalidad (Shapiro-Wilk) para la categoría de Alimentación	110
Tabla 16.	Análisis de homocedasticidad para la categoría de Cinéticos	111
Tabla 17.	Análisis de homocedasticidad para la categoría de Alimentación.....	111
Tabla 19.	Pruebas estadísticas para la categoría de Alimentación.....	112
Tabla 18.	Análisis Mann-Whitney para la categoría de Cinéticos	112
Tabla 20.	Variabilidad relativa (CV) y rangos observados por caso y métrica	114
Tabla 21.	Ranking de controladores por caso y métrica (mejor $\rightarrow$ peor)	114
Tabla 22.	Rango observado de distancias Manhattan por caso y métrica.....	115
Tabla 23.	Porcentaje de confiabilidad por controlador	116
Tabla 24.	Resultados del análisis de normalidad (Shapiro-Wilk).....	117
Tabla 25.	Homocedasticidad por caso y métrica (Levene)	118
Tabla 26.	Prueba aplicada y p-valor por caso y métrica.....	119
Tabla 27.	Ranking global promedio por métrica (menor es mejor)	122
Tabla 28.	Comparación de clasificaciones por tipo de metodología	145
Tabla 29.	Comparación de clasificaciones por tipo de metodología (continuación).....	146
Tabla 30.	Análisis descriptivo para la categoría de Ambiental	147
Tabla 31.	Análisis descriptivo para la categoría de Fugas	147

Tabla 32.	Análisis de normalidad Shapiro-Wilk para C1	148
Tabla 33.	Análisis de normalidad Shapiro-Wilk para C2	149
Tabla 34.	Análisis de normalidad Shapiro-Wilk para C3	149
Tabla 35.	Análisis de normalidad Shapiro-Wilk para C4	150

RESUMEN

Esta tesis aborda la estabilización de la producción de hidrógeno en un biorreactor CSTR de fermentación oscura mediante estrategias de control por modos deslizantes sin modelo, implementadas íntegramente en Python y validadas frente a un modelo de referencia migrado desde MATLAB/Simulink, con equivalencia en estado estacionario y discrepancias iniciales atribuibles a tolerancias numéricas y a la representación de las entradas como transiciones suaves ($<0.1\%$ de diferencia relativa en puntos de comparación).

Primero se caracterizó la superficie de respuesta del proceso variando sistemáticamente la concentración de glucosa (10-20 g/L) y el caudal de alimentación (2-8 L/d), y se refinó con una optimización L-BFGS-B que identificó un punto operativo de referencia (glucosa 20.00 g/L, caudal 4.06 L/d) asociado a una producción de 0.9289 mol/L.

Para habilitar un control simple y robusto, se construyó una aproximación lineal por tramos de la relación caudal-hidrógeno con tres zonas separadas alrededor de 2.8 y 3.7 L/d, que reproduce la curva característica con alta fidelidad (R^2 global ≈ 0.999).

Sobre esa base se implementaron cuatro variantes de control por modos deslizantes sin modelo (funciones de conmutación tipo tangente hiperbólica o saturación, con ganancias fijas o adaptativas), con conmutación automática entre zonas y límites físicos en el actuador, y cuyos parámetros se sintonizaron mediante un algoritmo genético que equilibra seguimiento, esfuerzo y suavidad de la señal de control.

La robustez se evaluó en escenarios determinísticos y estocásticos que combinan perturbaciones de alimentación, parámetros cinéticos, condiciones ambientales, fugas y ruido gaussiano del 2 % en el sensor de H_2 , utilizando 30 réplicas por combinación bajo ruido.

Las métricas de evaluación privilegiaron indicadores comprensibles para operación: error en estado estacionario, amplitud máxima del error e índice de chattering, calculados en ventanas temporales acordes a cada tipo de perturbación.

El análisis de patrones, apoyado en reglas de similitud y dendrogramas, mostró con frecuencia respuestas muy próximas entre tres controladores y la diferenciación de un cuarto, lo que

orientó comparaciones más finas. Bajo ruido se observaron contrastes claros: la variante con saturación y ganancia adaptativa tendió a contener mejor la amplitud y mostró mayor consistencia, mientras que otras destacaron en precisión según el caso; una variante elevó sistemáticamente el chattering, desaconsejándola cuando se requiere conmutación contenida.

En conjunto, los resultados indican que estas estrategias mantienen la producción cercana al objetivo con señales de control contenidas frente a perturbaciones representativas del proceso, y sugieren como siguiente paso reoptimizar incorporando explícitamente el error en estado estacionario y la amplitud máxima en la función de evaluación bajo un esquema multi-escenario.

ABSTRACT

This thesis addresses the stabilization of hydrogen production in a CSTR dark fermentation bioreactor using model-free sliding mode control strategies, fully implemented in Python and validated against a reference model migrated from MATLAB/Simulink with steady-state equivalence and initial discrepancies attributable to numerical tolerances and the representation of inputs as smooth transitions ($<0.1\%$ relative difference at comparison points).

First, the process response surface was characterized by systematically varying glucose concentration (10-20 g/L) and feed flow rate (2-8 L/d) and was refined with an L-BFGS-B optimization that identified a reference operating point (glucose 20.00 g/L, flow rate 4.06 L/d) associated with a production of 0.9289 mol/L.

To enable a simple and robust control, a piecewise linear approximation of the flow rate-hydrogen relationship was constructed with three zones separated around 2.8 and 3.7 L/d, which reproduces the characteristic curve with high fidelity (global $R^2 \approx 0.999$).

On this basis, four variants of model-free sliding mode control were implemented (using hyperbolic tangent or saturation switching functions, with fixed or adaptive gains), featuring automatic switching between zones and physical limits on the actuator. Their parameters were tuned using a genetic algorithm that balances tracking performance, control effort, and signal smoothness.

Robustness was evaluated under deterministic and stochastic scenarios combining feed perturbations, kinetic parameter variations, environmental conditions, leaks, and 2% Gaussian noise in the H_2 sensor, using 30 replicates per combination under noisy conditions.

The evaluation metrics favored indicators that are understandable for operation: steady-state error, maximum error amplitude, and a chattering index, calculated in time windows appropriate for each type of perturbation.

Pattern analysis, supported by similarity rules and dendrograms, frequently showed very close responses among three controllers and the differentiation of a fourth, which guided more detailed comparisons. Under noisy conditions, clear contrasts were observed: the variant with

saturation and adaptive gain tended to better contain amplitude and showed greater consistency, while others excelled in precision depending on the case. One variant systematically elevated chattering, making it inadvisable when contained switching is required.

Overall, the results indicate that these strategies maintain production close to the target with contained control signals in the face of representative process disturbances. They also suggest, as a next step, re-optimizing by explicitly incorporating steady-state error and maximum amplitude into the evaluation function under a multi-scenario scheme.

INTRODUCCIÓN

En el contexto de la transición energética global, el mundo se enfrenta a un reto común: encontrar nuevas formas de energía que sean limpias, sostenibles y versátiles (Q. Hassan et al., 2024, Dash et al., 2023). En este panorama, el hidrógeno verde (producido a partir de fuentes renovables) aparece como una alternativa prometedora. No solo puede servir como un medio eficiente de almacenamiento de energía, sino también como un combustible limpio, especialmente en aquellos sectores donde la electrificación directa resulta complicada (Jaradat et al., 2024).

Dentro de las diferentes formas de producir hidrógeno, la fermentación oscura se ha consolidado como una de las más interesantes, ya que al ser capaz de obtener biohidrógeno a partir de una variedad de residuos orgánicos, muchos de ellos procedentes de la agroindustria (Mohanakrishna et al., 2023), no sólo se genera energía revolvable, sino que también se da un nuevo valor a desechos, que de otra manera serían un problema ambiental (Abawalo et al., 2025, Talapko et al., 2023). El corazón de este proceso son los biorreactores: sistemas vivos y dinámicos donde comunidades de microorganismos transforman la materia orgánica en hidrógeno (Nirmala et al., 2023).

Sin embargo, de una escala de laboratorio a una industrial no es sencillo presenta distintos desafíos, como lo son: sistemas de múltiples factores interconectados (cantidad de sustrato, flujo de alimentación, pH, temperatura, etc.). Estos parámetros no solo cambian con el tiempo, sino que lo hacen de forma incierta, lo que dificulta mantener condiciones estables y eficientes, algo fundamental para que la tecnología sea viable (Mokhtarani et al., 2025).

Durante décadas, el control de procesos se ha apoyado en herramientas clásicas, como los controladores PID (Proporcional-Integral-Derivativo). Aunque funcionan muy bien en sistemas simples y predecibles, suelen quedarse cortos cuando se enfrentan a procesos no lineales y a perturbaciones inesperadas, como ocurre en los bioprocesos (Kuterbekov et al., 2024). Por ello, la investigación ha dado lugar a técnicas más avanzadas. Una de ellas es el Control por Modos Deslizantes (SMC), conocido por su gran robustez ante la incertidumbre y las perturbaciones externas (Alcaraz-Gonzalez et al., 2021, H. Li et al., 2025). Sin embargo, su

aplicación tradicional exige contar con un modelo matemático muy preciso del sistema, algo que en biotecnología es complicado y costoso.

Para afrontar esta problemática, entra el MF-SMC, la cual conserva las ventajas de robustez del SMC, pero evita la necesidad de conocer en detalle las ecuaciones del proceso. En su lugar, se basa en la información que se obtienen *on-line* de las entradas y salidas del sistema (Alcaraz–Gonzalez et al., 2021). Esto lo hace especialmente adecuado para bioprocesos, donde los modelos matemáticos rara vez reflejan toda la complejidad biológica. Además, se han desarrollado técnicas para suavizar la señal de control, como el uso de funciones tipo tangente hiperbólica o saturación, con el fin de evitar vibraciones indeseadas (chattering) y proteger así los equipos.

Otro reto importante es la adecuada sintonización de los parámetros de los controladores, esta tarea implica encontrar un punto de equilibrio entre distintos objetivos (lograr precisión en la respuesta, mantener la suavidad de la señal, reducir el esfuerzo de control) en función de las necesidades específicas del proceso. Para ello, se emplean herramientas de optimización que, en muchos casos, se inspiran en la naturaleza. Un ejemplo son los Algoritmos Genéticos (AG), capaces de explorar un amplio rango de combinaciones hasta identificar la configuración más adecuada (Alnaib et al., 2025).

En este marco, la presente tesis se sitúa en la intersección entre la biotecnología aplicada a la producción de hidrógeno y la teoría de control robusto. Su propósito central es diseñar, probar y evaluar un conjunto de controladores MF-SMC, orientados a mantener estable la producción de hidrógeno en un reactor de tanque agitado continuo (CSTR) simulado.

PLANTEAMIENTO DEL PROBLEMA

La producción de hidrógeno por fermentación oscura en biorreactores tipo CSTR exige mantener una operación estable y eficiente a pesar de las variaciones propias del proceso biológico y del entorno de planta. Este desafío se agrava por el carácter marcadamente no lineal del sistema y por la presencia de regiones operativas con comportamientos contrastantes, incluida una zona donde caudales elevados provocan lavado y caída de la producción, lo que complica la regulación en la práctica. Además, el desempeño depende de dos variables de operación clave (concentración de glucosa de alimentación y caudal) cuya interacción define una superficie de respuesta con zonas sensibles y óptimos locales dentro de rangos típicos de trabajo.

En condiciones reales, la operación se ve afectada por cambios en la calidad del sustrato, variaciones cinéticas de los microorganismos, modificaciones en la transferencia gas-líquido, alteraciones ambientales, fugas y, de forma ineludible, ruido de medición, especialmente en el sensor de hidrógeno gaseoso. Estos factores pueden presentarse de manera aislada o combinada, con patrones de perturbación que incluyen escalones, rampas y oscilaciones, reproduciendo situaciones frecuentes de planta que ponen a prueba la estabilidad del control.

Desde la perspectiva de control, el problema central reside en que la relación entre la variable manipulada (caudal de alimentación) y la variable objetivo (producción de hidrógeno) es indirecta y está mediada por un conjunto de ecuaciones acopladas, lo que dificulta el uso directo de estrategias clásicas. Para hacer viable el diseño se recurrió a una aproximación por tramos que captura el comportamiento global en regiones operativas bien definidas, habilitando una formulación simple y funcional para el control. Con base en ello, se optó por controladores por modos deslizantes sin modelo (MF-SMC), una familia conocida por su robustez ante incertidumbres y perturbaciones, y cuya implementación con funciones de conmutación suavizadas ($\tanh$ y saturación) busca reducir el chattering y preservar la integridad del proceso biológico.

El reto, por tanto, es doble: diseñar y sintonizar una estrategia de control capaz de sostener la producción cerca del valor de referencia a lo largo de todo el dominio operacional y, al mismo

tiempo, contener la variabilidad de la señal y el esfuerzo del actuador dentro de límites físicos y seguros. Para evaluar este equilibrio de manera justa frente a perturbaciones no estacionarias (rampas, senoidales y ruido), se adoptaron métricas adaptadas al contexto, como el error en estado estacionario y la amplitud máxima del error, además del chattering, calculadas en ventanas temporales acordes con la dinámica de cada tipo de señal. La evidencia obtenida en escenarios con ruido confirma que las diferencias entre controladores son estadísticamente significativas, lo que justifica una comparación sistemática y rigurosa de alternativas en condiciones estocásticas y no solo determinísticas.

En síntesis, el problema que aborda este trabajo es cómo garantizar, mediante una estrategia de control robusta y practicable, la operación confiable de un biorreactor de fermentación oscura frente a no linealidades, restricciones físicas y perturbaciones realistas, dentro de rangos de operación definidos y con criterios de desempeño que reflejen de manera fiel las exigencias de planta. La propuesta articula una caracterización operativa, una simplificación por tramos y el diseño de controladores MF-SMC con conmutación por zonas, para luego someterlos a una evaluación comparativa bajo escenarios determinísticos y estocásticos, atendiendo a la precisión, la contención de oscilaciones y la suavidad de la acción de control como ejes de decisión.

JUSTIFICACIÓN

La transición energética exige alternativas que sean a la vez limpias y versátiles, en este contexto, el hidrógeno se perfila como una opción prometedora, siempre que su producción pueda mantenerse de forma estable y eficiente. Entre las rutas de producción biológica más estudiadas, la fermentación oscura destaca por los resultados alentadores obtenidos en laboratorio y por la posibilidad de aprovechar residuos orgánicos y sustratos de bajo costo, no obstante, su traslado a condiciones reales plantea un desafío relevante: se requieren estrategias de operación y control que reduzcan la variabilidad del proceso y aseguren un desempeño confiable a lo largo del tiempo.

Este trabajo plantea una respuesta práctica a ese reto. Integra el conocimiento del proceso con herramientas de control robustas, define con claridad el rango operativo de interés y adopta simplificaciones que hacen posible una implementación realista en equipos experimentales. Para cuidar la integridad del bioproceso y evitar vibraciones indeseadas en la señal de control (chattering), se recurre a funciones de conmutación suavizadas.

Además, se construyó una plataforma de simulación que permite evaluar distintas estrategias de control bajo un mismo marco de referencia, tanto en escenarios “limpios” y controlados como en situaciones más cercanas a la realidad, con perturbaciones y ruido propios de planta. De esta manera, los controladores se comparan con criterios homogéneos y enfocados en lo que realmente importa en la práctica: su precisión, su capacidad de contener las oscilaciones y la suavidad de la acción de control.

Los resultados obtenidos no solo revelan las fortalezas y limitaciones de cada alternativa, sino que también ofrecen pautas concretas para elegir la estrategia más adecuada según las prioridades operativas.

HIPÓTESIS

La aplicación de controladores por modos deslizantes sin modelo, con conmutación suavizada y parámetros sintonizados mediante algoritmo genético, mantendrá la producción de hidrógeno cercana al valor objetivo, con variaciones acotadas y señales de control estables, aun ante cambios en la alimentación, en la cinética del proceso, fugas y ruido en la medición.

OBJETIVOS

Proponer, implementar en simulación y evaluar comparativamente estrategias de control por modos deslizantes sin modelo, sintonizadas mediante algoritmos genéticos, para mantener estable y cercana al objetivo la producción de hidrógeno en un reactor CSTR bajo distintas perturbaciones.

OBJETIVOS ESPECÍFICOS

1. Determinar el punto de operación y los rangos de trabajo de interés (concentración de glucosa y caudal de entrada) mediante optimización numérica, con el fin de maximizar la producción de hidrógeno.
2. Especificar, implementar en simulación y ajustar variantes de control por modos deslizantes sin modelo (con distintas leyes de conmutación y esquemas de ganancia) para regular la producción de hidrógeno.
3. Evaluar la robustez de los controladores ante variaciones de parámetros individuales y escenarios combinados en categorías relevantes (alimentación, parámetros cinéticos, condiciones ambientales, fugas y ruido).

LIMITACIONES Y ALCANCES

Alcances

- Se construyó una plataforma de simulación sólida para el control de un biorreactor de fermentación oscura, con un dominio operativo bien definido en términos de glucosa de entrada y caudal, y con un setpoint de producción de H_2 que orienta las decisiones de control.
- Se propuso un esquema de linealización por tramos, que traduce la producción de H_2 en caudales equivalentes según cada zona y respeta los límites físicos del actuador, lo que hace más viable su aplicación práctica.
- Se compara con un protocolo reproducible, varias leyes de control en escenarios sin ruido y con ruido, ofreciendo guías claras de selección según la prioridad (precisión, amplitud, esfuerzo o chattering).
- Deja un esquema metodológico transferible: caracterizar la operación, diseñar el controlador con límites físicos, sintonizar por optimización y evaluar robustez de forma determinística y estocástica.

Limitaciones

- El modelo se basa en una aproximación pseudo-estequiométrica simplificada que asume un pH constante de 5.5 y no considera la formación de coproductos. Dado que estos factores pueden influir en el comportamiento real del sistema, la extrapolación de los resultados a otras condiciones debe hacerse con precaución.
- La validez del modelo está acotada a rangos y condiciones específicas (operación y medio), de modo que operar fuera de ese dominio exige recalibración y nueva sintonía.
- Es un estudio exclusivamente *in silico*: no incluye validación en planta ni *hardware-in-the-loop*, por lo que pueden aparecer efectos no modelados (retardos, no linealidades de actuadores, restricciones de instrumentación).

- La incertidumbre se modeló solo como ruido gaussiano en el sensor de H_2 ; no se consideraron ruidos multivariantes, sesgos de calibración, pérdidas de señal ni variaciones de monitoreo en línea de pH o temperatura.
- La estrategia de control no tomó en cuenta el impacto de actuadores reales, se implementó únicamente a través de un canal (el caudal de alimentación) y se asumió un comportamiento idealizado.
- La sintonización inicial no tomó en cuentaa de manera explícita el error en estado estacionario (ESS) ni la amplitud máxima, que más adelante se identificaron como métricas más adecuadas al sistema por el tipo de perturbaciones a las que se sometieron los controladores.

CAPÍTULO 1: ANTECEDENTES

1.1 Producción de Biohidrógeno

Aunque la idea de producir hidrógeno por medios biológicos fue formulada por primera vez a principios del siglo XIX, la tecnología no recibió una atención significativa hasta la década de 1930, cuando se demostró de forma práctica su producción a través de la digestión anaeróbica de celulosa por microbios del tracto rumiante (Mishra et al., 2022). Sin embargo, no fue sino hasta las últimas décadas del siglo XX, impulsado por las crisis energéticas y una creciente conciencia ambiental, que la fermentación oscura comenzó a establecerse como un campo de investigación enfocado específicamente en la producción de biohidrógeno (Tapia-Venegas et al., 2015).

Los primeros trabajos en esta área se enfrentaron a desafíos que siguen siendo estudiados en la actualidad: rendimientos de hidrógeno bajos y muy por debajo del máximo teórico de 4 moles de H_2 por mol de glucosa, una marcada inestabilidad del proceso y la competencia por el sustrato con microorganismos metanogénicos (Tapia-Venegas et al., 2015, Castelló et al., 2020, Ramprakash et al., 2022), por lo tanto, las primeras investigaciones se centraron en comprender y optimizar las variables operativas críticas. Se llegaron a establecer las condiciones que favorecían las rutas metabólicas de las bacterias productoras de hidrógeno: un pH ligeramente ácido (5.5-6.0) y temperaturas mesofílicas o termofílicas, y se desarrollaron métodos para pretratar el inóculo con el fin de suprimir la metanogénesis (Sivagurunathan et al., 2016, García-Depraect et al., 2021).

A medida que el campo maduró, especialmente a partir de la década de 2000, se comenzó a pasar del uso de sustratos simples, como la glucosa, hacia el empleo de biomásas complejas y residuos agroindustriales (Soares et al., 2020). Este cambio introdujo nuevos retos, como la recalcitrancia de biomasa, cuya estructura funciona como una 'pared protectora' que dificulta la descomposición por los organismos (Basak et al., 2020). De aquí es que surge una extensa línea de investigación en estrategias de pretratamiento (físicas, químicas y biológicas) para hacer más accesibles los azúcares fermentables (Saha et al., 2022). De manera similar, el uso de sistemas integrados, en donde se acopla la fermentación oscura con otros procesos como la

fotofermentación o celdas de electrólisis microbianas (MEC), surge como una propuesta para mejorar la baja eficiencia de conversión (Ramprakash et al., 2022, Nirmala et al., 2023)

En la actualidad, esta tecnología sigue teniendo una gran relevancia. A pesar de décadas de investigación y avances importantes, su viabilidad a escala industrial sigue resultando problemática. Los principales restos siguen: la inestabilidad del proceso a largo plazo y la baja productividad volumétrica de hidrógeno (García-Depraect et al., 2021). Aunque la optimización de parámetros en estado estacionario ha sido ampliamente estudiada, existe una carencia de investigaciones enfocadas en sistemas de control en tiempo real capaces de estabilizar el proceso frente a las perturbaciones inherentes a un entorno industrial, como las fluctuaciones en la composición del sustrato.

1.2 Control por Modos Deslizantes (SMC)

Esta teoría del control tiene sus raíces en la escuela soviética de control de sistemas de estructura variable, la cuál comenzó a desarrollarse a mediados del siglo XX. Sin embargo, no fue sino hasta las décadas de 1970 y 1980 que se consolidó como una metodología formal, principalmente a través de los trabajos pioneros de Utkin (*Automation and Robotics*, 2008). El principio fundamental del SMC es su capacidad para forzar la trayectoria de un sistema a converger y permanecer sobre una superficie predefinida en el espacio de estados, conocida como "superficie deslizante", una vez se alcanza, el comportamiento del sistema se vuelve insensible a ciertas perturbaciones externas y a variaciones en los parámetros del modelo (*Automation and Robotics*, 2008, Obando et al., 2023).

Gracias a su robustez, el SMC encontró rápidamente aplicaciones en una amplia gama de campos de la ingeniería en donde los modelos de los sistemas eran imprecisos o experimentaban variaciones. Durante las décadas de 1980 y 1990, su uso se extendió a la robótica, el control de motores eléctricos, los sistemas aeroespaciales y los convertidores de potencia (*Automation and Robotics*, 2008, Morales et al., 2022), sin embargo, su principal desventaja es el fenómeno de chattering. Este fenómeno puede provocar un desgaste excesivo de los actuadores, generar o amplificar dinámicas no modeladas y, en última instancia, comprometer la estabilidad del sistema (Ouyang et al., 2022, Morales et al., 2022).

Su aplicación a los bioprocesos fue un paso natural, teniendo sus primeras aplicaciones a principios del siglo XXI, donde se buscó aprovechar la robustez del SMC para regular variables como la concentración de sustrato o biomasa en biorreactores (*Automation and Robotics*, 2008, López-Peréz et al., 2022). Sin embargo, su correcta aplicación depende de un modelo matemático preciso del proceso, lo que es difícil de obtener para sistemas biológicos vivos y en constante cambio (López-Peréz et al., 2022, Obando et al., 2023).

Este motivó la evolución hacia el control por modos deslizantes sin modelo (MF-SMC). Este nuevo enfoque fue desarrollado en los últimos años, y, aunque conserva la robustez del SMC tradicional se elimina la necesidad de un modelo detallado del sistema. En su lugar, el MF-SMC se basa en la estimación de la dinámica del sistema a partir de datos de entrada y salida medidos en tiempo real, lo que lo hace ideal para sistemas complejos (Khodadadi et al., 2015).

En el campo de la producción de biohidrógeno, la aplicación de estrategias de control avanzado es un área de investigación relativamente reciente pero muy importante. Si bien se han explorado enfoques como el control predictivo basado en modelo (MPC) para optimizar la producción de biohidrógeno (López Pérez et al., 2015, Adjisetya y Wahid, 2023), la literatura muestra un vacío en la aplicación y evaluación de estrategias de control robusto que no dependan de un modelo exacto. La alta sensibilidad de la fermentación oscura a perturbaciones en la alimentación, la temperatura o la cinética microbiana, hace que el MF-SMC sea un candidato ideal para garantizar una operación estable y eficiente (Alcaraz-Gonzalez et al., 2021).

1.3 Simulación

La simulación matemática se ha vuelto una herramienta indispensable en el diseño, análisis y optimización de los bioprocesos. Su aplicación no es nueva, pero su sofisticación y accesibilidad han crecido exponencialmente, permitiendo reducir costos y el tiempo asociados a la experimentación en planta piloto (Kasprzak y Marinova, 2025, Chezeau y Vial, 2019). En el contexto de la producción de biohidrógeno, la simulación ha sido fundamental para superar problemas comunes de la experimentación física, como los largos tiempos de respuesta de los sistemas biológicos y la dificultad para aislar el efecto de variables individuales.

Las primeras aproximaciones a la simulación de la fermentación oscura que ganaron notoriedad surgieron a finales de la década de 1990 y principios de los 2000, en donde se basaron en modelos cinéticos no estructurados. Estos modelos describen las relaciones macroscópicas entre el consumo de sustrato, el crecimiento de la biomasa y la formación de productos (hidrógeno y metabolitos) mediante ecuaciones diferenciales ordinarias (Couto et al., 2020). Uno de los más utilizados son las adaptaciones del *Anaerobic Digestion Model No. 1* (ADM1) (modelo de referencia para la digestión anaerobia) (Silva Neto et al., 2019); sin embargo, aunque estos modelos cinéticos pueden predecir el rendimiento global y explorar escenarios operativos, asumen condiciones de mezcla perfecta, ignorando los gradientes espaciales dentro del biorreactor.

Conforme se avanzaba en la comprensión teórica, se desarrollaron enfoques de simulación más complejos que fueran más realista. La Dinámica de Fluidos Computacional (CFD) se ha convertido en una herramienta poderosa para analizar la hidrodinámica, la transferencia de masa y de calor, y la distribución de fases dentro del reactor (Wodołański y Smoliński, 2022). Esta herramienta permite optimizar aspectos como la geometría del tanque o la configuración del agitador (en reactores CSTR), para mejorar la mezcla y facilitar la transferencia de masa (D. Zhang et al., 2015).

Un hecho importante ha sido el auge del software de código abierto. Tradicionalmente, la simulación de procesos químicos dependía de paquetes de software comerciales y costosos como Aspen Plus o HYSYS (Ramamany et al., 2022, Silva Neto et al., 2019). Hoy en día, lenguajes de programación como Python, que posee librerías de uso científico (SciPy, NumPy, Pandas etc.), se han consolidado como una alternativa potente y asequible (Silva Neto et al., 2019). Esto permite no solo implementar modelos cinéticos complejos, sino también automatizar la optimización de parámetros e integrar diferentes tipos de modelos. Proyectos como *Virtual Engineering* del NREL demuestran el potencial de Python para crear plataformas de simulación de procesos químicos completos, conectando modelos de distintas operaciones unitarias («NREL/VirtualEngineering», 2025).

A pesar de estos avances, aún se tienen desafíos importantes, como la creación de un "gemelo digital" para un biorreactor de fermentación oscura, que pueda integrar de manera precisa la

cinética microbiana con la hidrodinámica del reactor y la variabilidad del sustrato (Wicmandy y Tellez-Schmill, 2024). La validación de estos modelos con datos experimentales de largo plazo (especialmente bajo condiciones dinámicas y de perturbación) es otro reto importante.

CAPÍTULO 2: ESTADO DEL ARTE

2.1 Producción de hidrógeno

Las áreas principales de investigación en la actualidad sobre la fermentación oscura para la producción de hidrógeno se detallan a continuación.

2.1.1 Optimización de Parámetros del Proceso

La optimización de los parámetros operativos es, quizás, el área de estudio más crucial, ya que su objetivo es crear un ambiente perfecto para que los microorganismos trabajen a su máximo potencial mediante el control de variables como: pH, temperatura, carga orgánica y el tiempo de retención hidráulica (TRH).

Trabajos recientes se ha enfocado en encontrar las combinaciones óptimas para diferentes sustratos y configuraciones de reactores. Por ejemplo, en un estudio de Martínez-Fraile et al., 2025 sobre la fermentación de la anaraananana fracción orgánica de residuos sólidos municipales, se evaluó un rango de pH de 5.5 a 7.0 y un contenido de sólidos totales (TS) del 5 % al 10 %. Sus resultados identificaron que las condiciones óptimas para la máxima producción de biohidrógeno se alcanzaban con un pH de 7.0 y un 7.5 % de TS, demostrando que incluso pequeñas variaciones pueden tener un gran impacto.

El tiempo de retención hidráulica (TRH) es otro parámetro crítico que define el equilibrio entre la alimentación del sustrato y el tiempo que los microorganismos necesitan para la conversión. Un TRH demasiado corto puede "lavar" la biomasa del reactor, mientras que uno muy largo puede ser ineficiente. En la investigación de Regueira-Marcos et al., 2024 se estudió un proceso de dos etapas con residuos de alimentos donde se demostró que, al reducir gradualmente el TRH en el reactor de hidrógeno de 12 a 6 horas, se consigue maximizar la tasa de producción volumétrica de hidrógeno (HPR) de hasta 9.6 L H₂/L-d, sin embargo, una reducción adicional a 4 horas provocó el colapso del proceso.

2.1.2 Pretratamiento de Sustratos

Una de las ventajas que presenta la fermentación oscura es que pueden utilizarse una gran variedad de residuos orgánicos Nirmala et al., 2023. Sin embargo, muchos presentan estructuras complejas por lo que los microorganismos no los pueden degradar fácilmente. Por ello, el pretratamiento del sustrato es un área de investigación crucial para facilitar el acceso a los azúcares fermentables.

Una revisión realizada por Prabakar et al., 2018 clasifica los métodos de pretratamiento en cinco grandes grupos: sonólisis, microondas, tratamiento ácido/álcali, choque térmico y tratamientos biológicos e integrados. Concluyen que la elección del método más adecuado no es universal; depende intrínsecamente de las propiedades del residuo que se va a tratar. Por lo tanto, un análisis exhaustivo de las características del sustrato, incluyendo la presencia de posibles sustancias inhibidoras, es un paso obligatorio para seleccionar una estrategia de pretratamiento que realmente facilite y potencie la producción de biohidrógeno.

2.1.3 Mejoras Genéticas y Microbiología

El corazón de la fermentación oscura son los microorganismos, por tanto, mejorar su rendimiento implica aumentar la eficiencia del proceso. La ingeniería genética y la ingeniería metabólica son campos con un enorme potencial a futuro, aunque aún enfrentan desafíos para su aplicación a gran escala. Estudios como los de Anwar et al., 2019 y Bolatkhan et al., 2019 señalan que la modificación genética de los microorganismos para mejorar sus rutas metabólicas productoras de H_2 es una de las estrategias más prometedoras para alcanzar una producción rentable.

Paralelamente, es fundamental entender los consorcios microbianos mixtos que habitan en los biorreactores. Investigaciones como la de Dzulkarnain et al., 2022 se centran en el estudio de estos microbiomas para identificar las especies clave y las interacciones que favorecen la producción de hidrógeno. Por ejemplo, en el estudio de Martínez-Fraile et al., 2025, se asoció el alto rendimiento en la producción de H_2 con la presencia dominante de bacterias de los géneros *Clostridium sensu stricto* 7 y *Caproiciproducens*, en conjunto con bacterias ácido-

lácticas. Este tipo de conocimiento es vital para desarrollar estrategias de bioaumentación o para seleccionar inóculos más eficientes.

2.1.4 Configuración de Reactores

La literatura reporta el uso de una amplia variedad de configuraciones, cada una con sus ventajas para diferentes sustratos y condiciones. Se han investigado desde reactores de tanque agitado continuo (CSTR), reactores de lecho empacado de flujo ascendente (UPBR), y filtros anaerobios de flujo ascendente (UAFBR), hasta sistemas más avanzados como los biorreactores de membrana (AnMBR y L/G MBR) que permiten desacoplar el TRH del tiempo de retención de sólidos (SRT), logrando así mayores densidades de biomasa (W. Li et al., 2023, Renaudie et al., 2021).

Por ejemplo, Brindhadevi et al., 2021 emplearon dinámica de fluidos computacional (CFD) para comparar numéricamente el rendimiento de un CSTR horizontal (HCSTR) y uno vertical (VCSTR). Su estudio concluyó que la producción de hidrógeno mejoraba al optimizar la velocidad del agitador a 80 rpm, un factor que resultó ser más crítico que la propia orientación del biorreactor.

Por otro lado, para superar la limitación del lavado de biomasa en los CSTR, se investigan intensamente los reactores de lecho fijo o empacado, que inmovilizan a los microorganismos en un material de soporte. En la investigación de Karapinar et al., 2020 evaluaron el efecto del TRH en un reactor UPBR con perlas de poliéster como soporte y observaron que un TRH de 4 a 6 horas permitían una conversión de glucosa a H_2 del 60 %, pero tiempos menores reducían drásticamente la eficiencia, demostrando la existencia de un umbral operativo crítico. De manera similar, Corbari et al., 2019 estudiaron un reactor tipo UAFBR para tratar aguas residuales de yuca, encontrando que aumentar la carga orgánica y disminuir el TRH mejoraba la producción de hidrógeno, aunque alertaron que una acumulación excesiva de biomasa después de 10 días podía llegar a ser contraproducente.

2.2 Control por modos deslizantes para la producción de H₂

Para poder estabilizar bioprosos complejos, como la fermentación oscura para la producción de hidrógeno, las estrategias de control empleadas tienen que ser capaces de manejar la alta no linealidad de los sistemas, perturbaciones y ruido inherentes a los sistemas biológicos (López-Peréz et al., 2022). En este contexto, el Control por Modos Deslizantes (SMC) y sus variantes han surgido como un grupo de técnicas prometedoras por su robustez (Morales et al., 2022).

2.2.1 SMC Clásico

El SMC clásico base de esta familia de controladores. Su diseño busca forzar las trayectorias del sistema hacia una "superficie de deslizamiento", donde el sistema se vuelve insensible a ciertas perturbaciones (Morales et al., 2022). Esta capacidad para garantizar estabilidad ha sido documentada en la ingeniería de procesos químicos. Por ejemplo, Harivardhagini, 2019 implementó un SMC para la neutralización de pH en reactores CSTR, demostrando una fiabilidad superior a los controladores PID, mientras que Zlateva, 2021 demostró su robustez en simulaciones de tratamiento de aguas residuales bajo eventos climáticos extremos.

Sin embargo, la aplicación directa del SMC clásico a bioprosos se enfrenta a dos desafíos fundamentales. El primero es que depende de un modelo matemático preciso del sistema, y, obtener un modelo fiable para la fermentación oscura es una tarea extremadamente compleja (Rincón et al., 2014). El segundo inconveniente es el fenómeno del *chattering*: oscilaciones de alta frecuencia en la señal de control generadas por la naturaleza discontinua de su ley de control (Morales et al., 2022), el cuál no solo provoca un desgaste acelerado en los actuadores (como bombas y válvulas) sino que puede ser perjudicial para la comunidad microbiana, que es sensible a cambios bruscos en sus condiciones de operación. En su estudio, Derbeli et al., 2020 encontraron que el *chattering* era el principal inconveniente de su SMC de primer orden, causando baja precisión y pérdidas de energía.

2.2.2 SMC Adaptativo

En esta variante de control, los parámetros se ajustan en tiempo real. En un estudio realizado por Souissi, 2021, combinó el SMC tradicional con el algoritmo Super-Twisting para crear un controlador SMC adaptativo (ASMC) para un sistema de celdas de combustible PEM, logrando una reducción del chattering del 85 % en comparación con técnicas convencionales.

De manera similar, en Hui et al., 2020 se investigó el control de nivel de potencia para reactores nucleares de gas a alta temperatura. Se propuso un control adaptativo por modos deslizantes con Super-Twisting (HGO-ASTSMCS-PP), donde se introdujo un mecanismo de adaptación para ajustar las ganancias del controlador en línea, lo que permitió superar la sobreestimación de las perturbaciones desconocidas.

2.2.3 Evolución del SMC

Para superar estos inconvenientes, la investigación en control ha desarrollado variantes más sofisticadas.

Para la Reducción del Chattering se propusieron los Controladores por Modos Deslizantes de Orden Superior (HOSM), cuyo algoritmo más popular es el Super-Twisting (STA). A diferencia del SMC de primer orden, el STA genera una acción de control continua y suave, eliminando las conmutaciones bruscas. Su eficacia fue demostrada por Souissi, 2021, quien, al aplicarlo a un sistema de celdas de combustible, logró una reducción del chattering del 85 %. De forma similar, Derbeli et al., 2020 utilizaron un HOSM cuasi-continuo para el mismo fin. Una alternativa ampliamente utilizada es el reemplazo de la función signo por funciones de conmutación suavizadas, como la tangente hiperbólica ($\tanh$) o la saturación (sat), tal como lo proponen Ghani et al., 2022 y Morales et al., 2022.

Para manejar las incertidumbres del modelo es que surge el SMC adaptativo (ASMC). Aquí, las ganancias del controlador se ajustan en tiempo real para compensar la incertidumbre. Esta capacidad ha sido crucial en aplicaciones complejas como el control de potencia en reactores nucleares, donde Hui et al., 2020 lo emplearon para superar la sobreestimación de perturbaciones. Por lo general, estas técnicas se combinan; el controlador de Souissi, 2021,

por ejemplo, es un ASMC que integra el algoritmo STA para lograr tanto adaptabilidad como suavidad.

2.2.4 Control por Modos Deslizantes sin Modelo (MF-SMC)

Esta estrategia ha ganado considerable atención por su capacidad para manejar sistemas no lineales complejos con incertidumbres y perturbaciones, sin requerir un modelo matemático preciso de la planta (Zhu, 2021).

La potencia de este enfoque ha sido validada en áreas con grandes desafíos, similares a los presentes en bioprocesos. Por ejemplo, en el trabajo de Zhao et al., 2022 implementó un MF-SMC para mejorar la respuesta de velocidad en motores síncronos logrando una robustez superior al eliminar la dependencia de los parámetros del motor que varían con la operación. Dicha situación resulta análoga a un bioproceso, en donde el MF-SMC ya no necesita conocer las cinéticas microbinas, las cuáles fluctúan con el tiempo. De manera similar, en los vehículos autónomos, Oh y Seo, 2022 aplicó un SMC con acciones de retroalimentación adaptativa sin modelo para el seguimiento de trayectoria, lo que se asemeja al reto de mantener un punto de operación estable en un biorreactor a pesar de las variaciones en el sustrato. El trabajo de González-García et al., 2022 validaron experimentalmente un MF-SMC de alto orden para el seguimiento de trayectoria en vehículos submarinos autónomos (AUVs), lo que refuerza su aplicabilidad en entornos altamente no lineales y de alta incertidumbre, mientras que estudios teóricos como el de Zhu, 2021 formalizan el marco del MF-SMC para una clase amplia de sistemas.

2.2.5 Aplicación en biohidrógeno

El SMC es reconocido como una estrategia robusta en el sector del hidrógeno en general. Se ha aplicado para controlar electrolizadores PEM, como se muestra en el trabajo de Koundi et al., 2025, y en sistemas de celdas de combustible, donde Yu et al., 2024 propusieron un controlador híbrido PID-SMC. Sin embargo, su aplicación directa en la producción biológica de hidrógeno es notablemente escasa.

Algunos trabajos han sentado las bases. López Pérez et al., 2015 diseñaron un controlador no

lineal por retroalimentación para incrementar la producción de biohidrógeno en un reactor continuo, demostrando el potencial del control avanzado en este campo. Más recientemente, López-Peréz et al., 2022 diseñaron un SMC robusto para un biorreactor *fed-batch*, obteniendo una ley de control que no requiere conocer completamente las tasas de reacción, un paso conceptual importante hacia un enfoque sin modelo.

A pesar del éxito demostrado del MF-SMC en sistemas no lineales complejos y la reconocida necesidad de control robusto en la producción de biohidrógeno (Yahaya et al., 2023), la literatura revela un vacío en la aplicación específica del MF-SMC para estabilizar la producción de hidrógeno mediante fermentación oscura, la cuál es un área en gran medida inexplorada. Mientras que la mayoría de los estudios se han enfocado en la optimización de parámetros en estado estacionario (Kumar et al., 2022, Wodolazski y Smoliński, 2022), pocos abordan el problema de la regulación dinámica y robusta.

2.3 Simulación sobre producción de H₂

Las simulaciones aplicadas a la producción de biohidrógeno son principalmente numéricas, pero se dividen en distintos niveles de complejidad y enfoque. El método más extendido se basa en modelos cinéticos y estequiométricos, donde el núcleo son sistemas de ecuaciones diferenciales que describen las tasas de las reacciones bioquímicas, lo que permite la optimización de variables operativas críticas. Por ejemplo, en el trabajo de Elerakey et al., 2024, se empleó un modelo cinético de Gompertz modificado para analizar la producción de biohidrógeno a partir de residuos de cáscaras de frutas, lo que permitió cuantificar parámetros clave como el potencial máximo de producción de hidrógeno y la tasa máxima de producción. Por otro lado, en el trabajo de Elerakey et al., 2025, se empleó un modelo estadístico para optimizar el pH inicial, la concentración de sustrato y la adición de nutrientes, maximizando la producción de hidrógeno a partir de cáscaras de sandía.

También se han realizado estudios para analizar los fenómenos físicos que ocurren dentro de los reactores, para esto es que se recurre a los modelos de Dinámica de Fluidos Computacional (CFD). En la investigación de Wodolazski y Smoliński, 2022, se adoptó un modelo CFD multifásico transitorio para simular la fermentación oscura en un reactor de flujo pistón, lo

que les permitió examinar el efecto del TRH y el pH en la eficiencia del proceso. Actualmente se buscan modelos multifísicos que acoplan la CFD con la cinética biológica, mientras que en el estudio de Aghajani Delavar y Wang, 2021 se desarrolló un modelo a escala de poro utilizando el método de Lattice Boltzmann acoplado con autómatas celulares (LBM-CA) para investigar cómo las variaciones espaciotemporales del pH afectan el crecimiento del *biofilm* y la producción de hidrógeno. Esta simulación a microescala reveló que la producción puede reducirse más de un 25 % con cambios de pH aparentemente pequeños y que el crecimiento del *biofilm* puede disminuir hasta un 63.18 %, demostrando la importancia de los efectos locales que los modelos a gran escala podrían pasar por alto.

La simulación no solo se utiliza para optimizar, sino también para identificar y validar los modelos matemáticos más adecuados. Roeva et al., 2025 desarrollaron un modelo para la co-digestión de paja de trigo y biomasa de algas, y utilizaron su simulación para comparar la capacidad predictiva de diferentes algoritmos de optimización (deterministas y metaheurísticos), demostrando que el Algoritmo de Depredadores Marinos (MPA) se ajustaba con mayor precisión a los datos experimentales. Este enfoque de validación es crucial para asegurar la fiabilidad de las predicciones del modelo.

Otra área importante de estudio son los modelos basados en datos e inteligencia artificial (IA), que pueden identificar patrones complejos sin depender de los primeros principios. Un ejemplo práctico es el de Rezk et al., 2023 trabajo que combinó un Sistema de Inferencia Neuro-Difuso Adaptativo (ANFIS) para modelar un biorreactor de membrana con el Algoritmo Honey Badger para la optimización. La simulación identificó los valores óptimos para el caudal de gas de entrada, el pH y la velocidad del agitador, logrando aumentar el rendimiento de producción de hidrógeno en un 7.22 %. Estos modelos son especialmente valiosos para predecir el comportamiento de sistemas con sustratos complejos y variables.

La simulación también puede extenderse a la escala de toda la planta y su viabilidad económica, utilizando herramientas como Aspen Plus para modelar procesos integrados. La investigación de Bechara, 2022 presenta un avanzado modelo de simulación de procesos basado en el *Anaerobic Digestion Model 1* (ADM1) dentro de Aspen Plus. Su trabajo no solo se centró en la simulación cinética, sino también en la optimización de parámetros y el análisis de sensibilidad,

logrando un aumento del 50 % en la producción de metano a través de la optimización del proceso. Otro ejemplo es el estudio de Dolat et al., 2024, en donde integraron un modelo dinámico de un digestor anaerobio con datos de precios de gas para desarrollar una estrategia de programación dinámica de la alimentación. Su simulación demostró que ajustar el patrón de alimentación en respuesta a las fluctuaciones del mercado podría aumentar los ingresos anuales entre un 2 % y un 7.4 %, conectando directamente la simulación del proceso con la toma de decisiones económicas y la rentabilidad.

CAPÍTULO 3: MARCO TEÓRICO

3.1 Producción Biológica de Hidrógeno

3.1.1 Fermentación oscura

La fermentación oscura es un proceso metabólico llevado a cabo por una variedad de microorganismos anaerobios, los cuales pueden ser tanto estrictos (viven y trabajan en ausencia de oxígeno) como facultativos (pueden crecer tanto en presencia como en ausencia de oxígeno), en ausencia total de luz (Q. Zhang et al., 2024, Goveas et al., 2024, Kontodimos et al., 2025). En esencia, estas bacterias convierten materia orgánica rica en carbohidratos, como la glucosa, en biohidrógeno, dióxido de carbono y una mezcla de ácidos grasos volátiles (AGV), como el ácido acético y butírico (Mazzoli et al., 2024, Q. Zhang et al., 2024).

Este proceso es parte de la ruta metabólica más amplia de la digestión anaerobia, correspondiendo específicamente a la etapa de acidogénesis (Kontodimos et al., 2025). El objetivo de la producción de hidrógeno es favorecer dicha etapa e inhibir las etapas posteriores en donde el hidrógeno producido comienza a ser consumido por bacterias metanogénicas las cuales producen metano (Parra et al., 2025). Es por ello que controlar las condiciones operativas del biorreactor es de suma importancia ya que pequeños cambios afectan el rendimiento de hidrógeno (Mohanakrishna et al., 2023).

3.1.1.1 Ventajas

La fermentación oscura presenta distintas características que la vuelven atractiva para su estudio en laboratorio y también a mayor escala, algunas de los beneficios que presenta son:

- Alta tasa de producción: Comparada con otros procesos biológicos dependientes de la luz, la fermentación oscura generalmente alcanza tasas de producción de hidrógeno mucho más elevadas (Mazzoli et al., 2024, Mandalika et al., 2024).
- Independencia de la luz: Al no requerirla, los biorreactores pueden operar de forma continua durante todo el día sin necesidad de colocar fuentes de luz controladas, simpli-

ficando así el y reduciendo costos operativos (Q. Zhang et al., 2024, Mandalika et al., 2024).

- **Valorización de residuos:** Una de sus principales fortalezas es la capacidad de utilizar una amplia gama de sustratos orgánicos, incluyendo residuos agroindustriales y aguas residuales (Parra et al., 2025, Mohanakrishna et al., 2023). Esto no solo genera energía renovable, sino que también ofrece una solución al manejo de desechos, inscribiéndose en un modelo de economía circular.

A pesar de estas ventajas, la fermentación oscura es un proceso biológico complejo y marcadamente no lineal, sensible a las fluctuaciones en sus condiciones de operación (García-Depraect et al., 2021). Por esta razón es necesario el desarrollo de estrategias de control avanzadas que puedan ser capaces de estabilidad la producción de hidrógeno frente a las perturbaciones del entorno y efectos no modelados de los sistemas empleados, ya que esto es inevitable (Yahaya et al., 2023).

3.1.2 Factores Clave que Influyen en el Rendimiento

Como se mencionó anteriormente, el proceso de producción es complejo por los múltiples factores que influyen y la secuencia de reacciones que suceden, las cuales muchas de ellas se encuentran acopladas por lo que no existen comportamientos lineales (Goveas et al., 2024). Algunos de los parámetros más importantes en este proceso son:

Concentración de sustrato: Si la concentración del 'alimento' es demasiado baja el crecimiento y la producción se ve limitada, por el contrario, si la concentración aumenta demasiado la actividad metabólica de los microorganismos se ve afectada, limitando su el crecimiento y por ende, la producción (Yahaya et al., 2023).

Caudal de alimentación y Tiempo de Retención Hidráulica (TRH): El caudal de entrada al reactor está inversamente relacionado con el TRH, que es el tiempo promedio que el sustrato permanece dentro del reactor (Regueira-Marcos et al., 2023). Esta variable es crítica y su manipulación es el objetivo principal del controlador aquí diseñado.

Un caudal muy bajo (TRH alto) puede llevar a una baja productividad y favorecer el crecimiento de microorganismos no deseados, como los metanógenos (Fonseca, 2022).

Un caudal muy alto (TRH bajo) puede provocar el "lavado" del sistema, donde la biomasa es expulsada del reactor más rápido de lo que puede reproducirse, llevando al colapso de la producción (Regueira-Marcos et al., 2024).

El comportamiento del sistema cambia drásticamente en función del caudal, presentando regiones operativas con dinámicas muy distintas (Regueira-Marcos et al., 2023). Esta naturaleza no lineal hace que el control del caudal sea un desafío complejo y justifica el uso de una estrategia robusta como el control por modos deslizantes.

pH del medio: Aunque no es una variable manipulada por el controlador en esta tesis, el pH es uno de los parámetros más influyentes en la fermentación oscura (Goveas et al., 2024). Para este proceso es recomendable mantener un ambiente ligeramente ácido (entre 5.0 y 6.0) ya que los organismos metanogénicos prefieren ambientes neutros por lo que se ven inhibidas en este rango (Weide et al., 2020). El modelo matemático de producción de hidrógeno tomado como referencia (Aceves-Lara et al., 2008) opera con un pH controlado en 5.5.

3.1.3 Reactor de Tanque Agitado (CSTR)

Existen distintas configuraciones de reactores utilizadas en ingeniería de bioprocesos, donde cada una tiene sus propias fortalezas y debilidades [1], y en el contexto de la producción de biohidrógeno por fermentación oscura, el tipo de reactor a emplear debe de cubrir ciertas características, tales como el manejo de fases líquida, gaseosa y sólida, producto del sistema biológico complejo (Cherkasov et al., 2023). En este escenario, reactor CSTR resulta una buena opción por sus múltiples características, las cuales se detallarán más adelante.

3.1.3.1 Principio de Funcionamiento

Un CSTR es, en su forma más simple, un tanque equipado con un sistema de agitación (como un impulsor mecánico) diseñado para mantener el contenido del reactor lo más homogéneo posible (Times, 2025) y posee dos principios de operación fundamentales:

Flujo Continuo: El sustrato o "alimento" se introduce en el reactor a un ritmo constante, y simultáneamente, el producto (una mezcla de biomasa, sustrato no consumido y metabolitos) se extrae a la misma velocidad (Khazaei et al., 2020). Esto mantiene un volumen constante dentro del reactor durante toda la operación.

Mezclado Perfecto: La agitación se asume idealmente como "perfecta", lo que significa que cualquier partícula de fluido que entra al reactor se dispersa instantánea y uniformemente, como consecuencia, se asume que las propiedades del sistema (concentraciones, productos, temperatura, biomasa, etc.) son las mismas en cualquier punto (Omeke et al., 2024).

3.1.3.2 Ventajas en el Contexto de la Fermentación Oscura

La popularidad del CSTR en bioprocesos no es una coincidencia. Ofrece varias ventajas prácticas que lo hacen especialmente adecuado para la producción de hidrógeno:

Excelente Control de Temperatura: La agitación vigorosa asegura una distribución homogénea del calor generado o consumido por las reacciones biológicas (Ramli y Mohamad, 2017). Esto es vital para mantener a los microorganismos en su rango de temperatura óptimo, evitando sobrecalentamientos o enfriamientos locales que podrían afectar su metabolismo (Emeka y Onuora, 2024).

Manejo Eficiente de Sistemas Multifásicos: La fermentación oscura es un proceso trifásico: una fase líquida (medio de cultivo), una fase sólida en suspensión (la biomasa) y una fase gaseosa (el biohidrógeno y CO₂ producidos) (Cherkasov et al., 2023). Este reactor resulta adecuado para manejar este tipo de mezclas, facilitando así la transferencia de masa entre las fases (Palomo-Briones et al., 2019).

Operación sencilla y costo-efectiva: En comparación con configuraciones más complejas, como los reactores de lecho fijo (los cuales requieren materiales de soporte adicionales) (Wodołański y Smoliński, 2022, Vongkampang et al., 2023) o los biorreactores de membrana (son muy costosos), el CSTR destaca por su simplicidad. Su diseño es directo, resulta fácil de operar y, además, el proceso de escalado hacia aplicaciones industriales está ampliamente estudiado y documentado, siendo así una opción más económica viable y práctica (Cherkasov

et al., 2023).

3.1.3.3 Desafíos Operacionales

Algunos de los inconvenientes que presentan este tipo de reactores son:

Distribución Amplia de Tiempos de Residencia (RTD): Debido al mezclado perfecto, no todas las partículas de fluido pasan el mismo tiempo dentro del reactor (Cherkasov et al., 2023). Algunas salen casi inmediatamente después de entrar, mientras que otras permanecen por un tiempo mucho más largo que el promedio (Ri et al., 2019), lo que puede llevar a una conversión incompleta del sustrato o la posible degradación de productos si permanecen demasiado tiempo en el reactor (Omeke et al., 2024).

Riesgo de Lavado de Biomasa: Quizás el desafío más crítico en la operación de un CSTR para bioprocesos es el fenómeno de lavado (Trevisan et al., 2024). Si el caudal de alimentación es demasiado alto (es decir, el TRH es demasiado bajo), los microorganismos son expulsados del reactor a una velocidad mayor de la que pueden reproducirse (Regueira-Marcos et al., 2024). Esto provoca una disminución drástica de la biomasa activa hasta que, eventualmente, el proceso se detiene por completo (Ri et al., 2019).

Dinámica Inherente No Lineal: El crecimiento microbiano no es un proceso lineal, lo mismo que el comportamiento de los fluidos dentro del reactor, por lo que el sistema presenta una alta no linealidad (Sinha y Mishra, 2018). Las relaciones entre las variables de entrada (como el caudal) y las de salida (producción de hidrógeno) no son lineales, lo que hace que los controladores convencionales, como el PID, tengan un rendimiento limitado, especialmente frente a grandes perturbaciones (Ramli y Mohamad, 2017).

3.1.4 Modelos pseudo-estequiométricos

Para controlar un proceso, primero se debe entender, y para entender un bioproceso tan complejo como la fermentación oscura es necesario un "mapa" que describa su comportamiento. Este mapa es el modelo matemático. Sin embargo, en biología, crear un mapa perfectamente detallado puede ser tan complicado como el territorio mismo. Si intentáramos modelar cada

una de las cientos de reacciones bioquímicas que ocurren dentro de los microorganismos, obtendríamos un modelo de enorme complejidad, computacionalmente muy costoso y con tantos parámetros que sería casi imposible de calibrar en la práctica (De Figueiredo et al., 2023).

Por otro lado, se puede optar por usar un modelo de caja negra,^{en} donde se relacionan las entradas con las salidas sin explicar lo que sucede dentro, pero este enfoque tiene el inconveniente de no proporcionar suficiente información sobre la dinámica interna del sistema para diseñar un control robusto.

Los modelos pseudo-estequiométricos se encuentran entre estos dos enfoques (Moura et al., 2022); estos modelos, en lugar de detallar cada ruta metabólica, optan por 'compactar' múltiples reacciones a un número reducido de 'macro-reacciones' globales (Abdalah, 2020). La clave del término "pseudo."^{es} que estas reacciones no representan necesariamente una única ruta bioquímica real, sino una equivalencia matemática que respeta una ley fundamental: el balance de masa. Esto asegura que el modelo sea físicamente coherente, algo que los modelos de caja negra no garantizan (De Figueiredo et al., 2023).

3.1.4.1 Importancia y Ventajas para el Control de Procesos

Las principales ventajas de este tipo de modelos son:

Complejidad Manejable: Al reducir el número de ecuaciones y parámetros, el modelo se vuelve más fácil de simular, analizar, por lo que resulta más sencillo de utilizar para el diseño de controladores (Mudzanani et al., 2023).

Balance de Masa Asegurado: A diferencia de los modelos puramente empíricos, garantiza que la conversión de sustrato en productos y biomasa sea consistente, lo que aumenta la confianza en las predicciones del modelo (Abdalah, 2020).

Transparencia: Aunque simplificado, el modelo todavía ofrece una visión de los estados internos clave del sistema (concentraciones de biomasa, sustrato, productos), lo cual es indispensable para entender por qué el sistema responde de cierta manera a una acción de control.

3.1.4.2 Supuestos y limitaciones

Se necesita realizar una serie de simplificaciones para poder obtener un modelo menos complejo y que aún así pueda dimensionar correctamente los resultados. Por un lado, las intrincadas redes metabólicas que ocurren en la realidad se representan como un conjunto reducido de reacciones globales al eliminar los metabolitos intermedios y rutas secundarias (Abdalah, 2020). Por otro lado, se considera que los coeficientes estequiométricos permanecen constantes, cuando en un sistema biológico real dichos valores cambian según las condiciones operativas y la capacidad de adaptación de la comunidad microbiana. Por último, también suele asumirse que las condiciones ambientales son estables, lo que implica fijar variables críticas como el pH y la temperatura, pero significa que no podría predecir el comportamiento del sistema si el control de pH fallara (Gerdtzen et al., 2004).

La principal limitación, por tanto, es que el modelo puede perder poder predictivo si el proceso se aleja mucho de las condiciones bajo las cuales fue calibrado. No puede, por ejemplo, predecir un cambio en las rutas metabólicas dominantes debido a una perturbación severa (Mudzanani et al., 2023). Sin embargo, para el objetivo de mantener el sistema estable alrededor de un punto de operación óptimo, su precisión es más que suficiente.

3.1.4.3 Cinética del Proceso

Para poder describir la velocidad de las reacciones descritas por el modelo, es necesario conocer ciertos parámetros cinéticos, así se puede tener un mayor conocimiento del comportamiento de la comunidad microbiana, algunos de los más importantes se muestran a continuación:

Tasa Máxima de Absorción de Sustrato (μ_{max}): Este parámetro puede interpretarse como la 'velocidad máxima' a la que los microorganismos pueden consumir el sustrato cuando tienen alimento suficiente y todas las condiciones son favorables para su crecimiento (Sharma et al., 2016).

Constante de Semi-saturación (K_s): Este parámetro mide la afinidad de los microorganismos por su alimento (S. R. Hassan et al., 2022) donde valores bajos de K_s significa que la biomasa es muy eficiente mientras que un valor alto indica que se necesita una mayor concentración

de sustrato. Juntos, μ_{max} y K_s definen la famosa cinética de Monod, que describe cómo la velocidad de crecimiento (μ) depende de la concentración de sustrato (S):

Tasa de Dilución (D): Este no es un parámetro biológico, sino operacional, y es el corazón del problema de control de esta tesis. Se define como el caudal de alimentación dividido por el volumen del reactor ($D = Q/V$) y representa la velocidad a la que el medio es renovado (Jiang et al., 2020). Existe un equilibrio delicado: para que la biomasa sobreviva, su tasa de crecimiento (μ) debe ser mayor que la tasa de dilución (D). Si D supera a μ , se entra en el estado de lavado, donde los microorganismos son expulsados más rápido de lo que se reproducen, llevando al colapso del sistema.

Coeficientes de Transferencia de Masa (KLa): Finalmente, una vez que se produce el hidrógeno en la fase líquida, debe pasar a la fase gaseosa para ser recolectado y el coeficiente KLa es el que cuantifica la eficiencia de este transporte. Un valor alto indica una buena transferencia, favorecida por una agitación adecuada y la formación de pequeñas burbujas, mientras que un valor bajo podría crear un 'cuello de botella', limitando la producción de gas medida incluso si la actividad biológica es alta.

3.2 Control por Modos Deslizantes Sin Modelo (MF-SMC)

Esta estrategia de control es una técnica robusta la cual es capaz de forzar al sistema a seguir una trayectoria deseada y mantenerla allí con gran precisión, a pesar de las imprecisiones del modelo (Andrade Da Silva et al., 2005, Zhu, 2021).

3.2.1 Principio de Funcionamiento

El Control por Modos Deslizantes puede entenderse como una estrategia que guía al sistema en dos etapas complementarias:

1. **Fase de alcance:** el controlador actúa para llevar el estado del sistema, sin importar su punto de partida, hacia una trayectoria específica conocida como superficie deslizante. La forma en que se lleva a cabo esta etapa (qué tan rápido y el nivel de suavidad) depende de cómo se diseñe el controlador.

2. **Fase de deslizamiento:** en esta etapa, el controlador ajusta sus acciones de manera rápida y repetida para mantener al sistema confinado en esa trayectoria. Lo notable de este comportamiento es que, durante el deslizamiento, la dinámica del sistema se vuelve resistente a ciertas perturbaciones y variaciones en sus parámetros, otorgándole así la robustez que caracteriza a esta técnica (M. A. Hassan et al., 2023).

La superficie deslizante se diseña para que, una vez se alcance, el error de seguimiento del sistema tienda a cero de acuerdo con una dinámica estable y predecible. Una formulación común para esta superficie, que incorpora tanto el error instantáneo como el acumulado, es la siguiente:

$$s(t) = e(t) + \lambda \int_0^t e(\tau) f \tau \quad (3.1)$$

donde:

- $e(t)$ representa el error de seguimiento en el instante t .
- λ es un parámetro de diseño positivo que ajusta la velocidad de convergencia del error una vez que el sistema se encuentra en la fase de deslizamiento ($s(t) = 0$).

Tradicionalmente, la ley de control del SMC utiliza funciones discontinuas, como la función signo, para garantizar la condición de alcance y deslizamiento. Si bien esto asegura una robustez teórica máxima, en la práctica genera oscilaciones de alta frecuencia en la señal de control, un fenómeno indeseable conocido como chattering (M. A. Hassan et al., 2023, Morales et al., 2022). Este efecto puede provocar desgaste en los actuadores y provocar dinámicas no modeladas en el sistema, lo que limita su aplicación práctica (Ghani et al., 2022).

3.2.2 La Transición al Enfoque Sin Modelo (MF-SMC)

Para diseñar un controlador SMC convencional es necesario contar con un modelo matemático preciso del sistema a controlar, sin embargo, en bioprocesos o sistemas electromecánicos complejos, obtener estos modelos es una tarea muy difícil (Liu et al., 2023), para hacer frente

a este problema, es que surge el enfoque Sin Modelo. Esta variante ya no necesita un modelo matemático detallado sino que su diseño se basa en la relación cauda-efecto local entre la variable de control manipulada y el objetivo de control (Khan, [s.f.](#)).

3.2.3 Construcción de un Controlador MF-SMC

Los pasos principales para diseñar este tipo de controladores son:

1. **Caracterización de la Relación Entrada-Salida:** como ya se mencionó anteriormente, el funcionamiento de esta estrategia de control se fundamenta en la relación de causa-efecto, por lo que el primer paso consiste realizar un análisis del sistema en estado estacionario para determinar cómo es que responde la variable de salida (objetivo de control) ante cambios controlados de la variable de entrada. Con este procedimiento es que se obtiene la curva característica del proceso, la cual engloba el comportamiento no lineal del sistema.
2. **Aproximación Lineal por Tramos:** los sistemas complejos presentan un comportamiento no lineal, Dado que el diseño de controladores para sistemas no lineales es intrínsecamente complejo, una estrategia efectiva es aproximar la curva característica mediante un conjunto de segmentos de recta. Esta linealización por tramos divide el espacio operativo del sistema en varias regiones, y para cada una se define un modelo lineal local que simplifica significativamente el diseño posterior del controlador.
3. **Definición de la Superficie Deslizante:** Al igual que en el SMC clásico, se define una superficie deslizante. Es crucial notar que la definición de esta superficie se basa únicamente en el error de seguimiento y sus derivadas o integrales, por lo que es independiente del modelo del sistema.
4. **Cálculo del Control Equivalente por Zona:** es necesario obtenerlo para cada una de las zonas definidas. Este valor representa la acción de control ideal, esto quiere decir que, en la ausencia de perturbaciones en el sistema, este valor hace posible que se mantenga al sistema sobre la superficie definida ($s(t) = 0$) (M. A. Hassan et al., [2023](#)).

5. Ley de Control con Conmutación Suavizada: aquí se combina el control equivalente con un término robusto de conmutación para garantizar que el sistema pueda responder adecuadamente ante perturbaciones y variaciones no previstas. Para reducir el fenómeno indeseado de chattering, la función de conmutación discontinua se sustituye por una aproximación continua y suave, empleando funciones como la tangente hiperbólica ($\tanh$) o una función de saturación (sat) (Ghani et al., 2022). Estas funciones emulan el comportamiento de la función signo lejos de la superficie deslizante (generando una acción correctiva fuerte) pero se atenúan suavemente a medida que el sistema se acerca a ella, resultando en una señal de control continua y aplicable a sistemas físicos.

Con estos elementos, el controlador resultante es capaz de identificar la zona operativa del sistema actual y aplicar la ley de control local que corresponda. De esta manera es que se logra mantener la estabilidad y desempeño esperado.

3.3 Optimización y evaluación de estrategias de control

3.3.1 Optimización por Algoritmos Genéticos (AG)

Diseñar un controlador avanzado (como un controlador por modos deslizantes) requiere ajustar varios parámetros que determinan qué tan agresivo, rápido y suave será el control, y ese ajuste suele implicar compromisos difíciles entre objetivos contrapuestos (Sardella et al., 2021 Y. Li et al., 1996).

Buscar la mejor combinación de parámetros a mano, mediante prueba y error, es lento e inseguro; mejorar la velocidad de respuesta puede aumentar el esfuerzo del actuador o provocar oscilaciones y chattering, por lo que suele preferirse una búsqueda automatizada (Y. Li et al., 1996, Mavrinac et al., 2022).

Los algoritmos genéticos (AG) son técnicas de optimización inspiradas en la evolución natural que resultan útiles para este tipo de problemas porque exploran grandes espacios de soluciones de forma robusta y estocástica, sin requerir derivadas ni linealidad del modelo (Manohar, 2020, Moin, 1995, Wang et al., 2020).

3.3.1.1 Funcionamiento

Un AG parte de una 'población' de soluciones posibles (cada solución es un conjunto de parámetros del controlador) y las hace evolucionar durante varias generaciones mediante operadores que imitan la selección natural, el cruce y la mutación; con el tiempo, la población tiende a concentrarse en soluciones cada vez mejores (Manohar, 2020).

3.3.1.2 Componentes clave

- **Representación y población inicial:** cada individuo o 'cromosoma' es un vector que contiene los parámetros del controlador; la población se inicia con múltiples vectores generados aleatoriamente dentro de rangos razonables para asegurar diversidad (Mavrinac et al., 2022, Manohar, 2020).
- **Función de aptitud (fitness):** evalúa cada individuo aplicando sus parámetros en una simulación del proceso y devuelve un número que mide qué tan 'buena' es esa solución; para controladores suele combinarse más de un criterio (por ejemplo, ISE para precisión, esfuerzo de control y penalización del chattering) en una función ponderada (Y. Li et al., 1996, Mavrinac et al., 2022).
- **Selección:** las soluciones mejor evaluadas tienen más probabilidad de 'reproducirse'; métodos como la selección por torneo son usados habitualmente porque mantienen presión selectiva y diversidad al mismo tiempo (Manohar, 2020).
- **Cruce y mutación:** en el cruce se mezclan parámetros de dos padres para generar hijos para que posean rasgos combinados, mientras que la mutación introduce de manera aleatoria pequeñas variaciones para explorar nuevas regiones del espacio de soluciones (MATLAB, s.f.).
- **Criterio de terminación:** el ciclo se repite hasta que se cumple una condición (por ejemplo, cierto número de generaciones o convergencia), y la mejor solución encontrada se toma como configuración final del controlador (Azeez et al., 2023).

Sintonización de controladores mediante AG Los AG permiten equilibrar objetivos opuestos

(precisión, consumo y suavidad) sin necesidad de formular una solución analítica única, y han sido aplicados con éxito para reducir el chattering y mejorar el desempeño en controladores deslizantes y otros esquemas robustos (Y. Li et al., 1996, Wang et al., 2020, Bensaada y Boudghene Stambouli, 2013).

No obstante, su éxito depende de decisiones de diseño (tamaño de población, tasas de cruce y mutación, definición de la función de aptitud), por lo que una mala configuración puede aumentar el tiempo de cómputo o producir soluciones subóptimas (Mavrinac et al., 2022).

3.3.2 Simulación y Métricas de evaluación

La simulación ayuda a comprender el efecto que cada variable tiene sobre las salidas de modelo (Mirzal et al., 2006, Gani et al., 2019), además, si se incorpora ruido, variabilidad en los parámetros o escenarios no ideales, se convierte en un análisis de condiciones más cercanas a las reales (De Figueiredo et al., 2023). Por ello, un procedimiento práctico y extendido es combinar simulaciones ordenadas (primero deterministas, luego con variabilidad y ruido) para validar y ajustar controladores antes de cualquier implementación en planta (Mirzal et al., 2006, De Figueiredo et al., 2023).

3.3.2.1 Métricas de desempeño

Las métricas de simulación cuantifican aspectos clave del desempeño de un controlador: calidad de seguimiento, contención de picos, esfuerzo de actuador y suavidad de la actuación, entre otros, y sirven para comparar alternativas de control de forma objetiva (Pätsi et al., 2023, Vasudevan y Rangaiah, 2010).

A continuación se presentan las métricas más utilizadas de forma intuitiva y con su formulación matemática elemental cuando procede:

Precisión de seguimiento (Error en régimen o ESS): indica cuánto, en promedio, se desvía la salida del valor objetivo dentro de una ventana de observación (Pätsi et al., 2023, Vasudevan

y Rangaiah, 2010). Formulación típica (ventana $[t_0, t_f]$):

$$ESS = \frac{1}{N} \sum_{t=t_0}^{t_f} |e(t)| \quad y \quad e(t) = y_{ref}(t) - y(t) \quad (3.2)$$

donde:

- k es el índice de muestreo
- $y(t)$ es la salida del proceso

Error cuadrático integral (ISE) y variantes (IAE, ITAE): penalizan las desviaciones a lo largo del tiempo y otorgan mayor peso a errores grandes o persistentes según la forma elegida. (Mohamed et al., 2023). Formulación:

$$ISE = \int_{t_0}^{t_f} e^2(t) dt \quad (3.3)$$

Amplitud máxima (overshoot): cuantifica la mayor desviación puntual respecto al objetivo en la ventana considerada; útil para evaluar riesgos y límites de seguridad. (Xu et al., 2025). Formulación:

$$Amplitud = \max_{t \in [t_0, t_f]} |e(t)| \quad (3.4)$$

Esfuerzo de control (energía o variación total): mide la 'energía' o la variación acumulada que imprime el actuador; importante por costes y vida útil de equipos (Sarhadi, 2025). Formulación:

$$Esfuerzo = \int_{t_0}^{t_f} u^2(t) dt \quad (3.5)$$

donde $u(t)$ es la señal de control.

Índices de chattering o suavidad: caracterizan la rapidez y frecuencia de variaciones en la señal de control, que pueden dañar actuadores o activar dinámicas no modeladas. Una medida

práctica empleada es la integral del cuadrado de la derivada de la señal de control: (Pätsi et al., 2023, Arevalo-Castiblanco et al., 2020).

$$Chattering = \int_{t_0}^{t_f} (\dot{u}(t))^2 dt \quad (3.6)$$

3.3.2.2 Elección de ventanas temporales para evaluación de métricas

La selección de la ventana de tiempo sobre la cual se calcula cada métrica condiciona fuertemente la interpretación de resultados; elegir ventanas coherentes con la naturaleza de la perturbación y la dinámica del proceso es esencial para comparaciones válidas (Puiman et al., 2023, Lara-Musule et al., 2021).

Principio general: la ventana debe capturar el fenómeno que se pretende evaluar (transitorio inicial, recuperación, estado estacionario, comportamiento periódico), evitando mezclar comportamientos no homogéneos que dificulten la comparación (Puiman et al., 2023, Pätsi et al., 2023).

Criterios prácticos según tipo de perturbación:

- Escalón rápido: emplear una ventana que incluya la respuesta inmediata y una porción del posterior asentamiento para discriminar rapidez y precisión final (Ahmad Joharee et al., 2021).
- Rampa o variación lenta: en este caso, la atención se centra en la parte de la rampa donde la pendiente es más marcada. Esto permite evaluar con mayor precisión la capacidad del sistema para seguir cambios que ocurren de manera continua (Puiman et al., 2023, Lara-Musule et al., 2021).
- Señales periódicas (sinusoides): las métricas se calculan a lo largo de varios periodos o en ventanas que representen distintas fases del ciclo. Así se obtiene una visión más robusta y completa del desempeño del sistema (Pätsi et al., 2023).
- Ruido o perturbaciones estocásticas: cuando las señales incluyen ruido o variabilidad aleatoria, lo más adecuado es trabajar con ventanas largas y aplicar enfoques estadís-

ticos, como promedios y percentiles para facilitar la caracterización de la respuesta (Sreemahadevan et al., 2024, Lara-Musule et al., 2021).

3.3.3 Análisis estadísticos

3.3.3.1 Datos heterogpeneos en simulaciones

En estudios de simulación complejos es frecuente obtener conjuntos de respuestas heterogéneas que incluyen ejecuciones reproducibles, trayectorias con ruido, respuestas atípicas y múltiples métricas de desempeño; clasificar estas salidas según su grado de similitud facilita interpretar resultados, priorizar análisis y elegir pruebas estadísticas acordes a la estructura de los datos (Levy et al., 2025, Preud'homme et al., 2021).

Además, una clasificación previa permite reducir redundancias (por ejemplo, condensando un subgrupo muy próximo en un representante) y focalizar los contrastes estadísticos en comparaciones informativas, lo que mejora la potencia y la claridad de las conclusiones (Ciaramella et al., 2020, Diop et al., 2025).

3.3.3.2 Herramientas principales para determinar grados de similitud

Dendrogramas y clustering jerárquico Un dendrograma es la representación gráfica de un procedimiento de clustering jerárquico aglomerativo que fusiona iterativamente los pares de objetos (o clústeres) más próximos hasta formar un árbol, donde la altura de cada unión refleja la disimilitud a la que se fusionaron los grupos (Benatti y Costa, 2024, Preud'homme et al., 2021).

El uso práctico del dendrograma consiste en cortar el árbol a distintas alturas para obtener particiones con distintos niveles de granularidad y validar, de manera visual y cuantitativa, si existen parejas, subgrupos o agrupamientos más amplios entre las respuestas (Levy et al., 2025, Ciaramella et al., 2020).

Para tomar decisiones reproducibles sobre cortes y número de grupos conviene combinar la lectura del dendrograma con reglas numéricas y criterios de validación estadística, en lugar de basarse solo en la inspección visual (Diop et al., 2025, Benatti y Costa, 2024).

Medición cuantitativa de la similitud: distancias y descriptores resumen

Después del acondicionamiento (transformaciones y normalizaciones), cada respuesta se representa como un vector de métricas normalizadas y la disimilitud entre dos respuestas a y b se cuantifica mediante una medida de distancia; las más habituales son: la distancia Manhattan, definida como $d_{Manhattan}(a, b) = \sum_i |a_i - b_i|$, y la distancia euclidiana, definida como $d_{Euclidiana}(a, b) = \sqrt{\sum_i (a_i - b_i)^2}$ (Levy et al., 2025).

La distancia Manhattan suele preferirse cuando se desea mayor robustez ante valores extremos, pues penaliza de forma lineal las diferencias y reduce la influencia de outliers extremos (Todoric y Mastelic, 2023).

A partir de la matriz de distancias entre todos los pares en un caso se calculan descriptores resumen operativos que sirven para clasificar la estructura de similitud:

- Distancia mínima = $\min_{i < j} d_{ij}$, la mínima distancia pareada (identifica la pareja más próxima)
- Segunda distancia mínima = segunda mínima distancia pareada (permite distinguir parejas claras de similitudes difusas)
- Mediana = indica el nivel típico de separación

El uso de estos estadísticos resumen facilita traducir la información compleja de la matriz de distancias a criterios interpretables y reproducibles (Levy et al., 2025, Preud'homme et al., 2021).

Reglas empíricas para etiquetar grados de similitud

Sobre los descriptores anteriores se pueden aplicar reglas empíricas calibradas con inspección visual y validación jerárquica. Dichas reglas no son axiomas matemáticos sino criterios operativos que deben calibrarse con la inspección de los dendrogramas y con cortes basados en percentiles (por ejemplo P25 y P50) para distinguir agrupamientos fuertes, similitudes moderadas o diferenciaciones claras (Levy et al., 2025, Ciaramella et al., 2020).

Validación cuantitativa y pruebas de significación de agrupamientos

La clasificación por reglas y dendrogramas puede complementarse con procedimientos de validación estadística que evalúan si las particiones son consistentes o si podrían surgir por azar; enfoques recientes combinan clustering jerárquico con pruebas de significación en los nodos del dendrograma para decidir si dividir un grupo en subgrupos es estadísticamente justificable (Preud'homme et al., 2021, Benatti y Costa, 2024).

También existen índices y medidas para comparar dendrogramas y validar acuerdos entre clasificaciones (p. ej. índices tipo cophenetic, índices Z y otros métodos para comparar topologías), útiles cuando se requiere comparar resultados obtenidos con distintas métricas o métodos de linkage (Vidovic, 2019, Levy et al., 2025).

3.3.3.3 Estadísticas descriptivas

En el análisis de salidas de simulación, las medidas descriptivas condensan la información esencial de cada métrica y orientan la elección de métodos inferenciales posteriores (Arachchige et al., 2020, Chi et al., 2023).

Media: resume el valor central promedio de un conjunto de observaciones y se calcula como $\bar{x} = (1/n) \sum_{i=1}^n x_i$, donde $\bar{x}$ es la media, n el número de observaciones y x_i cada observación (Chi et al., 2023). La media es útil cuando la distribución es aproximadamente simétrica y no hay outliers extremos; en presencia de asimetría o valores atípicos, su interpretación puede ser engañosa porque es sensible a observaciones extremas (Chi et al., 2023, Veljkovic, 2024).

Mediana: es el valor que separa la mitad superior de la mitad inferior de la muestra (para ordenadas $x_{(1)} \leq \dots \leq x_{(n)}$, la mediana es $x_{(n/2)}$ o el promedio de los dos centrales si n es par) y es una medida de posición robusta frente a valores atípicos (Daraz et al., 2025). Se recomienda usar la mediana cuando la distribución está sesgada o cuando se desea una medida representativa del "centro típico" que no sea influida por extremos (Arachchige et al., 2020, Daraz et al., 2025).

IQR (rango intercuartílico): mide la dispersión central robusta y se define como $IQR = Q3 - Q1$, siendo $Q1$ y $Q3$ los percentiles 25 y 75 respectivamente (Arachchige et al., 2020). El IQR es apropiado para describir la variabilidad "típica" de los datos cuando hay colas

largas o outliers, y además sirve como escala para normalizaciones robustas previo cálculo de distancias o comparaciones (Arachchige et al., 2020, Daraz et al., 2025).

Desviación estándar (s): cuantifica la dispersión respecto a la media y se calcula como $s = \sqrt{(1/(n-1)) \sum_{i=1}^n (x_i - \bar{x})^2}$, donde el denominador $(n-1)$ corrige el sesgo en muestras finitas (MacMillan et al., 2022). Esta medida aporta información sobre la variabilidad absoluta de la métrica y es adecuada cuando la media es representativa; cuando la distribución es muy asimétrica conviene complementarla con medidas robustas (mediana, IQR) (Arachchige et al., 2020 Veljkovic, 2024).

Coefficiente de variación (CV): se define como $CV = s/\bar{x}$ (a menudo expresado en %) y resume la dispersión relativa ajustada por la escala de la media (Arachchige et al., 2020). CV es especialmente útil para comparar la variabilidad de métricas con unidades o escalas distintas: valores pequeños de CV indican resultados relativamente consistentes, mientras que CV altos señalan gran variabilidad relativa que puede afectar la confiabilidad de comparaciones (Arachchige et al., 2020, Chi et al., 2023).

Confiabilidad práctica: la confiabilidad de una métrica en simulaciones (evaluada por ejemplo mediante el CV o mediante la estabilidad del IQR en réplicas) indica cuán robustos son los resultados frente a ruido y variabilidad estocástica; en la práctica se usan umbrales operativos (p. ej. $CV \leq 15\%$ como alta confiabilidad), pero estos umbrales deben contextualizarse según la métrica y el dominio de estudio (Chi et al., 2023, Arachchige et al., 2020). Cuando la confiabilidad es baja conviene aumentar réplicas, usar estimadores robustos (mediana/IQR) o reportar intervalos de incertidumbre adecuados antes de realizar comparaciones formales (Chi et al., 2023, Veljkovic, 2024).

3.3.3.4 Supuestos estadísticos

La verificación de supuestos es un paso previo imprescindible porque los test paramétricos clásicos (t, ANOVA) presuponen errores aproximadamente normales y varianzas homogéneas; violar estas condiciones puede alterar la tasa de error tipo I y la potencia de las pruebas, por lo que conviene diagnosticarlas explícitamente antes del contraste formal (Wilcox y Rousselet,

2023, Shatz, 2024).

El test de **Shapiro-Wilk** comprueba la hipótesis nula de que una muestra procede de una distribución normal; su estadístico puede escribirse como

$$W = \frac{(\sum_{i=1}^n a_i x(i))^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.7)$$

donde $x(i)$ son los ordenados muestrales y a_i constantes que dependen de n , y valores bajos de W con $p < \alpha$ indican desviación de la normalidad (González-Estrada et al., 2022).

La **homocedasticidad** (igualdad de varianzas entre grupos) se evalúa con pruebas como Levene, cuya conclusión orienta si usar la ANOVA clásica (varianzas iguales) o alternativas robustas (p. ej. Welch) cuando existen heteroscedasticidad o tamaños de muestra desbalanceados (Wilcox y Rousselet, 2023).

3.3.3.5 Pruebas paramétricas

El **t de Student** compara medias entre dos grupos independientes bajo normalidad y homogeneidad de varianzas; la versión clásica usa la estadística $t = (\bar{x}_1 - \bar{x}_2) / (s_p \sqrt{1/n_1 + 1/n_2})$, con s_p^2 como la varianza combinada (Chicco et al., 2025).

El **ANOVA de una vía** extiende la comparación a k grupos evaluando la relación entre la varianza entre grupos y la varianza intra-grupo mediante el estadístico $F = MS_{between} / MS_{within}$; un F significativo indica que no todas las medias son iguales y exige post-hoc para identificar pares distintos (Wilcox y Rousselet, 2023, Bobbitt, 2019).

Cuando las varianzas son desiguales o los tamaños muestrales están desbalanceados, la ANOVA clásica puede comportarse mal; en esos casos la **ANOVA de Welch** es una alternativa robusta que ajusta los grados de libertad y tiende a controlar mejor el error tipo I bajo heteroscedasticidad (Lopez, s.f.).

3.3.3.6 Pruebas no paramétricas

Si las condiciones paramétricas no se cumplen, las pruebas no paramétricas basadas en rangos ofrecen alternativas que no requieren normalidad de las muestras; **U de Mann-Whitney** compara dos grupos mediante la suma de rangos y es apropiada para datos continuos no normales o con escalas ordinales (Chicco et al., 2025, Hinduja, 2023).

Para más de dos grupos, el test de **Kruskal-Wallis** actúa como análogo no paramétrico del ANOVA, comparando distribuciones (rangos) entre los k grupos; sin embargo, su uso exige cautela: en presencia de heterocedasticidad o diferencias de forma entre distribuciones, la interpretación centrada en "medianas" puede ser inadecuada y las tasas de error pueden desviarse de lo esperado (Nwobi, s.f., Kroeger et al., 2021).

En consecuencia, la elección entre test paramétrico y no paramétrico debe apoyarse en los diagnósticos de supuestos y en la naturaleza de la hipótesis (diferencias de medias vs. diferencias de distribuciones) (Shatz, 2024).

3.3.3.7 Análisis post-hoc

Los análisis post-hoc se aplican tras un contraste global significativo para identificar qué pares de grupos difieren exactamente, controlando el error familiar (*family-wise error rate*) (Bobbitt, 2019, Frost, s.f.).

Tukey (HSD) compara todas las parejas de medias controlando el error familiar mediante la distribución rango-studentizada; es apropiado cuando se cumplen supuestos de normalidad e igualdad de varianzas y ofrece una interpretación directa de diferencias de medias («Tukey's range test», 2025).

Games-Howell es un procedimiento post-hoc diseñado para comparar pares cuando existen varianzas desiguales y/o tamaños desbalanceados; sin embargo, en las fuentes que me fueron provistas no apareció una referencia específica a Games-Howell, por lo que no puedo aportar aquí una cita externa concreta sobre su formulación dentro del conjunto de documentos disponibles.

Para pruebas no paramétricas, tras un Kruskal-Wallis se emplea frecuentemente el **test de Dunn** para comparaciones por pares combinadas con correcciones por comparaciones múltiples (por ejemplo Bonferroni) para controlar la tasa de falsos positivos; la corrección de Bonferroni ajusta el nivel α por el número de comparaciones ($\alpha_{adj} = \alpha/m$) y es una estrategia conservadora ampliamente mencionada en la literatura de comparaciones múltiples (Ajee et al., 2024, Bobbitt, 2019).

En resumen, la selección del post-hoc adecuado debe responder a los supuestos diagnósticos (igualdad de varianzas, normalidad), al número y balance de muestras, y al objetivo inferencial (comparar medias paramétricamente o pares de distribuciones por rangos) (Bobbitt, 2019, Lopez, s.f.).

CAPÍTULO 4: METODOLOGÍA

4.1 Modelo matemático de la producción de hidrógeno

El modelo de planta para el diseño de control se basó en el trabajo de Aceves-Lara et al., 2008, que describe la dinámica de la fermentación oscura con balances de masa para sustrato, metabolitos, biomasa y fase gaseosa, incluyendo transferencia gas-líquido para H_2 y CO_2 .

Este modelo, originalmente implementado en MATLAB/Simulink, se tradujo a Python para su integración con rutinas de simulación y optimización. Se conservaron parámetros y condiciones operativas nominales reportadas en la literatura y en la migración: volumen de trabajo del reactor $V = 0.9$ L, tiempo de retención hidráulica (HRT) de 6 h, $pH \approx 5.5$, temperatura del reactor ≈ 308 K, y concentración de sustrato en el afluente $Glu_in = 20.04$ g/L. La variable controlada fue la producción de H_2 en la fase gaseosa, y la variable manipulada el caudal de alimentación.

4.1.1 Proceso de migración

Para poder migrar el modelo sin modificar el comportamiento del sistema original se reescribieron las 9 EDO respetando la notación, los parámetros se mantuvieron iguales, se fijaron las mismas condiciones iniciales [0.43, 0.35, 0.14, 0.12, 0.19, 0.1, 0.1, 0.004, 0.007].

La resolución numérica en Python se realizó con la función `odeint` de SciPy, lo que permitió ajustar explícitamente la precisión del integrador; en particular, se fijaron tolerancias relativas y absolutas estrictas (por ejemplo, $rtol = 1e-6$ y $atol = 1e-9$) para asegurar estabilidad y reproducibilidad en las simulaciones.

A diferencia de la configuración automática de tolerancias y de entradas en Simulink, en Python se representaron las variables de entrada mediante interpolación, introduciendo transiciones graduales más acordes con el comportamiento físico de cambios en el caudal de dilución y en la concentración de glucosa de alimentación.

Las entradas, $D(t)$ y $Glu_in(t)$, se implementaron como funciones del tiempo, constantes o por tramos según el experimento numérico, manteniendo la estructura del modelo y su coherencia

dimensional.

4.2 Análisis de sensibilidad

Para el diseño efectivo de controladores resultó indispensable caracterizar la respuesta del sistema frente a variaciones de sus entradas y, con ello, delimitar regiones operativas sensibles y rangos de trabajo seguros en los que el controlador deba sostener el desempeño deseado.

4.2.1 Caracterización de la superficie de respuesta

Se adoptó un enfoque en dos etapas para describir la superficie de respuesta del proceso de producción de hidrógeno. En primer lugar, se realizó un barrido exploratorio sobre una malla completa en el espacio de dos variables críticas: la concentración de glucosa en el afluente (10–20 g/L) y el caudal de alimentación (2–8 L/d). Se evaluaron 100 combinaciones (10×10 puntos) y, para cada par de condiciones, se integró el modelo en 100 unidades de tiempo; la respuesta considerada fue la producción de H₂ en fase gaseosa en régimen. Este análisis produjo un mapa de calor que ofreció una visión global de la superficie, lo que permitió localizar regiones de mayor interés operativo por su sensibilidad (cambios de producción).

4.2.2 Implementación del algoritmo de optimización

En una segunda etapa, se refinó la caracterización mediante optimización local con restricciones tipo caja sobre los mismos límites operativos. Se empleó el método L-BFGS-B (*Limited-memory Broyden–Fletcher–Goldfarb–Shanno con cotas*) ya que es adecuado en problemas no lineales suaves con restricciones de caja. La función objetivo se definió como el negativo de la producción de H₂ en régimen (minimización equivalente a la maximización del rendimiento), calculada a partir del simulador dinámico. La configuración adoptada fue la siguiente: límites [10, 20] g/L para la concentración de glucosa y [2, 8] L/d para el caudal; máximo de 100 iteraciones; y criterio de parada por tolerancia sobre la función de 1×10^{-5} . Como punto inicial se utilizaron $\text{Glu}_{\text{in}} = 20.04$ g/L y $Q_{\text{in}} = 5$ L/d, coherentes con condiciones nominales reportadas para la operación del sistema. Adicionalmente, para robustecer la solución, se repitió la optimización desde los mejores candidatos del barrido

denso y se verificó la consistencia de la convergencia (misma solución y valores de la función objetivo) entre ejecuciones. En todos los casos, el resto de condiciones operativas del modelo (pH, HRT, temperatura y parámetros cinético-físicoquímicos) se mantuvo fijo, de modo que la superficie de respuesta refleja exclusivamente el efecto de Glu_{in} y Q_{in} sobre la producción de hidrógeno.

4.3 Caracterización del comportamiento del sistema

Análisis de la curva característica.

Con la concentración de glucosa fijada en su valor óptimo de 20 g/L (resultado de la etapa de optimización), se estudió cómo cambia la producción de hidrógeno al variar el caudal de alimentación, con el fin de comprender el comportamiento global del proceso y sentar bases sólidas para el diseño del controlador por modos deslizantes sin modelo.

Se evaluó el sistema variando el caudal de entrada (Q_{in}) entre 0 y 8 L/d, manteniendo constante la glucosa en 20 g/L; se emplearon incrementos regulares de caudal para obtener una curva característica con resolución suficiente en todo el rango operativo. La curva se obtuvo mediante simulación del modelo en Python: para cada valor de caudal se integró el sistema hasta alcanzar el estado estacionario y, entonces, se registró la producción de H_2 correspondiente, garantizando que cada punto representara el equilibrio del proceso bajo esas condiciones.

Interpretación de la curva característica.

A partir de la curva característica se distinguieron, de forma visual, los comportamientos típicos: zona de incremento en la producción de H_2 ; una zona intermedia cercana al máximo de eficiencia; y una tercera zona en la que la producción disminuye cuando el caudal es elevado (efecto de “lavado” del reactor).

Del mismo modo, establecieron de manera visual dos puntos de transición que separan las regiones identificadas para así ayudar a delimitar rangos de operación prácticos. Esta lectura de la curva facilita, además, la posterior representación por tramos que se utiliza en el esquema de control por modos deslizantes, al ofrecer una guía clara para dividir el comportamiento en

segmentos aproximadamente lineales dentro de cada zona.

4.4 Linealización por tramos del modelo

Para poder diseñar un controlador por modos deslizantes sin modelo se requiere de una relación explícita entre la variable de control (caudal de entrada) y el objetivo de control (producción de hidrógeno). La dificultad que presenta el modelo original es que ambas variables se relacionan de manera indirecta a través de varias ecuaciones diferenciales acopladas, lo que dificulta su uso directo. Es por ello que se recurrió a una linealización por tramos (*piecewise linearization*), que es una aproximación sencilla y eficaz que reproduce el comportamiento no lineal del proceso dentro de las distintas regiones operacionales identificadas previamente.

4.4.1 Implementación

Ajuste de parámetros. Los parámetros de cada recta por tramo se estimaron por optimización numérica mediante el algoritmo L-BFGS-B, minimizando el error cuadrático medio (MSE) entre la producción de H₂ del modelo original y la aproximación lineal en los mismos puntos de evaluación. La función objetivo considerada fue:

$$\min_{\theta} \text{MSE} = \frac{1}{n} \sum_{i=1}^n (H_{2,\text{modelo}}(Q_i) - H_{2,\text{lineal}}(Q_i; \theta))^2 \quad (4.1)$$

donde θ corresponde a los parámetros de pendiente y ordenada al origen de cada tramo.

4.4.2 Formulación matemática:

La curva característica se aproxima con tres expresiones lineales, una por cada zona:

$$H_2 = m_i \cdot Q + b_i \quad (4.2)$$

donde:

- H_2 : Producción de hidrógeno (mol/L)

- Q : Caudal de entrada (L/d)
- m_i : Pendiente de la zona i
- b_i : Ordenada al origen de la zona i

Se cuenta con una estructura del modelo por tramos de la siguiente manera:

- Zona 1:

$$Q \leq t_1 \rightarrow H_2 = m_1 \cdot Q + b_1$$

- Zona 2:

$$t_1 < Q \leq t_2 \rightarrow H_2 = m_2 \cdot Q + b_2$$

- Zona 3:

$$Q > t_2 \rightarrow H_2 = m_3 \cdot Q + b_3$$

donde t_1 y t_2 son los puntos de transición.

4.4.3 Determinación de caudales equivalentes:

Para cada zona se calculó el caudal equivalente que satisface el setpoint de producción de hidrógeno. Este valor se obtiene sustituyendo H_2 , setpoint en la ecuación correspondiente y despejando Q_i se obtiene:

$$Q_i = \frac{H_{2, \text{setpoint}} - b_i}{m_i} \quad (4.3)$$

Estos caudales equivalentes definen puntos de operación de referencia y sirven como guías prácticas para el diseño del controlador por modos deslizantes en cada zona.

4.4.4 Validación del modelo linealizado por tramos

4.4.4.1 Evaluación cuantitativa de la precisión

Para establecer qué tan bien el modelo linealizado logra representar al modelo original, se establecieron indicadores para evaluar de manera cuantitativa el nivel de fidelidad. En este

caso, se recurrió a tres métricas estadísticas ampliamente utilizadas, ya que cada una aporta una perspectiva distinta sobre el desempeño del modelo.

4.4.4.2 Métricas de evaluación

El coeficiente de determinación (R^2) ayuda a mostrar qué porcentaje de la variaciones en la producción de hidrógeno el nuevo modelo es capaz de capturar (ecuación 4.4) Por otro lado, el error cuadrático medio (MSE) cuantifica el tamaño promedio de las diferencias entre lo predicho y lo observado (ecuación 4.5). Por último, el error absoluto medio (MAE) resume el error promedio sin importar la dirección de las desviaciones (positivas o negativas), lo que lo vuelve menos sensible a valores atípicos (ecuación 4.6).

1. Coeficiente de determinación (R^2):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.4)$$

donde y_i son los valores del modelo original, $\hat{y}_i$ los valores estimados por el modelo linealizado y $\bar{y}$ la media de los valores originales.

2. Error cuadrático medio (MSE):

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.5)$$

3. Error absoluto medio (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.6)$$

4.4.4.3 Procedimiento de validación

Se emplearon los mismos datos de la caracterización del sistema (caudal de entrada en el rango de 0-8 L/d). Para cada valor de caudal, se comparó la producción de hidrógeno del modelo original con la predicha por el modelo linealizado y se calcularon las métricas anteriores.

Se calcularon los valores de las métricas por cada una de las tres zonas operativas. Esto permitió identificar en qué intervalos la aproximación lineal es más precisa y, por tanto, más útil para fines de control. Además se realizó un análisis global de modelo para determinar el nivel de ajuste total del modelo linealizado.

4.5 Diseño de controladores por modos deslizantes sin modelo

Se eligió el control MF-SMC ya que es una técnica robusta de control y es posible trabajar sin conocer al detalle las ecuaciones del proceso que para este trabajo de investigación es indispensable. Esta técnica resulta útil en bioprocesos, donde a menudo hay parámetros inciertos y perturbaciones que no se pueden predecir del todo.

4.5.1 Componentes fundamentales del controlador

Para diseñar este tipo de control se definen dos piezas clave: la “superficie deslizante” y la ley de control.

4.5.1.1 Superficie deslizante

La superficie deslizante es una combinación sencilla del error actual y del error acumulado en el tiempo:

$$s(t) = e(t) + \lambda \int e(t)dt \quad (4.7)$$

donde:

- $e(t) = H_{2, set\ point} - H_{2, medido}$ es el error de seguimiento
- $\lambda > 0$ es el parámetro de diseño que establece la contribución integral del error

Con esta definición, cuando el sistema se mantiene en la superficie ($s(t) = 0$), el error se va reduciendo de forma rápida y suave hasta desaparecer, a una velocidad que depende de λ .

4.5.1.2 Leyes de Control y Funciones de Conmutación

Las acciones de control se definieron a partir de la combinación de dos tipos de funciones de conmutación: tangente hiperbólica y saturación, con dos estrategias de ajuste de ganancia, una de carácter fijo y otra de tipo adaptativo. De este modo se obtuvieron cuatro variaciones sencillas y robustas.

Funciones de conmutación seleccionadas

La tangente hiperbólica ($\tanh$) y saturación (sat) suavizan la conmutación del controlador y reducen el chattering frente a una función signo clásica. Esto es especialmente importante en bioprocesos, donde cambios bruscos pueden afectar a los microorganismos.

Leyes de control implementadas

1. Ley de control con tangente hiperbólica y ganancia fija:

$$Q = Q_{eq,i} + K_i \tanh \frac{s}{\varepsilon}$$

2. Ley de control con tangente hiperbólica y ganancia adaptativa:

$$Q = Q_{eq,i} + K_{adap} \tanh \frac{s}{\varepsilon}$$

3. Ley de control con saturación y ganancia fija:

$$Q = Q_{eq,i} + K_i \text{sat} \frac{s}{\phi}$$

4. Ley de control con saturación y ganancia adaptativa:

$$Q = Q_{eq,i} + K_{adap} \text{sat} \frac{s}{\phi}$$

donde:

- $Q_{eq,i}$: caudal equivalente de la zona operacional i (punto de referencia local).
- K_i : ganancia específica para cada zona

- K_{adap} : ganancia adaptativa con límites predefinidos
- ε : parámetro de “suavidad” en tanh (controla la pendiente alrededor de $s = 0$)
- ϕ : parámetro de “ancho de banda” en sat (define el rango lineal antes de saturar)
- s : es variable de la superficie deslizante

En resumen, tanh y sat controlan cuán agresiva es la corrección del error (s), mientras que las ganancias (fijas o adaptativas) ajustan la intensidad de la acción de control.

4.5.1.3 Estrategia de Conmutación entre Zonas

Los controladores por modos deslizantes diseñados operan con conmutación automática entre las tres zonas del modelo linealizado, basándose en el valor actual de la variable controlada (x_9 , que representa la producción de hidrógeno en mol/L).

Determinación de los límites de conmutación

Para decidir cuándo cambiar de una zona a otra, se evaluaron las rectas linealizadas en los caudales de transición previamente definidos. Así se obtuvieron los umbrales de H_2 que activan cada región:

- **Límite Zona 1-2:** Evaluando la ecuación de la Zona 1 en $t_1 = 2.8$ L/d:

$$H_{2,limite1} = 0.319 \times 2.8 + 0.018 = 0.911 \text{ mol/L}$$

- **Límite Zona 2-3:** Evaluando la ecuación de la Zona 2 en $t_2 = 3.7$ L/d:

$$H_{2,limite2} = 0.067 \times 3.7 + 0.688 = 0.936 \text{ mol/L}$$

Condiciones de conmutación implementadas Con estos umbrales, el controlador selecciona automáticamente la zona operativa en función de x_9 (producción de H_2):

- **Zona 1:** $x_9 \leq 0.911 \text{ mol/L}$

- **Zona 2:** $0.911 < x_9 \leq 0.936$ mol/L
- **Zona 3:** $x_9 > 0.936$ mol/L

De este modo, la conmutación entre zonas activa los parámetros de control más adecuados en cada región, aprovechando las características linealizadas locales y manteniendo un desempeño eficiente a lo largo de todo el rango operacional del biorreactor.

4.5.1.4 Ley de Adaptación para Ganancias Variables

La motivación de emplear controladores con ganancia adaptativa radica en permitir que esta se ajuste de manera automática según la magnitud del error en la superficie deslizante. De este modo, en cada instante de tiempo la ganancia se actualiza siguiendo la relación expresada en la ecuación 4.8

$$K_{adap}(t + dt) = K_{adap}(t) + \alpha \cdot |s(t)| \cdot dt \quad (4.8)$$

- Cuanto mayor sea el valor absoluto de la superficie $|s(t)|$, mayor será el ajuste.
- El parámetro α fija la “velocidad” de adaptación: valores más altos hacen que la ganancia cambie más rápido; valores más bajos, más lento.

Saturación de la ganancia adaptativa

Para evitar excesos que puedan desestabilizar el sistema (o estar sin acción de control), la ganancia adaptativa se mantiene dentro de un rango seguro:

$$K_{adap}(t) = \begin{cases} K_{min} & \text{si } K_{adap}(t) < K_{min} \\ K_{max} & \text{si } K_{adap}(t) > K_{max} \\ K_{adap}(t) & \text{en otro caso} \end{cases}$$

Así se asegura de que K_{adap} no se dispare ni quede demasiado pequeña.

Restricciones Operacionales

Además, la señal de control se limita a los rangos físicos del equipo. En la práctica se restringe el caudal a $[0,10]$ L/d:

$$Q_{controlado} = \begin{cases} 0 & \text{si } Q < 0 \\ 10 & \text{si } Q > 10 \\ Q & \text{si } 0 \leq Q \leq 10 \end{cases} \quad \text{L/d} \quad (4.9)$$

De este modo, el controlador siempre actúa dentro de los límites seguros del biorreactor.

4.6 Sintonización de Parámetros mediante Algoritmo Genético

Se empleó un Algoritmo Genético (AG) para explorar diferentes configuraciones del controlador y así poder seleccionar aquellas que ofrecieran el mejor desempeño. En este contexto, cada individuo representa una propuesta completa de parámetros; por ejemplo, en el controlador con función tanh y ganancia fija, se expresa como:

$$individuo = [\lambda, \varepsilon, K_1, K_2, K_3]$$

Los rangos de búsqueda de cada parámetro se definieron de manera que las soluciones encontradas mantuvieran la estabilidad y fueran físicamente realizables.

Para medir el desempeño, se definió una función de aptitud J (ecuación 4.10 que pondera tres aspectos: (1) qué tan bien el sistema sigue el setpoint (medido con el error cuadrático), (2) el esfuerzo que exige al actuador y (3) la suavidad de la señal de control.

Con los pesos $w_1 = 0.1$ y $w_2 = 0.3$, el AG buscó automáticamente el conjunto de parámetros que mejor equilibra estos objetivos: primero, mantener un seguimiento preciso del setpoint; luego, evitar esfuerzos excesivos del actuador; y, por último, reducir al mínimo las vibraciones o “saltos” en la señal de control.

$$J = ISE + w_1 \cdot \text{Esfuerzo de control} + w_2 \cdot \text{Chattering} \quad (4.10)$$

donde:

- $ISE = \int e(t)^2 dt$, con $e(t) = H_{2, \text{setpoint}} - H_{2, \text{medido}}$, mide el seguimiento del setpoint
- $\text{Esfuerzo de control} = \int (Q(t) - Q_{eq}(t))^2 dt$ penaliza la separación del caudal equivalente por zona
- $\text{Chattering} = \int (dQ/dt)^2$, penaliza variaciones rápidas en la señal de control

4.6.1 Configuración del Algoritmo:

El AG se configuró con los siguientes operadores y parámetros principales:

- Población: 100 individuos.
- Generaciones: 100 iteraciones.
- Selección: Selección por torneo (tournamentsize=3).
- Cruce: Cruce por mezcla (cxB1end con $\alpha=0.5$) con una probabilidad de 0.7.
- Mutación: Mutación gaussiana acotada (mutBoundedGaussian con $\sigma=0.2$) con una probabilidad de 0.3.

Esta misma configuración se ejecutó por separado para cada una de las cuatro leyes de control, de modo que cada una quedara sintonizada según sus propias características.

4.7 Contrucción de escenarios individuales y combinados

Para comprobar qué tan confiables son los controladores, se estableció un conjunto de casos de prueba que imitan problemas reales que pueden ocurrir en un biorreactor de hidrógeno. La idea fue poner a los controladores en situaciones difíciles y evaluar la respuesta, tanto

con perturbaciones únicas (escenarios individuales) como con varias a la vez (escenarios combinados).

4.7.1 Modelo de referencia

El modelo original de Aceves-Lara et al., 2008 de la fermentación anaerobia describe el proceso con 9 variables y 23 parámetros. Para simplificar, se dividieron esos parámetros en dos grupos:

- Constantes físicas (por ejemplo, la constante de los gases, las masas moleculares y los volúmenes del reactor y de la fase gas), porque son propiedades fijas del sistema.
- Parámetros que sí pueden variar en la operación diaria.

Además, se fijó una meta de producción de hidrógeno (setpoint) de 0.9289 mol/L, que proviene del mejor valor encontrado en una etapa previa de optimización.

4.7.2 Escenarios individuales

Se eligieron 17 parámetros que en la vida real suelen variar por cambios en materias primas, condiciones ambientales, desgaste de equipos o variaciones del proceso, dichos parámetros se agruparon dentro de cinco categorías y se etiquetaron como P1 a P17 para facilitar la identificación en el tratamiento posterior de los resultados, los parámetros son:

Parámetros de alimentación (P1-P4):

- P1 - Degradación de glucosa: 0.2 % por día, para reflejar la degradación natural del sustrato.
- P2 - Concentración de glucosa: ± 20 % respecto al valor nominal para simular variaciones en concentración de glucosa.
- P3, P4 - Caudal de alimentación: cambios tipo escalón (± 20 %) y oscilaciones sinusoidales (± 20 %), para simular fallos en la bomba de alimentación.

Parámetros Cinéticos (P5-P9):

- P5, P6 - Tasas máximas de absorción (μ_1, μ_2): Variaciones de $\pm 10\%$ y $\pm 20\%$ representando cambios en la actividad de los microorganismos.
- P7 -Constante de semisaturación (K_1): $\pm 20\%$, para cambios en la afinidad por el sustrato.
- P8, P9 - Coeficientes de transferencia de masa ($KLh_2, KLco_2$): $\pm 20\%$, para condiciones de mezcla o intercambio gas-líquido más favorables o más difíciles.

Parámetros Ambientales (P10-P13):

- P0 - Temperatura del reactor (T_{reac}): ± 2 K, causado por pequeñas variaciones del control térmico.
- P11 - Temperatura ambiente (T_{amb}): $10-30^\circ\text{C}$, para imitar cambios de temperatura a lo largo de la estación.
- P12 - Presión atmosférica (P_{atm}): ± 0.04 bar, modelando fluctuaciones barométricas asociadas a cambios ambientales.
- P13 - Presión de vapor (P_{vap}): $\pm 10\%$, representando cambios en condiciones de equilibrio de la fase gaseosa dentro del reactor.

Parámetros de Fugas (P14-P16):

- P14, P15 - Fuga de CO_2 e H_2 : $0-10\%$, para simular pérdidas que podrían ocurrir por conexiones deficientes o sellos mal colocados.
- P16 - Inhibición de reacción: $\pm 10\%$, modelando efectos de subproductos tóxicos

Parámetros de Ruido (P17):

- P17 - Ruido en sensor de H_2 : Se introdujo un ruido gaussiano del $\pm 2\%$ en el sensor de H_2 , reflejando la inexactitud normal de las mediciones.

4.7.3 Escenarios combinados

Para poder aproximarse a lo que pasa en la vida real, los controladores se probaron en situaciones donde ocurren varias perturbaciones al mismo tiempo. Se eligieron estas combinaciones basadas en cómo suelen relacionarse los parámetros entre sí y en lo que se reporta en plantas de fermentación anaerobia.

Escenarios de alimentación (E1-E2)

- E1: Degradación de glucosa 0.2 % diario + Concentración de glucosa inicial +20 % del óptimo. Simula: un sustrato fresco, con la concentración de glucosa óptima al inicio, que se va degradando poco a poco durante el proceso.
- E2: Degradación de glucosa 0.2 % diario + Concentración de glucosa inicial -20 % del valor óptimo. Simula: un sustrato de menor calidad (o ya algo degradado antes de empezar), con menos glucosa disponible de entrada.

Escenarios cinéticos (E3-E7)

- E3: Tasa máxima μ_1 +10 % + Semisaturación K_1 -20 % + Inhibición oscilante 5 % en reacción 1. Simula: condiciones favorables para crecer (más capacidad y más afinidad por el sustrato), pero con oscilaciones de inhibición.
- E4: Tasa máxima μ_1 -10 % + Semisaturación K_1 -20 % + Inhibición oscilante 5 % en reacción 1. Simula: microorganismos bajo estrés (menos capacidad) aunque con buena afinidad, y además con inhibición periódica.
- E5: Tasa máxima μ_1 -10 % + μ_2 -20 % + Inhibición oscilante 5 % en reacción 1. Simula: un escenario adverso, con caída general de la actividad microbiana.
- E6: Tasa máxima μ_1 -10 % + μ_2 +20 % + Inhibición oscilante 5 % en reacción 1. Simula: rutas metabólicas que reaccionan distinto (una empeora, otra mejora) frente a las perturbaciones del entorno.
- E7: Tasa máxima μ_1 +10 % + Semisaturación K_1 -20 % + Inhibición oscilante 10 % en

reacción 1. Simula: un “peor caso” por la combinación de alta exigencia e inhibición más fuerte.

- E8: Tasa máxima μ_1 -10 % + Semisaturación K_1 +20 % + Inhibición oscilante 5 % en reacción 1. Simula: microorganismos estresados (menos capacidad y menor afinidad) que, aun así, mantienen algo de actividad.

Escenarios de fugas (E9)

- E10: Fuga CO_2 10 % + Fuga H_2 10 % + Reducción coeficientes transferencia masa CO_2 y H_2 en 20 %. Simula: pérdida de gases y isminución de intercambio gas-líquido, frecuente en equipos con gran deterioro o con sellos deficientes.

Escenarios de ruido (E10-E12)

- E10: Ruido sensor $\text{H}_2 \pm 2\%$ + Caudal rampa descendente simulando falla progresiva de bomba. Simula: mediciones imprecisas justo cuando la alimentación va cayendo poco a poco por problemas mecánicos.
- E11: Ruido sensor $\text{H}_2 \pm 2\%$ + Caudal rampa ascendente. Simula: mediciones imprecisas junto con una sobrealimentación gradual del sistema.
- E12: Ruido sensor $\text{H}_2 \pm 2\%$ + Caudal con perturbaciones escalón +20 % y -20 %. Simula: señales de medición con ruido mientras la operación sufre cambios bruscos en las condiciones de proceso.

Con estos casos, se probaron los controladores primero con cada perturbación por separado y, después, combinando varias a la vez. Así fue posible evaluar de forma ordenada y realista, qué tan bien mantienen la producción cerca de la meta, cuánto esfuerzo de control se necesita y qué tanto se evitan los saltos u oscilaciones indeseadas en la señal de control.

4.7.4 Denificación de las perturbaciones

Para imitar de forma sencilla y realista lo que pasa en planta cuando se presentan cambios, se usaron tres tipos de señales. Cada una representa un patrón típico de cómo se mueven las

variables en el tiempo:

Escalón: sirven para cambios bruscos e inmediatos, como si una bomba fallara de repente, cambiara al instante la composición de la alimentación o se encendiera/apagara un equipo auxiliar. Para este trabajo, ese salto fue de +20 % o - 20 % respecto al valor nominal.

Rampa: representan cambios graduales, por ejemplo, el desgaste progresivo de un equipo, variaciones de temporada en el ambiente o ajustes controlados de operación. La variable sube o baja a una velocidad constante durante la simulación.

Sinusoidal: muchos procesos presentan oscilaciones periódicas de forma natural, ya sea por los ciclos día/noche de temperatura o pequeñas variaciones de energía eléctrica. Estas perturbaciones se plantearon como una sola señal de sólo un ciclo a lo largo de los 100 días de simulación, para observar cómo responde el controlador tanto cuando la perturbación sube como cuando baja.

4.8 Configuración de las Simulaciones

Después de ajustar cada controlador con sus mejores parámetros (ver sección 4.6), fueron puestos a prueba en distintas condiciones de operación para comprobar qué tan bien funcionan ante perturbaciones y cambios en el proceso.

4.8.1 Plataforma de simulación

Para que todo fuera consistente y fácil de repetir, se trabajó con cuatro scripts en Python, uno por cada controlador. Todos con la misma estructura, solo cambiando la ley de control: tangente hiperbólica con ganancia fija, tangente hiperbólica con ganancia adaptativa, saturación con ganancia fija y saturación con ganancia adaptativa.

Cada script incluye los siguientes componentes:

- Librerías para cálculo y manejo de datos: NumPy y SciPy (simulación numérica) y Pandas (procesamiento de datos).

- Parámetros del controlador: se cargan los valores óptimos obtenidos en la sintonización.
- Formulación del modelo matemático del proceso de producción de hidrógeno
- Modelo del proceso: el modelo matemático de la producción de hidrógeno.
- Ley de control: la lógica específica de cada controlador.
- Ejecución y guardado: se corre la simulación y se almacenan los resultados de forma ordenada.

Trabajar de forma modular permite cambiar o revisar un controlador sin modificar el resto y garantiza que todas las comparaciones se hagan bajo exactamente las mismas condiciones.

4.8.2 Condiciones de simulación estandarizadas

Para que la comparación entre controladores fuera justa y consistente, todas las pruebas se realizaron bajo las mismas condiciones de simulación.

Parámetros de referencia

El punto de operación se mantuvo en 0.9289 mol/L de hidrógeno, valor que se identificó previamente como el óptimo durante la etapa de optimización.

Cada experimento se corrió durante 100 pasos de tiempo discretos, lo suficiente para observar no solo la etapa transitoria, sino también el comportamiento estable del sistema. El paso de integración fue de una unidad, lo que dio la resolución necesaria para seguir la dinámica sin perder detalle.

Configuración numérica

Cada controlador comenzó desde las mismas condiciones iniciales para poder asegurar la igualdad en las comparaciones.

Para la integración numérica se eligió la función `solve_ivp` de SciPy, ya que ofrece resultados confiables y se adapta bien a las características de este tipo de simulaciones.

4.8.3 Protocolo de Simulación diferenciado

Debido a que algunas perturbaciones incluyen azar, se adaptó el protocolo según el tipo de prueba.

Casos Determinísticos

Cuando no hay componentes aleatorias (ruido como perturbación), se ejecutó una sola simulación por cada combinación caso–controlador. Al ser un comportamiento reproducible, no hacen falta réplicas para caracterizarlo

Casos Estocásticos

Cuando hay simulación de ruido gaussiano en el "sensor detector de hidrógeno gaseoso". Para este caso se realizaron 30 simulaciones por combinación caso–controlador. Con este número de simulaciones es posible capturar la variabilidad propia del ruido y de poder estimar métricas con solidez estadística para finalmente aplicar inferencia estadística con potencia suficiente

4.8.4 Gestión de Parámetros

Los cambios de parámetros se aplicaron manualmente, de forma controlada, en cada *script* antes de correr las simulaciones. Aunque exige más intervención, garantiza comparaciones consistentes entre controladores dentro de un mismo escenario y facilita la trazabilidad de todos los ensayos.

4.8.5 Métricas de Evaluación del Desempeño

Se eligieron métricas alineadas con el tipo de perturbaciones y los objetivos de control. En lugar de ISE y esfuerzo de control, se empleó Error en estado estacionario (ESS) y Amplitud máxima del error. La justificación es que el conjunto de pruebas considera señales distintas al escalón (como senoidales, rampas y ruido), en las cuales las métricas tradicionales pueden resultar menos claras. En estos casos, el ESS y la amplitud máxima ofrecen una representación más adecuada de la precisión en el seguimiento y de la estabilidad del sistema.

4.8.5.1 Definiciones matemáticas

Error en Estado Estacionario (ESS): Cuantifica la precisión promedio del controlador en el seguimiento del setpoint durante ventanas temporales específicas:

$$ESS = \frac{1}{n} \sum_{t_{inicio}}^{t_{final}} |H_{2,set\ point} - H_{2,simulado}(i)| \quad (4.11)$$

Amplitud máxima: Mide la desviación máxima de la variable controlada respecto al setpoint en intervalos definidos:

$$Amplitud = \max_{t \in [t_{inicio}, t_{fin}]} |H_{2,set\ point} - H_{2,simulado}(i)| \quad (4.12)$$

Índice de Chattering: Cuantifica la actividad de conmutación de la señal de control a lo largo de toda la simulación:

$$Chattering = \int_0^T \left(\frac{dQ}{dt} \right)^2 dt \quad (4.13)$$

4.8.6 Tasa de éxito del controlador

Además de las métricas de error continuo (ESS, Amplitud) y de esfuerzo de control (*Chattering*), se estableció un criterio de desempeño para tener una evaluación de fiabilidad operativa. Este enfoque permite cuantificar de manera la capacidad de cada estrategia de control de mantener el bioproceso dentro de un rango de operación deseable y seguro, lo cual es de máxima relevancia para aplicaciones industriales.

Para cada escenario de perturbación determinístico, se define un caso de éxito como aquella simulación en la que un controlador demuestra la capacidad de mantener la variable de proceso (producción de hidrógeno) dentro de una banda de tolerancia predefinida del $\pm 5\%$ con respecto al valor de referencia o setpoint (0.9289 mol/L). Esta condición debe cumplirse durante la ventana temporal de estado estacionario definida para cada tipo de perturbación.

Desviaciones mayores podrían indicar una respuesta subóptima del controlador, con el riesgo de comprometer la eficiencia metabólica del cultivo microbiano.

La tasa de éxito se define como el porcentaje de casos en lo que el controlador cumplió satisfactoriamente el criterio definido:

$$Tasa\ de\ exito\ (\%) = \left(\frac{Num\ de\ casos\ de\ xito}{Numero\ total\ de\ casos\ evaluados} \right) \times 100\% \quad (4.14)$$

Este análisis se realizó en dos niveles para permitir una evaluación completa de la robustez:

1. Análisis global: Se calculó una tasa de éxito general para cada controlador considerando la totalidad de los 25 escenarios de prueba, ofreciendo una medida de su fiabilidad general.
2. Análisis por categoría: La tasa de éxito se calculó por cada una de las cuatro categorías de perturbación (Alimentación, Cinéticos, Ambientales y Fugas).

Una vez identificados los escenarios de éxito de cada controlador, se realizó un análisis estadístico descriptivo condicional. El objetivo es caracterizar el comportamiento operativo de los controladores únicamente cuando están cumpliendo con su objetivo principal (mantener el proceso dentro del rango $\pm 5\%$). Sobre este conjunto de datos es que se calcularon: Media, Mediana y Desviación Estándar para las métricas de Amplitud Máxima del Error y el Índice de *Chattering*: Al centrar el análisis en los casos de éxito es posible analizar cómo es que los controladores alcanzan el objetivo de control.

4.8.7 Ventanas de evaluación adaptadas

Para que las métricas reflejen de forma justa el comportamiento bajo cada tipo de perturbación, se calcularon en intervalos de tiempo definidos a la medida de su dinámica. La Tabla 1 muestra los intervalos tomados para cada métrica.

Tabla 1: Ventanas de evaluación empleadas para cada tipo de perturbación

Tipo de perturbación	ESS	Amplitud máxima
Sinusoidal	0–50 y 51–100 (promedio)	0–50 y 51–100 (promedio)
Rampa	90–100	1–100
Ruido	80–100	1–100
Escalón	26–50 y 76–100 (promedio)	26–50 y 76–100 (promedio)

Perturbaciones sinusoidales: se decidió dividir en dos mitades el horizonte de tiempo (0-50 y 51-100) ya que este tipo de perturbaciones presentan un solo ciclo, por lo que en la ventana 0-50 se tienen los valores arriba del valor nominal (desviaciones positivas) y en la ventana de 51-100 se encuentran los valores menores al valor nominal (desviaciones negativas). Al promediarlas, se obtiene una evaluación más equilibrada del desempeño del controlador a lo largo de todo el ciclo.

Perturbaciones tipo rampa: ESS se tomó en el rango de 90-100 porque es cuando el sistema enfrenta el cambio más pronunciado y se ve mejor la precisión de seguimiento al final de la rampa. La amplitud máxima se evalúa de 1-100 ya que un pico puede aparecer en cualquier momento, especialmente al inicio mientras el controlador se adapta al cambio progresivo.

Escenarios con ruido: ESS en 80-100 para medir el desempeño una vez superados los transitorios y cuando el sistema se comporta de forma estadísticamente estacionaria. De igual manera, la amplitud máxima va de 1-100 porque los picos inducidos por el ruido pueden surgir en cualquier instante, independientemente del estado del sistema.

Perturbaciones tipo escalón: se evaluaron las ventanas en 26-50 y 76-100, ya que es en donde ocurren los cambios, los 25 instantes a las perturbaciones el sistema se mantiene en su funcionamiento nominal.

4.8.8 Gestión y almacenamiento de datos

Se realizó un registro de distintos valores de salida para cada simulación para más adelante analizar el comportamiento de los controladores bajo cada escenario individual y combinado bajo los cuales fueron evaluados. Para ello se diseñó un esquema doble: por un lado, se guardaron las variables que cambian con el tiempo, y por otro, se calcularon métricas que permiten resumir el desempeño de manera más clara.

En la primera parte del registro se almacenaron datos básicos pero fundamentales: el tiempo, representado como un vector discreto de 0 a 100; el caudal controlado (Q), es decir, la señal que el controlador aplicaba en cada instante; la cantidad de hidrógeno producido (H_2) como variable de salida del sistema; y dos formas de medir la diferencia con respecto al objetivo: el error instantáneo (la diferencia directa entre el setpoint y el valor simulado) y el error absoluto (la magnitud de esa desviación, sin importar el signo).

La segunda parte se centró en métricas que condensan el desempeño. Entre ellas, el ESS, calculado dentro de la ventana temporal correspondiente a cada tipo de perturbación; la amplitud máxima, evaluada en el intervalo específico definido según la naturaleza de la perturbación; y el índice de chattering, que se midió a lo largo de toda la simulación para tener una idea del esfuerzo de control requerido.

Dicho esquema de almacenamiento permitió no solo garantizar que las simulaciones pudieran repetirse bajo las mismas condiciones, sino también contar con una base sólida para más adelante realizar un análisis estadístico completo y confiable de los resultados.

4.9 Evaluación de robustez para casos determinísticos

Para analizar cómo se comportan los cuatro controladores propuestos frente a distintas perturbaciones, fue necesario organizar el estudio en dos grandes bloques: escenarios determinísticos (sin ruido) y escenarios estocásticos (con ruido), ya que cada uno requiere su propio enfoque de análisis por la naturaleza de las perturbaciones.

4.9.1 Identificación de patrones de similitud

4.9.1.1 Identificación visual

El trabajo comenzó con una revisión visual de las respuestas temporales de las simulaciones, ya que al observar las curvas de producción de hidrógeno y el caudal de entrada, se detectaron algunos patrones en el desempeño de los controladores: en algunos escenarios, varios controladores reaccionaban de forma muy similar y tendían a agruparse; en otros, en cambio, destacaba un controlador con una respuesta claramente distinta al resto. Esta lectura inicial sirvió para orientar y priorizar los análisis cuantitativos posteriores.

A partir de esta inspección visual fue posible los patrones de comportamiento. Este primer acercamiento fue clave para orientar los análisis cuantitativos posteriores y priorizar los escenarios que requerían un estudio más detallado.

4.9.1.2 Clasificación mediante reglas estadísticas

Para pasar de una impresión cualitativa a una medición objetiva de la similitud entre controladores, se comenzó por acondicionar las métricas de desempeño. Dado que el índice de chattering presentó una dispersión muy alta (con valores extremos), se aplicó una transformación logarítmica natural que estabiliza su escala y evita que unos pocos valores atípicos dominen los cálculos. Sobre las tres métricas, se utilizó una normalización robusta (mediana y rango intercuartílico) en lugar del escalado estándar; así cada métrica aporta de forma equilibrada al análisis aun en presencia de valores extremos.

Con las métricas ya normalizadas, se cuantificó la semejanza entre controladores mediante distancias Manhattan. Esta elección es menos sensible a outliers que la distancia euclidiana y reduce el riesgo de que una sola métrica altere el resultado. En términos prácticos, la distancia entre dos controladores se calcula como la suma de las diferencias absolutas en cada una de las tres métricas.

Las reglas de clasificación son las siguientes:

- **Pareja:** si se cumplen simultáneamente dos condiciones que indican la existencia de un

par de controladores muy similares y claramente separados del resto

$$d_{min} \leq 0.25 \cdot d_{mediana} \text{ y } d_{2,min} \geq 4 \cdot d_{min}$$

- **Subgrupo:** si se cumplen las siguientes condiciones, las cuales sugieren la formación de un grupo de tres o más controladores con un grado de similitud notable

$$d_{min} \leq 0.45 \cdot d_{mediana} \text{ y } d_{2,min} \leq 0.8 \cdot d_{mediana}$$

- **Diferenciados:** si todos los controladores exhiben comportamientos distintos entre sí, cumpliendo la condición de que incluso la distancia mínima es significativamente alta en relación con la dispersión típica

$$d_{min} > 0.6 \cdot d_{mediana}$$

Ambiguo: Cualquier caso que no satisfaga de forma clara ninguna de las reglas anteriores

Los casos marcados como ambiguos se revisaron con dendrogramas obtenidos por clustering jerárquico (*average linkage*). Esta capa de validación permitió esclarecer la estructura de similitud y decidir, con un criterio cuantitativo, la existencia de grupos de similitud. Para ello, se realizaron cortes en los percentiles P25 y P50 de la distribución de distancias para cada uno de los casos, dichos diagramas fueron interpretados de la siguiente manera: por debajo de P25 se establece la presencia de agrupamientos fuertes; entre P25 y P50 se consideraron como similitudes moderadas, habituales en parejas o tríos no tan unidos, y, encima de P50 se asumió una diferenciación clara, propia de controladores aislados.

En conjunto, este procedimiento encadena preprocesamiento robusto, una métrica de distancia apropiada y reglas interpretables, y lo refuerza con una validación jerárquica guiada por percentiles.

4.9.2 Evaluación de Representante vs C4

De la clasificación de los casos por grados de similitud obtenida, se determinó que la mayoría de casos pertenecen a la clasificación de Sugbrupo, por lo tanto, el análisis se centró en

analizar las diferencias entre el conjunto de controladores C1–C2–C3 y el controlador C4. Para ello, se excluyeron los casos que, por su clasificación previa, correspondían a agrupamientos completos o a comportamientos claramente diferenciados.

En cada escenario considerado se determinó un “representante” del grupo C1–C2–C3. El procedimiento consistió en calcular un puntaje compuesto por controlador como promedio de las métricas normalizadas (ESS, Amplitud Chattering), y seleccionar después como representante aquel cuyo puntaje quedó más próximo a la media aritmética del grupo en ese escenario.

Antes de pasar a las comparaciones, se verificaron los supuestos estadísticos, para ello se evaluó la normalidad mediante la prueba de Shapiro–Wilk para cada métrica en ambos grupos y, en paralelo, se contrastó la igualdad de varianzas con la prueba de Levene. Con base en estos resultados, la elección de pruebas siguió un protocolo estándar: cuando se cumplieron normalidad y homocedasticidad se aplicó la prueba t de Student para muestras independientes; en caso contrario, se recurrió a la prueba no paramétrica U de Mann–Whitney. En todos los contrastes se mantuvo un nivel de significancia de $\alpha = 0.05$. Adicionalmente, se calculó el coeficiente r de Cohen para estimar el tamaño del efecto y valorar la relevancia práctica de las diferencias observadas.

4.9.3 Casos especiales

4.9.3.1 Casos diferenciados

Para los casos en donde los cuatro controladores mostraron un comportamiento diferenciado el análisis se enfocó en cuantificar la variabilidad entre controladores, acotar rangos de desempeño y contrastar criterios de excelencia técnica (capacidad de mantener el |ESS| y la amplitud del error por debajo del 5 % del setpoint).

En primera instancia, se realizó un análisis estadístico descriptivo por combinación controlador–caso. Tomando las tres métricas de desempeño se calcularon medidas de tendencia central (media y mediana) y de dispersión (desviación estándar, mínimos y máximos). Este resumen permitió capturar tanto el comportamiento típico de cada controlador como la amplitud de sus

fluctuaciones frente a la perturbación específica.

Con el fin de comparar la consistencia relativa entre métricas con escalas y unidades distintas, se calculó el coeficiente de variación ($CV = \lambda/\mu \times 100$). Se interpretó $CV \leq 15\%$ como variabilidad baja, entre $15\text{--}35\%$ como moderada y $> 35\%$ como alta. Dicha métrica resultó determinante para identificar controladores con desempeño inestable y así valorar la confiabilidad de las mediciones en los distintos escenarios.

Además, se determinaron los valores mínimo y máximo por métrica, controlador y caso, a partir de los cuales se obtuvieron rangos absolutos; cuando el número de observaciones lo permitió, se complementó con el rango intercuartílico para evaluar la dispersión central. Este análisis de rangos ayudó a distinguir los controladores más estables y menos sensibles.

Una vez establecido el desempeño fue posible elaborar un ranking para contar comparación relativa entre controladores, donde valores menores indicaron mejor desempeño (Ranking 1) y valores mayores el peor (Ranking 4). En presencia de empates se asignaron rangos promediados para poder garantizar una comparación equitativa.

Finalmente, se establecieron umbrales definidos mediante criterios de: “Excelente”, “Aceptable” o “Deficiente”. Los criterios incluyeron un error en estado estacionario $\leq 5\%$ del setpoint, una amplitud máxima dentro de límites operacionales seguros y valores de chattering suficientemente bajos para no comprometer la vida útil de los actuadores. Con ello se estableció no solo qué controlador se comportó mejor en términos relativos, sino también si alcanzó niveles de desempeño adecuados desde el punto de vista técnico.

4.9.3.2 Casos agrupados

Para los casos clasificados como agrupados, la convergencia de las respuestas entre los cuatro controladores exigió otro tratamiento. Para estos casos el análisis se orientó a confirmar la convergencia mediante: el índice de correlación intraclass (ICC), y las distancias entre respuestas.

Para cuantificar la similitud se calcularon distancias Manhattan directamente sobre las métricas originales, sin normalización previa. Esta decisión respondió a que, en estos escenarios, las

escalas de las métricas fueron comparables y las diferencias entre controladores resultaron muy pequeñas.

Además, se evaluó el grado de semejanza con el ICC a partir de un modelo de análisis de varianza de un factor. En términos operativos, se descompuso la variabilidad total en tres componentes: la suma de cuadrados total, que recogió la variación de todas las observaciones respecto de la gran media; la suma de cuadrados entre grupos, que capturó las diferencias atribuibles a los controladores; y la suma de cuadrados dentro de grupos, que midió la variación residual dentro de cada controlador.

4.10 Evaluación de robustez para casos estocásticos

4.10.1 Configuración Experimental

Para evaluar los controladores en condiciones realistas de operación, se introdujo ruido gaussiano de $\pm 2\%$ únicamente en la simulación del 'sensor de hidrógeno gaseoso' para los casos de esta categoría. Esta perturbación replicó las inexactitudes habituales de la instrumentación industrial y fijó un escenario operativo que los controladores debían gestionar de forma eficaz. El protocolo consistió en ejecutar 30 simulaciones independientes por cada combinación caso-controlador, lo que produjo 480 corridas en total ($4 \text{ casos} \times 4 \text{ controladores} \times 30 \text{ réplicas}$). Las simulaciones recurrieron a la generación intrínseca de números aleatorios del sistema y no se fijaron semillas específicas.

4.10.2 Análisis de confiabilidad por Coeficiente de Variación

Como primera lectura de la estabilidad, se clasificó la confiabilidad de cada métrica a partir del coeficiente de variación (CV %) calculado sobre las 30 réplicas por combinación. Se interpretaron $CV \leq 15\%$ como alta confiabilidad (comportamiento consistente), valores entre 15% y 25% como confiabilidad moderada y $CV > 25\%$ como confiabilidad baja, indicativa de alta sensibilidad al ruido.

4.10.3 Verificación de supuestos estadísticos

Antes de seleccionar los contrastes, se evaluaron los supuestos sobre los datos brutos (las 30 simulaciones por combinación). La normalidad se comprobó con la prueba de Shapiro–Wilk ($\alpha = 0.05$) aplicada a cada métrica por caso y controlador. En paralelo, la homocedasticidad se examinó con la prueba de Levene para comparar la igualdad de varianzas entre los cuatro controladores por métrica y caso.

4.10.3.1 Estrategia de Análisis Estadístico

A partir de la combinación de resultados de normalidad y homocedasticidad, se adoptó una estrategia escalonada. Cuando se cumplieron ambos supuestos se aplicó un ANOVA de una vía con comparaciones post-hoc de Tukey; si se cumplió la normalidad pero no la homocedasticidad se recurrió al ANOVA de Welch con post-hoc de Games–Howell; y, en presencia de no normalidad, se utilizó la prueba de Kruskal–Wallis (independiente del supuesto de varianzas) con comparaciones post-hoc de Dunn. En todos los casos se mantuvo un nivel de significancia de $\alpha = 0.05$.

4.10.3.2 Análisis de Rankings y Desempeño Global

Para cada métrica y caso, se ordenó a los controladores asignando rangos de 1 (mejor desempeño) a 4 (peor), promediando en situaciones de empate. Con dichos rangos posteriormente se calculó un puntaje promedio global por controlador y por métrica para poder identificar patrones de desempeño consistentes a través de los escenarios estocásticos. Este esquema sintetizó de forma compacta la comparación entre controladores y facilitó la lectura de fortalezas y debilidades bajo ruido.

CAPÍTULO 5: RESULTADOS

5.1 Validación de la migración del modelo

Para comprobar que la traducción del modelo original a Python conservara el mismo comportamiento, se ejecutaron simulaciones en ambos entornos bajo las mismas condiciones operativas (alimentación de glucosa fija en 20 g/L y una dilución equivalente a 1 d^{-1}). Las Figuras 1 y 2 recogen la evolución temporal de la producción de hidrógeno en MATLAB/Simulink (modelo original) y en Python (modelo migrado), respectivamente.

En ambas figuras se observa que tanto en MATLAB como en Python se alcanza un estado estacionario cercano a 0.3 mol/L de H_2 en menos de un día. La diferencia aparece en el arranque: el modelo original en MATLAB exhibe un pico inicial pronunciado, con un sobreimpulso de aproximadamente 3.74 mol/L antes de estabilizarse, mientras que la versión en Python asciende de forma gradual y continua hasta el valor final, sin generar sobreimpulso.

5.1.1 Explicación de las diferencias

Estas discrepancias se entendieron a la luz de cómo cada entorno resolvió las EDO y trató las entradas.

1. **Precisión y tolerancias del integrador.** En la migración a Python las tolerancias se fijaron en $\text{rtol} = 1\text{e-}6$ y $\text{atol} = 1\text{e-}9$, mientras que en Simulink se utilizaron tolerancias automáticas por defecto, más orientadas a mejorar la precisión y disminuir el coste computacional. Se piensa que esta elección de tolerancias más severas en Python favoreció una integración más “suave” del transitorio.
2. **Representación de las entradas.** En Simulink las señales de entrada pueden aplicarse como cambios instantáneos (escalones), lo que acentúa picos o sobreimpulsos al inicio; en Python, en cambio, las entradas de dilución y de glucosa se implementaron como funciones interpoladas de tiempo $D(t)$ y $\text{Glu_in}(t)$, introduciendo transiciones graduales más acordes con el comportamiento físico del proceso y mitigando el sobreimpulso numérico.




Figura 1: Producción de hidrógeno con el modelo original (MATLAB)

. Fuente: Elaboración propia con base en Aceves-Lara et al., 2008.




Figura 2: Producción de hidrógeno con el modelo migrado a Python

3. **Algoritmos de integración.** Mientras que MATLAB/Simulink recurre a integradores automáticos de paso adaptativo (p. ej., variantes de Runge–Kutta) para equilibrar precisión y eficiencia, la implementación en Python utilizó la función `odeint` de SciPy (que llama al algoritmo LSODA) para resolver las 9 EDO del sistema, lo que facilitó una conmutación robusta entre métodos explícitos e implícitos en función de la rigidez local del problema.

5.1.2 Validación cuantitativa

Para respaldar la comparación cualitativa, se tomaron lecturas de la producción de hidrógeno en estado estacionario en distintos instantes. La Tabla 2 muestra que las diferencias relativas entre MATLAB y Python fueron inferiores al 0.1 % en todos los puntos analizados, estos resultados indicaron que la migración preservó las propiedades clave del modelo original (valor estacionario, forma de la respuesta y tiempos de asentamiento), y las diferencias en el transitorio inicial respondieron a decisiones de configuración numérica (tolerancias) y de representación de entradas (interpolación vs escalón) adoptadas en la implementación en Python.

Tabla 2: Comparación cuantitativa de los modelos (MATLAB y Python)

Tiempo (d)	MATLAB	Python	Diferencia (%)
20	0.3102	0.3101	0.03
40	0.3102	0.3101	0.03
60	0.3102	0.3101	0.03
80	0.3102	0.3101	0.03
100	0.3102	0.3101	0.03

5.2 Análisis de sensibilidad

Una vez validada la migración del modelo, se exploró sistemáticamente cómo responden las salidas del proceso frente a cambios en las dos entradas clave: la concentración de glucosa en

el afluente (10–20 g/L) y el caudal de alimentación (2–8 L/d), con el objetivo de identificar regiones operativas favorables para la producción de hidrógeno y delimitar zonas de riesgo operacional.

5.2.1 Diagrama de calor

La Figura 3 resume esta exploración mediante un diagrama de calor que representa la superficie de respuesta de H_2 en función de ambas entradas, evidenciando un comportamiento marcadamente no lineal del biorreactor. Esta visualización permitió ubicar, de un vistazo, los rangos aproximados de caudal y sustrato que maximizan la producción, así como aquellas que la comprometen.




Figura 3: Producción de hidrógeno en función del caudal y concentración de glucosa

A partir del mapa se distinguen tres zonas principales:

Zona I: con caudales muy bajos se observa la menor producción de hidrógeno; en este dominio, al ir incrementando el caudal desde valores muy bajos la respuesta mejora de manera gradual, coherente con la dinámica de arranque y la mayor disponibilidad efectiva de sustrato

en el volumen útil.

Zona II: asociada a concentraciones elevadas de glucosa ($\approx 17\text{--}20$ g/L) y caudales intermedios ($\approx 3\text{--}6$ L/d), donde el balance entre disponibilidad de sustrato y tiempo de residencia favorece la actividad fermentativa y, por tanto, la generación de H_2 ; este dominio incluye el óptimo previamente identificado en 20 g/L y ≈ 4.06 L/d, utilizado más adelante como referencia de control.

Zona III: para caudales elevados (>7 L/d) la producción cae de forma consistente, independientemente de la concentración de glucosa, por efecto de lavado; los tiempos de residencia demasiado cortos desestabilizan la biomasa activa y reducen la eficiencia global del proceso.

5.2.2 Optimización de variables

Contando con una visualización del comportamiento general del sistema se procedió ahora a realizar una optimización para obtener los valores óptimos de las variables de entrada dentro del rango establecido empleando el método L-BFGS-B de `scipy.optimize.minimize`, por lo que la función objetivo consistió en maximizar la producción de hidrógeno.

El proceso de optimización determinó las siguientes condiciones óptimas:

- Concentración óptima de glucosa: 20.00 g/L
- Caudal óptimo de entrada: 4.06 L/d
- Producción máxima de H_2 : 0.9289 mol/L

Los valores obtenidos fueron verificados mediante una simulación adicional programada en el código de optimización, lo que permitió confirmar la convergencia del algoritmo y la consistencia de los resultados.

5.3 Caracterización del comportamiento del sistema

5.3.1 Curva característica del sistema

La curva característica del sistema se muestra en la Figura 4, en donde se relaciona el caudal de alimentación con la producción de H_2 ; dicha gráfica se obtuvo manteniendo una concentración constante de glucosa en 20 g/L. La curva revela el comportamiento no lineal del biorreactor y proporciona información sobre las diferentes regiones operacionales.

A partir de la curva característica se pueden apreciar tres zonas, por lo que de manera visual se optó por establecer los puntos de transición entre dichas zonas. El primer punto se estableció en $t_1 = 2.8$ L/d, señalando el paso de una fase de crecimiento inicial casi lineal a una región de desaceleración. El segundo punto se colocó en $t_2 = 3.7$ L/d; alrededor de este punto es que se da la máxima de producción de H_2 y, partir de ese punto, la producción desciende de forma gradual por el efecto de lavado del reactor.




Figura 4: Curva característica y puntos de transición de la producción de H_2

5.4 Linealización por tramos

El siguiente paso consistió en obtener el conjunto de ecuaciones que relacionen de manera explícita la variable de control con el objetivo de control, para lograrlo se realizó una

aproximación por tramos de la curva característica obtenida anteriormente.

El ajuste convergió correctamente y arrojó las siguientes ecuaciones por zona:

- Zona 1:

$$H_2 = 0.32Q + 0.02$$

- Zona 2:

$$H_2 = 0.07Q + 0.69$$

- Zona 3:

$$H_2 = -0.01Q + 0.99$$

5.4.1 Caudales equivalentes para control

Siguiendo la metodología de la sección 4.4.3, se sustituyó el setpoint de producción ($H_{2,setpoint} = 0.9289$ mol/L) en cada ecuación y se despejó Q para obtener los puntos de operación de referencia por zona:

Zona 1 ($Q \leq 2.8$ L/d):

$$Q_{eq,1} = \frac{0.9289 - 0.02}{0.32} = 2.85 \text{ L/d}$$

Zona 2 ($2.8 < Q \leq 3.7$ L/d):

$$Q_{eq,2} = \frac{0.9289 - 0.69}{0.07} = 3.59 \text{ L/d}$$

Zona 3 ($Q > 3.7$ L/d):

$$Q_{eq,3} = \frac{0.9289 - 0.99}{0.01} = 4.27 \text{ L/d}$$

Estos caudales equivalentes sirven como referencias de operación para implementar los controladores por modos deslizantes, facilitando condiciones iniciales coherentes con cada región del modelo linealizado.

5.4.2 Validación visual

Al superponer el modelo linealizado por tramos sobre la curva característica original (ver Figura 5) se puede apreciar que ambas coinciden de manera satisfactoria en las tres zonas.




Figura 5: Zonas de operación linealizadas. Glucosa fija a 20 g/L

5.4.3 Validación cuantitativa

Para establecer de manera cuantitativa la calidad de la linealización del modelo, se aplicaron métricas estándar (R^2 , MSE y MAE) para cuantificar la calidad del ajuste por zona donde se obtuvieron los valores mostrados en la Tabla 3.

Tabla 3: Métricas de desempeño por zona.

Métrica	Zona 1	Zona 2	Zona 3
R^2	0.997	0.927	0.983
MSE	1.07×10^{-4}	2.4×10^{-5}	1.3×10^{-5}
MAE	0.018	0.004	0.003

Como era esperable, la Zona 2 (la más no lineal) presenta errores algo mayores, aunque dentro de márgenes satisfactorios. En las Zonas 1 y 3 la precisión es excelente y el comportamiento queda bien representado.

Evaluación global del modelo

El desempeño global confirma la validez de la aproximación por tramos:

- Coeficiente de determinación: $R_{Global}^2 = 0.999$
- Error cuadrático medio: $MSE_{Global} = 6 \times 10^{-5} \text{ mol/L}$
- Error absoluto medio: $MAE_{Global} = 0.005 \text{ mol/L}$

Un R^2 cercano a 1 y errores bajos (RMSE/MAE) indican que la linealización reproduce con fidelidad la variabilidad y el nivel de la curva original, por lo que resulta adecuada para el diseño y la sintonía de los controladores.

5.5 Sintonización de parámetros mediante AG

5.5.1 Parámetros Óptimos de los Controladores

Se sintonizaron los cuatro esquemas de control por modos deslizantes con un AG, buscando el mejor equilibrio entre precisión de seguimiento, esfuerzo de control y suavidad de la señal según la función de aptitud definida (ecuación 4.10). A continuación se presentan los conjuntos óptimos de parámetros para cada controlador:

Controlador C1 - Tangente hiperbólica con ganancias fijas

$$\lambda : 0.100; \quad \varepsilon = 1.000; \quad K_1 = 0.776; \quad K_2 = 0.500; \quad K_3 = 1.780$$

Un valor bajo de λ hace que las correcciones sean más suaves, aunque menos rápidas. A su vez, un ε grande aplana la curva de la función $\tanh$, lo que ayuda a evitar saltos bruscos en la señal de control. La ganancia presenta un incremento importante en la Zona 3, que es donde el sistema se vuelve más exigente y por lo tanto, se requiere de un control más firme.

Controlador C2 - Tangente hiperbólica con ganancia adaptativa

$$\lambda = 0.100; \quad \varepsilon = 0.500; \quad \alpha = 0.010; \quad K_{min} = 0.730; \quad K_{max} = 3.860$$

Presenta un comportamiento parecido al de C1 ya que tiene correcciones suaves, pero al tener un ε más pequeño se vuelve más sensible a las desviaciones. La ganancia se ajusta de forma dinámica gracias a α , que regula la rapidez de ese ajuste a un ritmo moderado. El amplio rango que se presenta entre K_{min} y K_{max} permite que el controlador sea más firme en situaciones críticas y más conservador cuando el sistema está estable, adaptándose según lo requiera la dinámica.

Controlador C3 - Saturación con ganancias fijas

$$\lambda : 0.500; \quad \phi = 0.500; \quad K_1 = 0.770; \quad K_2 = 0.100; \quad K_3 = 4.290$$

Es el controlador que tiene el valor de λ más alto, lo que refuerza el peso del componente integral y lo hace más sensible a errores persistentes. El parámetro ϕ define la zona lineal antes de saturar, lo que permite transiciones más suaves. Las ganancias varían bastante entre zonas (con K_2 muy baja y K_3 muy alta), reflejando que este esquema requiere un ajuste muy específico dependiendo de la región de operación.

Controlador C4 - Saturación con ganancia adaptativa

$$\lambda = 0.100; \quad \phi = 0.099; \quad \alpha = 0.001; \quad K_{min} = 0.209; \quad K_{max} = 1.117$$

Es el enfoque más conservador. El ϕ pequeño hace que las transiciones sean aún más suaves, y el valor de α , diez veces menor que en C2, reduce mucho la velocidad de adaptación. Esto significa que en este controlador se sacrifica la velocidad de respuesta para favorecer una mayor estabilidad. Además, este es el rango de ganancia más estrecho de todos, lo que impide que el controlador sea más agresivo.

5.5.2 Evaluación del desempeño de optimización

Tras la sintonización, las métricas de desempeño quedaron como se muestra en la Tabla 4. Se puede observar que los cuatro controladores convergieron a valores prácticamente idénticos de

ISE ($\approx 0.426-0.427$). Esto indica que, en términos de seguimiento al setpoint, el desempeño es equivalente y que las diferencias relevantes se explican por los otros dos componentes de la función objetivo: el esfuerzo de control y el chattering.

C2 obtuvo el mejor valor de la función objetivo ($J=0.430$): su combinación de ISE bajo con un chattering prácticamente nulo (0.001) lo posiciona como el compromiso más favorable entre precisión y suavidad, aunque a costa de un esfuerzo de control mayor que C1 (0.379 frente a 0.177).

C4 se ubicó en segundo lugar ($J=0.441$). Aun cuando su esfuerzo de control es el más alto (1.350), mantuvo un chattering bajo (0.008) y un ISE equivalente al resto, lo que sugiere una señal de control relativamente suave pero más exigente para el actuador.

C1 ($J=0.449$) destacó por el menor esfuerzo de control de todo el conjunto (0.177), con un chattering moderado (0.016).

C3 presentó el mayor valor de la función objetivo ($J=0.453$). Aunque su valor de ISE es prácticamente el mismo que los otros controladores, no aporta una ventaja clara ni en esfuerzo (0.213) ni en chattering (0.016) respecto a los demás, por lo que en el balance global es el que posee el desempeño más bajo.

Tabla 4: Resultados de desempeño de los controladores tras la optimización.

Controlador	ISE	Esfuerzo de control	Chattering	Función objetivo
C1	0.427	0.177	0.016	0.449
C2	0.426	0.379	0.001	0.430
C3	0.426	0.213	0.016	0.453
C4	0.426	1.350	0.008	0.441

5.6 Evaluación de robustez para casos determinísticos

5.6.1 Análisis de la tasa de éxito

5.6.1.1 ESS

La evaluación global (tomando los 25 escenarios determinísticos), reveló diferencias claras en la capacidad de cada controlador para garantizar una operación fiable (ver Tabla 5).

Tabla 5: Tasa de éxito global por controlador

Controlador	Casos de éxito	Porcentaje de éxito (%)
C1	14	56
C2	15	60
C3	17	68
C4	13	52

El controlador C3 se estableció como la estrategia más robusta en términos globales, con una tasa de éxito del 68 %. Los controladores C1 y C2 mostraron un desempeño competitivo (56 y 60 % respectivamente), mientras que C4 demostró ser el menos fiable (52 %) pero no demasiado alejado de C1.

Por otro lado, la evaluación por categoría de perturbación ofrece una visión más detallada de la robustez de cada controlador (ver Tabla 6).

Tabla 6: Tasa de éxito por categoría de perturbación

Categoría	C1 (%)	C2 (%)	C3 (%)	C4 (%)
Alimentación	33.33	50.00	66.67	33.33
Cinéticos	45.45	45.45	54.55	36.36
Ambientales	100	100	100	100
Fugas	75	75	75	75

De este análisis se observa que el controlador C3 es superior en las categorías de Alimentación

Tabla 7: Estadísticas descriptivas para la Amplitud en casos de éxito

Métrica	C1	C2	C3	C4
Media	0.020	0.017	0.032	0.043
Mediana	0.007	0.005	0.010	0.040
Desv. Estándar	0.022	0.021	0.040	0.015

y Cinéticos. Por otro lado, la categoría de Ambientales mostró una tasa de éxito del 100 % frente a los cuatro controladores. En la categoría de Fugas, todos los controladores obtuvieron una tasa de éxito de 75 %, lo que indica lo que indica que este tipo de perturbaciones, la elección de una variante de control no es relevante.

5.6.1.2 Amplitud máxima del error

La Tabla 7 resume el comportamiento de la amplitud máxima en los casos de éxito.

Se observa que el controlador C4 presenta la media de amplitud más alta (0.0428) cuando logra tener éxito, lo que justifica su baja tasa de éxito en comparación con los otros controladores, ya que, incluso cuando se mantiene dentro del rango del $\pm 5\%$, tiende a operar con oscilaciones más pronunciadas. Por el contrario, los controladores C1 y C2 muestran la mejor contención de la amplitud, con las medias más bajas, indicando un control más estable y cercano al *setpoint*.

5.6.1.3 Chattering

El análisis del chattering revela la diferencia más drástica entre las estrategias de control (ver Tabla 8). El controlador C3, el más fiable en términos de tasa de éxito, lo logra a costa de una acción de control extremadamente agresiva. Su media de chattering (2.988) es un orden de magnitud superior a la de los otros controladores, siendo casi 8 veces mayor que la de C2 y 4 veces mayor que la de C4. En contraste, los controladores C1, C2 y C4 mantienen un nivel de chattering bajo y comparable entre sí, lo que indica una señal de control significativamente más suave.

Tabla 8: Estadísticas descriptivas para el Chattering en casos de éxito

Métrica	C1	C2	C3	C4
Media	0.246	0.394	2.988	0.765
Mediana	0.016	0.001	0.017	0.012
Desv. Estándar	0.428	0.828	5.544	1.650

5.6.2 Identificación de patrones de comportamiento

5.6.2.1 Clasificación visual

La inspección de las respuestas temporales de la producción de hidrógeno, a lo largo de 100 unidades de tiempo, mostró patrones que se repiten entre escenarios (véase Figura 6).




Figura 6: Comparación de la producción de hidrógeno bajo diferentes escenarios

(a) Tres controladores se agrupan y uno se diferencia del resto. (b) Los cuatro controladores muestran un comportamiento diferenciado. (c) Los cuatro controladores presentan un agrupamiento conjunto.

Con mayor frecuencia, las trayectorias no aparecen como cuatro curvas diferenciadas, sino que tienden a agruparse: tres controladores (C1, C2 y C3) evolucionan de manera muy

similar, mientras C4 se mantiene claramente separado del resto. En unos cuantos casos la convergencia se da entre los cuatro controladores los cuales parecen seguir la misma dinámica sin diferencias marcadas visualmente. En el otro extremo se encontraron un par de casos en donde cada controlador siguió su propio camino, sin evidencias de agrupamiento. Estos patrones de similitud sugieren que la estructura del comportamiento no es uniforme, sino que varia entre escenarios ofreciendo un panorama más matizado del desempeño relativo entre controladores por lo que fue indispensable realizar pruebas cuantitativas diferenciadas que se adecuaran a las características de agrupamiento identificadas. El resumen de esta primera clasificación se muestra en la Tabla 9.

Tabla 9: Resumen de la clasificación visual

Grupo de similitud	Frecuencia	Porcentaje (%)
Subgrupo	16	64
Par	5	20
Diferenciado	4	16
Total	25	100

5.6.2.2 Clasificación automática

Para complementar la lectura visual y aportar un criterio de reproducibilidad se decidió aplicar una clasificación basada en la distancia Manhattan calculada sobre las métricas previamente normalizadas. Este enfoque permitió esclarecer los grados de similitud entre controladores con indicadores comparables entre escenarios. En términos operativos, la distancia mínima ($d_{\min}$) identifica el par más parecido (la “pareja” más próxima); la segunda mínima ($d_{2\min}$) ayuda a determinar si esa pareja es un caso aislado o pertenece a un conjunto más amplio; la media y la mediana de distancias (d_{promedio} y d_{mediana}) describen el nivel general de proximidad entre todos los pares; y la distancia máxima ($d_{\max}$) marca el límite superior de separación, es decir, el par que más se aleja del resto. La Tabla 10 recoge estos estadísticos para tres casos representativos que ilustran patrones de comportamiento diferenciados.

Tabla 10: Estadísticos de distancia Manhattan para casos representativos

Caso	d_min	d_2min	d_promedio	d_mediana	d_max
E5	0.111	0.177	0.256	0.235	0.450
P15	0.002	0.056	0.314	0.317	0.615
P16	0.615	0.854	1.232	1.153	2.116

Analizando los datos de la tabla, el caso P15 se clasifica como un caso de agrupamiento: dos controladores son prácticamente indistinguibles ($d_{\min} \approx 0.002$) y, a partir de ahí, se produce un salto hasta la segunda mínima, lo que refleja la configuración 'Subgrupo'. En E5, en cambio, las distancias se sitúan en un rango intermedio ($d_{\min} = 0.111$) y crecen de manera gradual ($d_{2\min}/d_{\min} \approx 1.59$), un signo de que no hay un único bloque compacto, sino más bien parejas o subgrupos con similitud moderada pero claramente distinguible; además, la separación máxima contenida ($d_{\max} \approx 0.450$) sugiere que ninguno queda completamente aislado del conjunto. Por su parte, P16 muestra un patrón de diferenciación notorio: incluso los controladores más próximos están lejos entre sí ($d_{\min} \approx 0.615$) y tanto la mediana como el máximo de las distancias son elevados, lo que confirma que no se forman agrupamientos y que cada controlador mantiene una dinámica propia. En conjunto, estos tres ejemplos muestran cómo el análisis de distancias perfila, con un solo vistazo, la transición desde escenarios de coalescencia hacia otros de similitud parcial y, finalmente, de separación nítida entre controladores.

Aplicación de reglas de clasificación

Al aplicar de manera sistemática las reglas empíricas (sección 4.9.1.2) al conjunto de casos, se obtuvo la distribución que se muestra en la Tabla 11.

Tabla 11: Resumen de la clasificación mediante reglas de clasificación

Grupo de similitud	Frecuencia	Porcentaje (%)
Subgrupo	8	32
Par	12	48
Ambiguo	5	20
Total	25	100

Es importante notar que, a diferencia de lo que se observó de manera visual en una primera revisión, las reglas estadísticas no detectaron casos totalmente agrupados ni completamente separados. Esto se debe a que dichas reglas se basaron en los valores de las métricas las cuales fueron calculadas mediante ventanas específicas (ver sección 4.8.7), mientras que la evaluación visual consideró todo el comportamiento del sistema a lo largo del tiempo.

5.6.2.3 Clasificación mediante dendrogramas

Para profundizar en la estructura de similitudes a distintas escalas se recurrió a dendrogramas de agrupamiento, a partir de los cuales se distinguieron tres configuraciones generales: parejas (dos controladores se unen a distancias muy pequeñas respecto al resto), subgrupos (tres controladores mantienen una similitud moderada y se diferencian del cuarto) y diferenciados (todas las distancias son altas y no se forman agrupamientos claros). La Figura 7 ilustra casos representativos de cada patrón: P15 como ejemplo de subgrupo (con C1-C2-C3 muy próximos y C4 a mayor distancia), E5 como agrupamiento (los cuatro controladores son afines), P16 como escenario diferenciado (todas las distancias por encima del umbral P50, sin evidencias de vínculos fuertes) y P6 como pareja (C2 y C3 muy próximos mientras que C1-C4 se apartan).




Figura 7: Dendrogramas representativos de patrones de agrupamiento.

(a) Subgrupo, (b) Diferenciado, (c) Agrupamiento, (d) Pareja

La Tabla 12 resume la frecuencia relativa de cada configuración en el conjunto analizado. Como se aprecia, el patrón dominante es el de subgrupos (52 %), seguido por parejas (24 %); los agrupamientos suponen un 16 % y los escenarios diferenciados son los menos frecuentes (8 %). En conjunto, esta distribución confirma que, aunque aparecen parejas y agrupamientos puntuales, la pauta más habitual es la formación de subgrupos, un rasgo con implicaciones directas para el diseño de comparaciones estadísticas y la selección de contrastes adecuados.

Tabla 12: Porcentajes de clasificación mediante dendrogramas

Similitud	Frecuencia	Porcentaje
Agrupamiento	4	16 %
Parejas	6	24 %
Subgrupo	13	52 %
Diferenciados	2	8 %
Total	25	100 %

5.6.2.4 Clasificación final

Para la clasificación final de los casos se optó por utilizar las etiquetas derivadas de los dendrogramas. Esta elección respondió a que las otras dos alternativas presentaban limitaciones importantes: las reglas estadísticas, aunque objetivas y automatizables, dejaban varios casos sin una etiqueta clara al no cumplirse con precisión ciertos criterios; mientras que la evaluación visual aportaba intuición pero resultaba demasiado subjetiva y difícil de reproducir como único criterio. En contraste, los dendrogramas ofrecen una representación visual de la estructura de similitud junto con reglas de corte cuantificables (percentiles).

En cuanto al número de categorías, los dendrogramas mostraron inicialmente cuatro patrones reconocibles: agrupamiento, parejas, subgrupos y diferenciados. Sin embargo, para los análisis estadísticos se consolidaron en tres: Agrupados, Subgrupos y Diferenciados.

Se tomó la decisión de añadir a la categoría de 'subgrupos' la categoría parejas para así poder evitar más divisiones de los datos y asegurar que hubiera suficiente información para los análisis estadísticos, además de que las parejas formadas no incluyen a C4 mas que en un sólo caso (ver ANEXO A, Tablas [28](#) y [29](#) para la clasificación detallada).

5.6.3 Representante vs C4

Con la clasificación por similitud finalizada, se decidió analizar primero los casos agrupados. El paso inicial fue elegir, caso a caso, un “representante” del grupo C1-C2-C3. Para ello, se calculó un puntaje compuesto como el promedio de las tres métricas normalizadas para

cada controlador del grupo y se designó representante al que quedara más cerca de la media del propio grupo en ese escenario. Así se aseguró de que el elegido reflejara fielmente el comportamiento colectivo.

La Tabla 13 resume la frecuencia con la que cada controlador fue seleccionado entre los 19 casos incluidos. C3 fue el representante en el 47.6 % de los casos, seguido de C2 (28.6 %) y C1 (23.8 %). En otras palabras, C3 es, con mayor frecuencia, el que mejor se aproxima a la media del grupo C1-C2-C3. Aun así, el hecho de que C1 o C2 asuman la representación en el 52.4 % restante confirma la solidez del criterio: la representatividad se reparte entre los tres en función de las condiciones específicas de cada escenario.

Tabla 13: Distribución de selección como controlador representante

Controlador	Frecuencia	Porcentaje (%)
C1	5	23.8
C2	6	28.6
C3	10	47.6
Total	21	100

5.6.3.1 Verificación de supuestos estadísticos

Antes de elegir las pruebas estadísticas, se comprobaron los supuestos básicos de normalidad y homocedasticidad para las tres métricas de desempeño en ambos grupos de controladores.

Análisis de normalidad por categoría

- Categoría Cinéticos: Según la prueba de Shapiro-Wilk ($\alpha = 0.05$), la mayoría de las métricas del grupo Representante (ESS, Amplitud y Chattering) no sigue una distribución normal ($p < 0.05$). En C4 se observó un patrón similar para ESS y Amplitud, mientras que Chattering sí cumplió normalidad ($p = 0.077$), lo que sugiere una conmutación más predecible del controlador bajo perturbaciones cinéticas.
- Categoría Alimentación: En contraste, para esta categoría el grupo Representante cumplió normalidad en las tres métricas (ESS, Amplitud y Chattering). En C4 únicamente

Chattering se desvió de la normalidad ($p = 0.041$), indicando que, ante perturbaciones de alimentación, su error y amplitud se comportan de forma consistente, pero su conmutación presenta mayor variabilidad.

Tabla 14: Análisis de normalidad (Shapiro-Wilk) para la categoría de Cinéticos

Controlador	Métrica*	Estadístico	p_valor	Normal
Representante	ESS	0.778	0.024	FALSO
C4	ESS	0.709	0.005	FALSO
Representante	Amplitud	0.777	0.024	FALSO
C4	Amplitud	0.700	0.004	FALSO
Representante	Chattering	0.652	0.001	FALSO
C4	Chattering	0.828	0.077	VERDADERO

*Nota: *métricas normalizadas*

Tabla 15: Análisis de normalidad (Shapiro-Wilk) para la categoría de Alimentación

Controlador	Métrica*	Estadístico	p_valor	Normal
Representante	ESS	0.836	0.155	VERDADERO
C4	ESS	0.902	0.423	VERDADERO
Representante	Amplitud	0.850	0.193	VERDADERO
C4	Amplitud	0.933	0.619	VERDADERO
Representante	Chattering	0.953	0.757	VERDADERO
C4	Chattering	0.765	0.041	FALSO

*Nota: *métricas normalizadas*

Análisis de homocedasticidad por categoría

La prueba de Levene ($\alpha = 0.05$) confirmó la igualdad de varianzas entre el grupo Representante y C4 tanto en cinéticos como en alimentación (ver Tablas 16 y 17). En cinéticos, los p-valores fueron: ESS = 0.773, Amplitud = 0.603 y Chattering = 0.172; todos por encima del umbral de significancia. De forma similar, en alimentación se observaron p-valores de 0.595 (ESS),

0.600 (Amplitud) y 0.732 (Chattering). En conjunto, estos resultados indican que las posibles diferencias entre grupos no se deben a dispersiones desiguales, sino a diferencias reales de desempeño.

Tabla 16: Análisis de homocedasticidad para la categoría de Cinéticos

Métrica	Estadístico	p_valor	Homocedasticidad
ESS*	0.087	0.773	VERDADERO
Amplitud*	0.285	0.603	VERDADERO
Chattering*	2.108	0.172	VERDADERO

*Nota: *métricas normalizadas*

Tabla 17: Análisis de homocedasticidad para la categoría de Alimentación

Métrica	Estadístico	p_valor	Homocedástico
ESS*	0.307	0.595	VERDADERO
Amplitud*	0.298	0.600	VERDADERO
Chattering*	0.126	0.732	VERDADERO

*Nota: *métricas normalizadas*

5.6.3.2 Pruebas estadísticas (Cinéticos y Alimentación)

La selección de los contrastes se ajustó a los supuestos verificados para cada métrica y categoría. Cuando ambos grupos cumplían normalidad y homocedasticidad, se aplicó t de Student para muestras independientes; si fallaba la normalidad (en cualquiera de los grupos), se recurrió a la prueba no paramétrica U de Mann-Whitney.

Categoría Cinéticos: Al no cumplirse la normalidad de forma sistemática, se empleó Mann-Whitney en las tres métricas y en ningún caso se detectaron diferencias significativas entre el grupo Representante y C4 (Tabla 18).

Tabla 19: Pruebas estadísticas para la categoría de Alimentación

Metrica	Prueba	Estadistico	Valor_p	Significativo
ESS*	t-test	-0.571	0.584	FALSO
Amplitud*	t-test	-0.612	0.558	FALSO
Chattering*	Mann-Whitney	13	1	FALSO

*Nota: *métricas normalizadas*

Tabla 18: Análisis Mann-Whitney para la categoría de Cinéticos

Metrica	Estadistico	Valor_p	Significativo
ESS*	16	0.318	FALSO
Amplitud*	17	0.383	FALSO
Chattering*	23	0.902	FALSO

*Nota: *métricas normalizadas*

Categoría Alimentación: Dado que ESS y Amplitud cumplieron normalidad y homocedasticidad en ambos grupos, se utilizó t de Student y no se detectaron diferencias significativas. Para Chattering, C4 no cumplió normalidad, por lo que se aplicó Mann-Whitney ($U = 13$, $p = 1.000$), confirmando también la ausencia de diferencias significativas entre el Representante y C4.

En síntesis, todos los p-valores superaron el nivel de significancia establecido ($\alpha = 0.05$). Esta convergencia estadística sugiere que, desde una perspectiva cuantitativa, los cuatro controladores exhiben desempeños equivalentes cuando se enfrentan a perturbaciones relacionadas con parámetros de alimentación y cinéticos del sistema de producción de hidrógeno.

5.6.3.3 Análisis de las categorías Ambiental y Fugas

Debido al número reducido de casos, las perturbaciones de tipo Ambiental y de Fugas se analizaron únicamente de forma descriptiva, excluyéndolas de las pruebas de inferencia estadística para mantener la validez de los resultados. Los estadísticos completos para cada métrica se presentan en el ANEXO B (Tablas 30 y 31).

El análisis reveló tres patrones clave para evaluar la robustez del sistema.

1. Se observó una alta consistencia en el desempeño de todos los controladores. Las desviaciones estándar fueron muy bajas (del orden de 10^{-3} a 10^{-6}), lo que indica un comportamiento predecible y estable frente a estas perturbaciones.
2. Aunque todos mostraron estabilidad, el grupo Representante presentó una su mayor precisión respecto al controlador C4. En la escala normalizada (valores más negativos indican mejor desempeño) el grupo Representante obtuvo medias y medianas más bajas en las métricas ESS y Amplitud.
3. El esfuerzo de control (chattering) fue prácticamente igual entre ambos grupos (-0.175 para el Representante y -0.185 para C4), lo que indica que la mayor precisión del grupo C1-C2-C3 no implica un mayor desgaste del actuador, sino una acción de control más eficiente.

Aunque el sistema mostró una buena estabilidad general ante perturbaciones ambientales y de fugas, los controladores C1, C2 y C3 ofrecieron un desempeño superior en precisión y control de errores sin aumentar el esfuerzo de control, consolidándose como la opción más adecuada para este tipo de condiciones.

5.6.4 Casos diferenciados

En esta sección se presentan los escenarios que se apartaron del patrón general y que, por ello, se analizaron de manera individual. En particular, se observó que el caso P4 exhibió coeficientes de variación (CV) de magnitud comparable entre métricas (ESS: 26.98 %, Amplitud: 21.96 % y Chattering: 34.69 %), mientras que el caso P16 mostró una variabilidad marcadamente alta en Chattering (94.16 %) frente a valores acotados en ESS (14.73 %) y Amplitud (9.09 %). Para contextualizar esa variabilidad, en la Tabla 20 se resumen además los rangos (mín-máx) observados para cada métrica en ambos casos.

Tabla 20: Variabilidad relativa (CV) y rangos observados por caso y métrica

Caso	Métrica	CV (%)	Mín	Máx
P4	ESS	26.98	0.0227	0.0431
P4	Amplitud	21.96	0.0536	0.0874
P4	Chattering	34.69	0.5568	1.1174
P16	ESS	14.73	0.0487	0.0666
P16	Amplitud	9.09	0.0699	0.0845
P16	Chattering	94.16	0.0053	1.2920

En términos de desempeño relativo, se obtuvo un patrón consistente entre P4 y P16 para ESS y Amplitud: C3 siendo el mejor controlador mientras que C4 es el que muestra el desempeño más bajo. En cambio, para la métrica de Chattering se observó una inversión entre casos: a P4 lo favoreció C1, mientras que a P16 C4. La Tabla 21 sintetiza estas jerarquías.

Tabla 21: Ranking de controladores por caso y métrica (mejor → peor)

Caso	ESS	Amplitud	Chattering
P4	C3 > C2 > C1 > C4	C3 > C2 > C1 > C4	C1 > C3 > C4 > C2
P16	C3 > C2 > C1 > C4	C3 > C2 > C1 > C4	C4 > C3 > C1 > C2

Este contraste sugiere que las condiciones operativas específicas del escenario modulan la eficacia relativa de los controladores para atenuar la conmutación: en un entorno con variabilidad moderada de Chattering (tipo P4), el controlador C1 tendió a reducir mejor la conmutación; en un entorno con alta sensibilidad de conmutación (tipo P16), el controlador C4 resultó más efectivo .

5.6.5 Casos agrupados

En los casos agrupados (E4, E5, E7 y E8) se observó una convergencia prácticamente perfecta entre los cuatro controladores, de acuerdo con dos tipos de evidencia: concordancia entre

controladores y distancia entre respuestas, todas apuntan a respuestas equivalentes en estas condiciones experimentales.

La concordancia se cuantificó mediante la correlación intraclase (ICC), que fue igual a 1.0 en todas las métricas (ESS, Amplitud y Chattering) y en los cuatro casos, lo que indica ausencia de variabilidad atribuible al efecto del controlador.

El análisis de distancias Manhattan entre controladores corroboró esta convergencia: para ESS y Amplitud se registraron distancias del orden de 10^{-6} - 10^{-2} , mientras que para Chattering, aun siendo mayores en términos absolutos, también se mantuvieron en un rango muy próximo, lo que es compatible con la ausencia de diferencias operativas en el desempeño global (ver Tabla 22).

Tabla 22: Rango observado de distancias Manhattan por caso y métrica

Caso	Métrica	Distancia mínima	Distancia máxima
E4	ESS	2.71E-04	5.69E-03
E4	Amplitud	1.74E-03	6.72E-03
E4	Chattering	3.65E-02	2.02E-01
E5	ESS	1.07E-04	4.13E-03
E5	Amplitud	2.32E-05	3.55E-03
E5	Chattering	3.59E-02	2.00E-01
E7	ESS	8.98E-06	5.52E-03
E7	Amplitud	3.58E-04	5.53E-03
E7	Chattering	2.73E-02	1.73E-01
E8	ESS	7.46E-05	1.01E-02
E8	Amplitud	2.71E-03	9.73E-03
E8	Chattering	3.31E-02	1.88E-01

5.7 Evaluación de robustes para casos estocásticos

5.7.1 Caracterización de confiabilidad por controlador

Bajo condiciones estocásticas (ruido en la medición de H_2), la confiabilidad de cada controlador se evaluó a partir de los coeficientes de variación (CV) calculados sobre 30 simulaciones independientes por combinación controlador-caso-métrica, y clasificando la confiabilidad como alta ($CV \leq 15\%$), moderada ($15\% < CV \leq 25\%$) o baja ($CV > 25\%$). Este enfoque permitió estimar de forma consistente la estabilidad del desempeño frente al ruido.

Distribución general de confiabilidad

En conjunto, el controlador C4 fue el que mostró mayor solidez, ya que el 75 % de sus métricas se mantuvieron en un nivel de alta confiabilidad. Le siguieron C2 con 66.7 % y C1 con 58.3 %. En cambio, C3 resultó ser el más sensible al ruido: solo alcanzó un 41.7 % de métricas con alta confiabilidad y, además, más de la mitad de sus resultados quedaron en rangos bajos. Estos porcentajes se resumen en la Tabla 23.

Tabla 23: Porcentaje de confiabilidad por controlador

Controlador	% Alta	% Baja	% Moderada
C1	58.30	33.30	8.30
C2	66.70	8.30	25.00
C3	41.70	58.30	0.00
C4	75.00	8.30	16.70

5.7.2 Verificación de supuestos estadísticos

5.7.2.1 Normalidad (Shapiro-Wilk)

En conjunto se realizaron 48 comprobaciones de normalidad ($4 \text{ casos} \times 4 \text{ controladores} \times 3 \text{ métricas}$), de las cuales 6 mostraron desviaciones significativas ($p < 0.05$) concentradas en escenarios y métricas específicas. Se observó que el caso E10 concentró el mayor número de incumplimientos (C1-Chattering, C2-ESS, C2-Amplitud y C4-Chattering), mientras que

también se registraron violaciones puntuales en C3-E12-Amplitud y en C4-P17-Chattering. La Tabla 24 resume estas incidencias, los resultados completos se encuentran en el ANEXO C (Tablas 32, 33, 34, 35)

Tabla 24: Resultados del análisis de normalidad (Shapiro-Wilk)

Caso	Controlador	Métrica	p-valor	Cumple normalidad
E10	C1	Chattering	0.0005	No
E10	C2	ESS	0.0028	No
E10	C2	Amplitud	0.0138	No
E10	C4	Chattering	0.0416	No
E12	C3	Amplitud	0.0237	No
P17	C4	Chattering	0.0359	No

En términos de patrones, la métrica Chattering fue la más afectada por no normalidad, principalmente en E10, mientras que las anomalías en ESS y Amplitud se concentraron en C2 en ese mismo caso.

5.7.2.2 Homocedasticidad (Levene)

El análisis de igualdad de varianzas mostró un comportamiento más marcado: Chattering incumplió sistemáticamente la homocedasticidad en los cuatro casos analizados (P17, E10, E11 y E12), con p-valores extremadamente bajos ($p \ll 0.001$), lo que evidencia varianzas desiguales entre controladores para esta métrica bajo ruido. En contraste, ESS fue homogénea en E10, E11 y E12, pero no en P17; y Amplitud cumplió homocedasticidad en todos los casos (ver Tabla 25).

Tabla 25: Homocedasticidad por caso y métrica (Levene)

Caso	Métrica	p-valor	Homocedástico
P17	ESS	9.06E-10	No
P17	Amplitud	4.57E-01	Sí
P17	Chattering	5.75E-16	No
E10	ESS	6.71E-02	Sí
E10	Amplitud	3.37E-01	Sí
E10	Chattering	2.33E-21	No
E11	ESS	8.01E-01	Sí
E11	Amplitud	1.87E-01	Sí
E11	Chattering	6.35E-19	No
E12	ESS	5.79E-02	Sí
E12	Amplitud	8.03E-01	Sí
E12	Chattering	2.70E-17	No

5.7.3 Resultados de pruebas estadísticas

Para cada combinación de caso y métrica se compararon los cuatro controladores (C1-C4) mediante una prueba global. La matriz de decisión aplicada por caso y métrica se resume en la Tabla 26, junto con los p-valores obtenidos. En todos los casos los contrastes globales resultaron significativos ($\alpha = 0.05$), lo que confirmó la existencia de diferencias estadísticamente relevantes entre controladores.

Tabla 26: Prueba aplicada y p-valor por caso y métrica

Caso	Métrica	Prueba aplicada	p-valor
P17	ESS	ANOVA de Welch	1.50e-65
P17	Amplitud	ANOVA (una vía)	3.43e-67
P17	Chattering	Kruskal-Wallis	1.22e-15
E10	ESS	Kruskal-Wallis	3.45e-22
E10	Amplitud	Kruskal-Wallis	4.95e-21
E10	Chattering	Kruskal-Wallis	5.46e-18
E11	ESS	ANOVA (una vía)	1.52e-71
E11	Amplitud	ANOVA (una vía)	3.83e-25
E11	Chattering	ANOVA de Welch	4.90e-27
E12	ESS	ANOVA (una vía)	7.88e-63
E12	Amplitud	Kruskal-Wallis	2.23e-21
E12	Chattering	ANOVA de Welch	1.86e-14

5.7.3.1 Desempeño por caso y métrica

Caso P17 – Perturbaciones combinadas

- ESS. C3 destacó con el menor error en estado estacionario (≈ 0.0026), superando con claridad a C1, C2 y C4.
- Amplitud. C4 fue el más eficiente al contener la amplitud, con diferencias significativas frente a los demás.
- Chattering. C3 presentó valores muy elevados (≈ 360.7), en contraste con los bajos niveles de C1, C2 y C4 ($\approx 20-23$).

Caso E10 – Perturbaciones en glucosa

- ESS. C3 y C1 mostraron los errores más bajos; C2 y C4 quedaron en desventaja.
- Amplitud. C3 nuevamente lideró con la amplitud más reducida, seguido de C1.

- Chattering. C3 volvió a ser el menos favorable (≈ 81.2), mientras que C1 y C4 alcanzaron los mejores valores (≈ 1.4 y 1.8).

Caso E11 – Perturbaciones en caudal

- ESS. C4 se posicionó con la media más baja, seguido por C2; C1 y C3 quedaron al final.
- Amplitud. C4 repitió liderazgo, con C1 detrás y C2–C3 más rezagados.
- Chattering. C3 fue el peor (≈ 550.7), muy por encima de los demás (≈ 43 – 50).

Caso E12 – Perturbaciones combinadas glucosa–caudal

- ESS. C4 volvió a liderar con el error más bajo, seguido por C1 y C3; C2 quedó último.
- Amplitud. C1 y C3 compartieron los mejores valores, con C2 y C4 en posiciones menos favorables.
- Chattering. C3 presentó el peor desempeño (≈ 313.6), mientras que C1, C2 y C4 mantuvieron niveles bajos y similares (≈ 28 – 32).

Al analizar todos los escenarios con ruido se confirma que siempre hubo diferencias globales entre controladores en las tres métricas (ESS, Amplitud y Chattering).

- ESS. C3 fue el mejor en P17 y uno de los más sólidos en E10, pero C4 tomó ventaja en E11 y E12.
- Amplitud. C4 lideró en P17 y E11, mientras que en E10 lo hizo C3; en E12 se observó un empate favorable entre C1 y C3.
- Chattering. C3 fue sistemáticamente el más problemático en todos los escenarios, mientras que C1, C2 y C4 se mantuvieron con valores bajos y muy similares.

5.7.3.2 Síntesis del análisis estadístico y rankings globales

Para integrar la evidencia de los escenarios con ruido se elaboró un ranking global promedio por métrica (ESS, Amplitud y Chattering), asignando en cada caso puntajes de 1 (mejor) a 4 (peor) y promediándolos a través de los cuatro escenarios; en presencia de empates, se promediaron las posiciones correspondientes. Este procedimiento resume la posición relativa de cada controlador de forma compacta y comparable entre métricas y casos, manteniendo la trazabilidad con los rankings por caso y las comparaciones post hoc originales.

De la Tabla 27 se observó lo siguiente:

- Precisión (ESS). Se obtuvo un desempeño muy parejo entre C1 y C3, con puntajes promedio de 2.25 y 2.38, respectivamente, seguidos de C4 (2.50) y C2 (2.88). En términos prácticos, C1 y C3 sobresalieron en precisión bajo ruido, con diferencias pequeñas entre ambos.
- Estabilidad frente a sobreoscilaciones (Amplitud). Se concluyó que C4 fue el más consistente, con el puntaje más bajo (1.63), mientras que C3 (2.63) y C1 (2.75) ocuparon posiciones intermedias y C2 quedó en último lugar (3.00). Este patrón confirma que, cuando el objetivo es minimizar la amplitud de las desviaciones, C4 aporta la respuesta más contenida en condiciones ruidosas.
- Esfuerzo/actividad de control (Chattering). Se observó un empate favorable de C1, C2 y C4 (2.00), mientras que C3 se ubicó claramente rezagado (4.00). En otras palabras, tres controladores mantuvieron niveles de chattering similares y bajos, y solo C3 destacó negativamente por una actividad de control marcadamente superior.

Tabla 27: Ranking global promedio por métrica (menor es mejor)

Controlador	ESS (puntaje)	Amplitud (puntaje)	Chattering (puntaje)
C1	2.25	2.75	2.00
C2	2.88	3.00	2.00
C3	2.38	2.63	4.00
C4	2.50	1.63	2.00

Estos resultados se vieron respaldados por el análisis de confiabilidad (CV %) realizado sobre las 30 réplicas de cada combinación caso–controlador. En ese análisis se mostró que C4 fue el más consistente, contando con el mayor porcentaje de mediciones altamente confiables (75.0 %) y el menor de baja confiabilidad (8.3 %), por el otro lado, C3 presentó un 58.3 % de sus resultados en el rango de baja confiabilidad. Finalmente C1 y C2 ocuparon una posición intermedia, con un 58.3 % y 66.7 % de alta confiabilidad, respectivamente. Estos hallazgos son coherentes con el ranking global en amplitud (donde C4 fue el mejor) y con los resultados de chattering, que confirmó que C3 presenta un desempeño problemático.

De manera integrada, el análisis de los escenarios con ruido permitió establecer criterios operativos para la selección de controladores según la métrica que se establezca como prioritaria. Para la precisión (ESS), se observó que C1 y C3 ofrecieron el mejor desempeño global presentando diferencias mínimas entre ambos puntajes promedio, lo que los vuelve alternativas equivalentes para este tipo de casos con ruido. Respecto a la amplitud de las oscilaciones, se concluyó que C4 destacó de forma consistente sobre el resto, constituyéndose en la opción preferente cuando el objetivo es contener la variabilidad de la señal en presencia de ruido. En cuanto al chattering, se obtuvo que C1, C2 y C4 mantuvieron niveles bajos y comparables, mientras que C3 resultó poco recomendable al presentar una actividad de control marcadamente superior, comprometiendo la estabilidad práctica del accionamiento. En conjunto, estos resultados globales son coherentes con los patrones observados caso a caso en los escenarios P17, E10, E11 y E12, y proporcionan una guía clara para elegir el controlador más adecuado según la métrica de interés en condiciones afectadas por ruido.

CONCLUSIONES

Este trabajo de tesis propuso, implementó y evaluó comparativamente un conjunto de estrategias de control por modos deslizantes sin modelo (MF-SMC) para la estabilización de la producción de hidrógeno en un biorreactor CSTR simulado, de los resultados obtenidos se han extraído conclusiones que no solo validan la hipótesis planteada, sino que también establecen un mapa claro de compromisos operativos para la selección de controladores en aplicaciones prácticas.

Validación del modelo y plataforma de simulación

La migración del modelo cinético-fisicoquímico de fermentación oscura de MATLAB/Simulink a Python conservó con rigor el comportamiento estacionario del sistema: las diferencias relativas entre ambos entornos fueron inferiores al 0.1 % en todos los puntos comparados, lo que confirma la validez de la plataforma adoptada para diseño y evaluación de controladores en este trabajo.

Las discrepancias transitorias iniciales se explicaron por decisiones numéricas y de implementación de entradas (tolerancias más estrictas e interpolación de señales en Python), por lo que no comprometen la utilidad del modelo para propósitos de control en régimen y bajo perturbaciones sostenidas.

Caracterización operativa y linealización por tramos

Se identificaron de manera sistemática regiones operativas favorables y de riesgo en el espacio de operación (Glu_{in} 10–20 g/L, Q_{in} 2–8 L/d), extrayéndose un punto de referencia óptimo en $\text{Glu}_{\text{in}} = 20.0$ g/L y $Q_{\text{in}} = 4.06$ L/d, con producción máxima de H_2 de 0.9289 mol/L.

A partir de la curva característica (con transiciones en 2.8 y 3.7 L/d), se formuló una aproximación por tramos que ofrece relaciones explícitas entre caudal y producción por zona, con desempeño de ajuste excelente (R^2 global = 0.999; errores MSE/MAE globales bajos), habilitando un diseño de control simple y eficaz sobre una base matemática transparente.

Diseño MF-SMC y sintonización Se desarrollaron cuatro variaciones de control por modos deslizantes sin modelo (MF-SMC) combinando funciones de conmutación tanh/saturación con

ganancias fijas/adaptativas y conmutación automática entre zonas, priorizando la reducción de chattering y la operación dentro de límites físicos del actuador.

La sintonización mediante Algoritmo Genético equilibró seguimiento (ISE), esfuerzo de control y suavidad, arrojando un ranking global por función objetivo en el que C2 resultó el más eficiente ($J = 0.430$), seguido por C4 ($J = 0.441$), C1 ($J = 0.449$) y C3 ($J = 0.453$), lo que revela compromisos claros entre suavidad de señal y esfuerzo del actuador.

Tasa de éxito para los casos determinísticos

Este análisis reveló que la robustez de un controlador no se puede medir por una única métrica, sino por el balance entre su fiabilidad, la estabilidad de su respuesta y el esfuerzo de control que ejerce. Aunque los resultados en las categorías de Alimentación y Cinéticos no mostraron diferencias significativas, se reveló una clara jerarquía de desempeño operativo:

- **C3 (Fiable y Agresivo):** Se consolidó como el controlador más robusto, con una Tasa de Éxito global más alta (68 %). Sin embargo, esto se logra a costa de un índice de chattering drásticamente elevado, siendo en promedio 8 veces superior al de C2, que, aunque efectiva es potencialmente perjudicial para los actuadores a largo plazo.
- **C4 (Oscilatorio):** Demostró ser la opción menos viable. Presentó una Tasa de Éxito baja (52 %) lo que se relaciona con su pobre precisión, presentando el ESS más alto del conjunto. Adicionalmente, en los casos donde tuvo éxito, operó con la mayor amplitud de error promedio (0.0428), denotando un control inestable.
- **C1 y C2 (Equilibrados):** Se establecen como las alternativas más balanceadas. Ofrecen una fiabilidad competitiva (56 % y 60 %, respectivamente) pero con un esfuerzo de control (*chattering*) significativamente menor y valores moderados de la amplitud del error. C2, en particular, destaca por tener la mediana de *chattering* y la media de amplitud más bajas de todos los controladores exitosos.

Pruebas estadísticas de escenarios determinísticos

En ausencia de ruido de medición, la mayoría de los escenarios no muestran cuatro comportamientos claramente separados, sino estructuras de similitud en 'Subgrupos' (parejas o tríos

afines), lo que justifica comparar al Representante del conjunto C1–C2–C3 frente a C4 para evitar comparaciones redundantes y ganar potencia estadística.

Con esta estrategia, y tras verificar normalidad y homocedasticidad, no se observaron diferencias estadísticamente significativas entre el Representante y C4 en las categorías de perturbaciones de alimentación y cinéticas, lo que indica desempeños equivalentes cuando no hay ruido y se mantienen varianzas comparables.

En este contexto, la selección de controlador puede guiarse por los compromisos de diseño obtenidos en la sintonización: C2 minimizó la función objetivo global ($J = 0.430$) gracias a chattering prácticamente nulo, a costa de mayor esfuerzo de control; C4 ocupó el segundo lugar ($J = 0.441$) con baja conmutación pero el esfuerzo más alto; C1 privilegió el menor esfuerzo ($J = 0.449$) con chattering moderado; y C3 mostró el desempeño global más bajo ($J = 0.453$) sin ventajas claras en esfuerzo o chattering.

En suma, sin ruido se concluyó que los cuatro controladores ofrecen desempeños comparables en alimentación y cinéticos, por lo que la decisión puede basarse en prioridades de ingeniería: ahorro energético (C1), suavidad extrema de la señal (C2), o robustez conservadora (C4).

Panorama general de escenarios estocásticos

Bajo ruido gaussiano en la medición de H2 y 30 réplicas por combinación, todas las pruebas globales por caso y métrica resultaron significativas, evidenciando sensibilidad diferencial a la estocasticidad y descartando equivalencia entre controladores en presencia de ruido.

Se observó un patrón robusto a través de los cuatro casos con ruido: en precisión (ESS), C1 y C3 tendieron a liderar en P17 y E10, mientras que C4 tomó ventaja en E11 y E12; en amplitud, C4 ofreció la contención más consistente (P17 y E11), con empates favorables de C1–C3 en E12 y liderazgo de C3 en E10; en chattering, C3 fue sistemáticamente el más alto (peor), mientras C1, C2 y C4 mantuvieron niveles bajos y similares.

El ranking global promedio sintetizó estas tendencias: ESS favoreció a C1 y C3 (2.25 y 2.38), la amplitud favoreció claramente a C4 (1.63), y en chattering C1, C2 y C4 empataron con buen desempeño (2.00), dejando a C3 rezagado (4.00).

La estabilidad de resultados (confiabilidad) refuerza estas conclusiones: C4 concentró el mayor porcentaje de métricas con alta confiabilidad (75 %), seguido por C2 (66.7 %) y C1 (58.3 %), mientras que C3 mostró la mayor sensibilidad al ruido con predominio de baja confiabilidad, lo que respalda la preferencia por C4 cuando la prioridad es operar con variabilidad contenida bajo incertidumbre.

Síntesis final

En conclusión, este trabajo demuestra que el enfoque MF-SMC, combinado con una sintonización multiobjetivo mediante Algoritmos Genéticos, es una base robusta y viable para el control de la producción de hidrógeno. La elección del controlador óptimo no es única, sino que depende de lo que se priorice. Por lo tanto, se tiene que:

- Para Máxima fiabilidad (mantener la producción en rango), C3 es la mejor opción, pero debe establecerse un mantenimiento regular de los actuadores.
- Para una máxima estabilidad y amortiguación del ruido, C4 ofrece el mejor manejo de la amplitud en escenarios estocásticos.
- Para un rendimiento equilibrado, C1 y C2 son las opciones más recomendables, siendo C2 ligeramente superior en suavidad de control y C1 en precisión.

Estos hallazgos no solo demuestran que es posible mantener una producción de hidrógeno estable mediante MF-SMC, sino que también trazan un camino claro para la selección informada de estrategias de control.

REFERENCIAS BIBLIOGRÁFICAS

- Abawalo, M., Pikon, K., Landrat, M., & Scierski, W. (2025). Hydrogen Production from Biowaste: A Systematic Review of Conversion Technologies, Environmental Impacts, and Future Perspectives. *Energies*, 18(17), 4520. <https://doi.org/10.3390/en18174520>
- Abdalah, M. (2020). Modeling reactor-focused energy balances for multi-stage CSTR anaerobic digestion systems. *Journal of Renewable and Sustainable Energy*, 12(6), 065502. <https://doi.org/10.1063/5.0013954>
- Aceves-Lara, C., Latrille, E., Bernet, N., Buffière, P., & Steyer, J.-P. (2008). A pseudo-stoichiometric dynamic model of anaerobic hydrogen production from molasses. *Water research*, 42, 2539-50. <https://doi.org/10.1016/j.watres.2008.02.018>
- Adjisetya, M., & Wahid, A. (2023). Multivariable Model Predictive Control to Control Bio-H₂ Production from Biomass. *ChemEngineering*, 7(1), 7. <https://doi.org/10.3390/chemengineering7010007>
- Aghajani Delavar, M., & Wang, J. (2021). Numerical investigation of pH control on dark fermentation and hydrogen production in a microbioreactor. *Fuel*, 292, 120355. <https://doi.org/10.1016/j.fuel.2021.120355>
- Ahmad Joharee, N. A., Ali, J. M., Mohd Fuad, M. N., & Abd Rahman, N. (2021). Simulation of process control for production of 5-HMF from old coconut water. *IOP Conference Series: Materials Science and Engineering*, 1192(1), 012020. <https://doi.org/10.1088/1757-899X/1192/1/012020>
- Ajee, K. L., Valsan, A., & Sankaran, R. (2024). Choosing the right statistical test: A guide for data analysis. *Amrita Journal of Medicine*, 20(2), 86-88. https://doi.org/10.4103/AMJM.AMJM_27_24
- Alcaraz–Gonzalez, V., Rodriguez–Valenzuela, G., Gomez–Martinez, J. J., Dotto, G. L., & Flores–Estrella, R. A. (2021). Hydrogen production automatic control in continuous microbial electrolysis cells reactors used in wastewater treatment. *Journal of Environmental Management*, 281, 111869. <https://doi.org/10.1016/j.jenvman.2020.111869>
- Alnaib, I. I., Alsammak, A. N., & Mohammed, K. K. (2025). Brushless DC motor drive with optimal fractional-order sliding-mode control based on a genetic algorithm. *Electrical*

Engineering and Electromechanics, (2), 19-23. <https://doi.org/10.20998/2074-272X.2025.2.03>

- Andrade Da Silva, J. M., Teppa Garrán, P. A., & Ferrer Suárez, J. J. (2005). Control de Sistemas No Lineales de datos muestreados a través de un enfoque de ganancia programada difusa por Modo Deslizante. *Revista de la Facultad de Ingeniería Universidad Central de Venezuela*, 20(2), 15-27. http://ve.scielo.org/scielo.php?script=sci_abstract&pid=S0798-40652005000200002&lng=es&nrm=iso&tlng=es
- Anwar, M., Lou, S., Chen, L., Li, H., & Hu, Z. (2019). Recent advancement and strategy on bio-hydrogen production from photosynthetic microalgae. *Bioresource Technology*, 292, 121972. <https://doi.org/10.1016/j.biortech.2019.121972>
- Arachchige, C. N. P. G., Prendergast, L. A., & Staudte, R. G. (2020). Robust analogs to the coefficient of variation. *Journal of Applied Statistics*, 49(2), 268-290. <https://doi.org/10.1080/02664763.2020.1808599>
- Arevalo-Castiblanco, M. F., Rodriguez-Garavito, C. H., Patiño-Forero, A. A., & Salazar-Caceres, J. F. (2020). Controlador LQR y SMC Aplicado a Plataformas Pendulares. (arXiv:2002.04684). <https://doi.org/10.48550/arXiv.2002.04684>
- Automation and Robotics*. (2008). IntechOpen.
- Azeez, M. I., Abdelhaleem, A. M. M., Elnaggar, S., Moustafa, K. A. F., & Atia, K. R. (2023). Optimized sliding mode controller for trajectory tracking of flexible joints three-link manipulator with noise in input and output. *Scientific Reports*, 13, 12518. <https://doi.org/10.1038/s41598-023-38855-7>
- Basak, B., Jeon, B.-H., Kim, T. H., Lee, J.-C., Chatterjee, P. K., & Lim, H. (2020). Dark fermentative hydrogen production from pretreated lignocellulosic biomass: Effects of inhibitory byproducts and recent trends in mitigation strategies. *Renewable and Sustainable Energy Reviews*, 133, 110338. <https://doi.org/10.1016/j.rser.2020.110338>
- Bechara, R. (2022). Improvements to the ADM1 based Process Simulation Model: Reaction segregation, parameter estimation and process optimization. *Heliyon*, 8(12), e11793. <https://doi.org/10.1016/j.heliyon.2022.e11793>

- Benatti, A., & Costa, L. d. F. (2024). Agglomerative Clustering in Uniform and Proportional Feature Spaces [arXiv:2407.08604], (arXiv:2407.08604). <https://doi.org/10.48550/arXiv.2407.08604>
- Bensaada, M., & Boudghene Stambouli, A. (2013). A practical design sliding mode controller for DC–DC converter based on control parameters optimization using assigned poles associate to genetic algorithm. *International Journal of Electrical Power and Energy Systems*, 53, 761-773. <https://doi.org/10.1016/j.ijepes.2013.05.043>
- Bobbitt, Z. (2019, abril). A Guide to Using Post Hoc Tests with ANOVA. <https://www.statology.org/anova-post-hoc-tests/>
- Bolatkhani, K., Kossalbayev, B. D., Zayadan, B. K., Tomo, T., Veziroglu, T. N., & Allakhverdiev, S. I. (2019). Hydrogen production from phototrophic microorganisms: Reality and perspectives. *International Journal of Hydrogen Energy*, 44(12), 5799-5811. <https://doi.org/10.1016/j.ijhydene.2019.01.092>
- Brindhadevi, K., Shanmuganathan, R., Pugazhendhi, A., Gunasekar, P., & Manigandan, S. (2021). Biohydrogen production using horizontal and vertical continuous stirred tank reactor- a numerical optimization. *International Journal of Hydrogen Energy*, 46(20), 11305-11312. <https://doi.org/10.1016/j.ijhydene.2020.06.155>
- Castelló, E., Nunes Ferraz-Junior, A. D., Andreani, C., Anzola-Rojas, M. d. P., Borzacconi, L., Buitrón, G., Carrillo-Reyes, J., Gomes, S. D., Maintinguer, S. I., Moreno-Andrade, I., Palomo-Briones, R., Razo-Flores, E., Schiappacasse-Dasati, M., Tapia-Venegas, E., Valdez-Vázquez, I., Vesga-Baron, A., Zaiat, M., & Etchebehere, C. (2020). Stability problems in the hydrogen production by dark fermentation: Possible causes and solutions. *Renewable and Sustainable Energy Reviews*, 119, 109602. <https://doi.org/10.1016/j.rser.2019.109602>
- Cherkasov, N., Adams, S. J., Bainbridge, E. G. A., & Thornton, J. A. M. (2023). Continuous stirred tank reactors in fine chemical synthesis for efficient mixing, solids-handling, and rapid scale-up. *Reaction Chemistry and Engineering*, 8(2), 266-277. <https://doi.org/10.1039/D2RE00232A>
- Chezeau, B., & Vial, C. (2019, enero). Chapter 19 - Modeling and Simulation of the Biohydrogen Production Processes. En A. Pandey, S. V. Mohan, J.-S. Chang, P. C. Hallenbeck

- & C. Larroche (Eds.), *Biohydrogen (Second Edition)* (pp. 445-483). Elsevier. <https://www.sciencedirect.com/science/article/pii/B9780444642035000198>
- Chi, K.-Y., Li, M.-Y., Chen, C., Kang, E., & Taiwan, C. (2023). Ten circumstances and solutions for finding the sample mean and standard deviation for meta-analysis. *Systematic Reviews*, 12(1), 62. <https://doi.org/10.1186/s13643-023-02217-1>
- Chicco, D., Sichenze, A., & Jurman, G. (2025). A simple guide to the use of Student's t-test, Mann-Whitney U test, Chi-squared test, and Kruskal-Wallis test in biostatistics. *BioData Mining*, 18(1), 56. <https://doi.org/10.1186/s13040-025-00465-6>
- Ciaramella, A., Nardone, D., & Staiano, A. (2020). Data integration by fuzzy similarity-based hierarchical clustering. *BMC Bioinformatics*, 21(10), 350. <https://doi.org/10.1186/s12859-020-03567-6>
- Corbari, S. D. M. L., Andreani, C. L., Torres, D. G. B., Eng, F., & Gomes, S. D. (2019). Strategies to improve the biohydrogen production from cassava wastewater in fixed-bed reactors. *International Journal of Hydrogen Energy*, 44(32), 17214-17223. <https://doi.org/10.1016/j.ijhydene.2019.04.242>
- Couto, P. T., Eng, F., Naessens, W., Nopens, I., Zaiat, M., & Ribeiro, R. (2020). Modelling sugarcane vinasse processing in an acidogenic reactor to produce hydrogen with an ADM1-based model. *International Journal of Hydrogen Energy*, 45(11), 6217-6230. <https://doi.org/10.1016/j.ijhydene.2019.12.206>
- Daraz, U., Almulhim, F. A., Alomair, M. A., & Alomair, A. M. (2025). Population Median Estimation Using Auxiliary Variables: A Simulation Study with Real Data Across Sample Sizes and Parameters. *Mathematics*, 13(10), 1660. <https://doi.org/10.3390/math13101660>
- Dash, S. K., Chakraborty, S., & Elangovan, D. (2023). A Brief Review of Hydrogen Production Methods and Their Challenges. *Energies*, 16(3), 1141. <https://doi.org/10.3390/en16031141>
- De Figueiredo, R., Toso, B., & Schmith, J. (2023, noviembre). Auto-Tuning PID Controller Based on Genetic Algorithm. En M. Shamsuzzoha & G. Lloyds Raja (Eds.), *Disturbance Rejection Control*. IntechOpen. <https://doi.org/10.5772/intechopen.110143>

- Derbeli, M., Barambones, O., Farhat, M., Ramos-Hernanz, J. A., & Sbita, L. (2020). Robust high order sliding mode control for performance improvement of PEM fuel cell power systems. *International Journal of Hydrogen Energy*, 45(53), 29222-29234. <https://doi.org/10.1016/j.ijhydene.2020.07.172>
- Diop, A., El-Malki, N., Chevalier, M., Péninou, A., Roman-Jimenez, G., & Teste, O. (2025). Simrec: a similarity measure recommendation system for mixed data clustering algorithms. *Journal of Big Data*, 12(1), 43. <https://doi.org/10.1186/s40537-024-01052-y>
- Dolat, M., Murali, R., Zarei, M., Zhang, R., Pincam, T., Liu, Y.-Q., Sadhukhan, J., Bywater, A., & Short, M. (2024). Dynamic feed scheduling for optimised anaerobic digestion: an optimisation approach for better decision-making to enhance revenue and environmental benefits. *Digital Chemical Engineering*, 13. <https://doi.org/10.1016/j.dche.2024.100191>
- Dzulkarnain, E. L. N., Audu, J. O., Wan Dagang, W. R. Z., & Abdul-Wahab, M. F. (2022). Microbiomes of biohydrogen production from dark fermentation of industrial wastes: current trends, advanced tools and future outlook. *Bioresources and Bioprocessing*, 9(1), 16. <https://doi.org/10.1186/s40643-022-00504-8>
- Elerakey, N., Rasmey, A.-H. M., Aboseidah, A. A., & Hawary, H. (2024). Mathematical modeling of biohydrogen production via dark fermentation of fruit peel wastes by *Clostridium butyricum* NE95. *BMC Biotechnology*, 24(1), 105. <https://doi.org/10.1186/s12896-024-00925-7>
- Elerakey, N., Rasmey, A.-H. M., Mohammed, Y. M., Aboseidah, A. A., & Hawary, H. (2025). Maximizing biohydrogen production from watermelon peels using *Clostridium butyricum* NE133: a statistical optimization approach with Plackett–Burman and Box–Behnken designs. *Biotechnology for Biofuels and Bioproducts*, 18(1), 54. <https://doi.org/10.1186/s13068-025-02652-3>
- Emeka, E. D. O., & Onuora, E. O. (2024). Continuous Stir Tank Reactor Plant: A Process Review Perspective. *International Journal of Progressive Sciences and Technologies*, 48(1), 494-506. <https://doi.org/10.52155/ijpsat.v48.1.6869>
- Fonseca, L. (2022). Dark Fermentation - Where is the market? <https://aquaenviro.co.uk/dark-fermentation-where-is-the-market/>

- Frost, J. (s.f.). Using Post Hoc Tests with ANOVA. <https://statisticsbyjim.com/anova/post-hoc-tests-anova/>
- Gani, M. M., Islam, M. S., & Ullah, M. A. (2019). Optimal PID tuning for controlling the temperature of electric furnace by genetic algorithm. *SN Applied Sciences*, 1(8), 880. <https://doi.org/10.1007/s42452-019-0929-y>
- García-Depraect, O., Castro-Muñoz, R., Muñoz, R., Rene, E. R., León-Becerril, E., Valdez-Vazquez, I., Kumar, G., Reyes-Alvarado, L. C., Martínez-Mendoza, L. J., Carrillo-Reyes, J., & Buitrón, G. (2021). A review on the factors influencing biohydrogen production from lactate: The key to unlocking enhanced dark fermentative processes. *Bioresource Technology*, 324, 124595. <https://doi.org/10.1016/j.biortech.2020.124595>
- Gerdtsen, Z. P., Daoutidis, P., & Hu, W.-S. (2004). Non-linear reduction for kinetic models of metabolic reaction networks. *Metabolic Engineering*, 6(2), 140-154. <https://doi.org/10.1016/j.ymben.2003.11.003>
- Ghani, M. F., Ghazali, R., Jaafar, H. I., Soon, C. C., Sam, Y. M., & Has, Z. (2022). Improved Third Order PID Sliding Mode Controller for Electrohydraulic Actuator Tracking Control. *Journal of Robotics and Control (JRC)*, 3(2), 219-226. <https://doi.org/10.18196/jrc.v3i2.14236>
- González-Estrada, E., Villaseñor, J. A., & Acosta-Pech, R. (2022). Shapiro-Wilk test for multivariate skew-normality. *Computational Statistics*, 37(4), 1985-2001. <https://doi.org/10.1007/s00180-021-01188-y>
- González-García, J., Gómez-Espinosa, A., García-Valdovinos, L. G., Salgado-Jiménez, T., Cuan-Urquizo, E., & Escobedo Cabello, J. A. (2022). Experimental Validation of a Model-Free High-Order Sliding Mode Controller with Finite-Time Convergence for Trajectory Tracking of Autonomous Underwater Vehicles. *Sensors*, 22(2), 488. <https://doi.org/10.3390/s22020488>
- Goveas, L. C., Nayak, S., Kumar, P. S., Vinayagam, R., Selvaraj, R., & Rangasamy, G. (2024). Recent advances in fermentative biohydrogen production. *International Journal of Hydrogen Energy*, 54, 200-217. <https://doi.org/10.1016/j.ijhydene.2023.04.208>

- Harivardhagini, S. (2019). Acidic Control of a Chemical Plant Implementing Non Linear Controllers. *International Journal of Innovative Technology and Exploring Engineering*, 8(10), 54-58. <https://doi.org/10.35940/ijitee.I8623.0881019>
- Hassan, M. A., Cao, Z., & Man, Z. (2023). Hyperbolic-Secant-Function-Based Fast Sliding Mode Control for Pantograph Robots. *Machines*, 11(10), 941. <https://doi.org/10.3390/machines11100941>
- Hassan, Q., Algburi, S., Sameen, A. Z., Salman, H. M., & Al-Jiboory, A. K. (2024). A review of green hydrogen production by renewable resources. *Energy Harvesting and Systems*, 11(1). <https://doi.org/10.1515/ehs-2022-0127>
- Hassan, S. R., Hung, Y.-T., Dahlan, I., & Abdul Aziz, H. (2022). Kinetic Study of the Anaerobic Digestion of Recycled Paper Mill Effluent (RPME) by Using a Novel Modified Anaerobic Hybrid Baffled (MAHB) Reactor. *Water*, 14(3), 390. <https://doi.org/10.3390/w14030390>
- Hinduja, H. (2023, mayo). Comparative Analysis of Popular Statistical Tests: Which One to Use When? <https://pub.towardsai.net/comparative-analysis-of-popular-statistical-tests-which-one-to-use-when-95fce172a81f>
- Hui, J., Ling, J., & Yuan, J. (2020). HGO-based adaptive super-twisting sliding mode power level control with prescribed performance for modular high-temperature gas-cooled reactors. *Annals of Nuclear Energy*, 143, 107416. <https://doi.org/10.1016/j.anucene.2020.107416>
- Jaradat, M., Almashaileh, S., Bendea, C., Juaidi, A., Bendea, G., & Bungau, T. (2024). Green Hydrogen in Focus: A Review of Production Technologies, Policy Impact, and Market Developments. *Energies*, 17(16), 1-27. <https://ideas.repec.org/a/gam/jeners/v17y2024i16p3992-d1454835.html>
- Jiang, F., Peng, Z., Li, H., Li, J., & Wang, S. (2020). Effect of Hydraulic Retention Time on Anaerobic Baffled Reactor Operation: Enhanced Biohydrogen Production and Enrichment of Hydrogen-producing Acetogens. *Processes*, 8(3), 339. <https://doi.org/10.3390/pr8030339>
- Karapinar, I., Gokfiliz Yildiz, P., Pamuk, R. T., & Karaosmanoglu Gorgec, F. (2020). The effect of hydraulic retention time on thermophilic dark fermentative biohydrogen production

- in the continuously operated packed bed bioreactor. *International Journal of Hydrogen Energy*, 45(5), 3524-3531. <https://doi.org/10.1016/j.ijhydene.2018.12.195>
- Kasprzak, J., & Marinova, M. (2025). Development of Process Configurations and Simulation of Biofuel Production. *Energies*, 18(17), 4713. <https://doi.org/10.3390/en18174713>
- Khan, A. (s.f.). A QUICK INTRODUCTION TO SLIDING MODE CONTROL AND ITS APPLICATIONS. https://www.academia.edu/36218899/A_QUICK_INTRODUCTION_TO_SLIDING_MODE_CONTROL_AND_ITS_APPLICATIONS
- Khazaei, T., Williams, R. L., Bogatyrev, S. R., Doyle, J. C., Henry, C. S., & Ismagilov, R. F. (2020). Metabolic multistability and hysteresis in a model aerobe-anaerobe microbiome community. *Science Advances*, 6(33), eaba0353. <https://doi.org/10.1126/sciadv.aba0353>
- Khodadadi, M., Shahbazian, M., & Aghajani, M. (2015). A Novel Approach in Design of Model-free Fuzzy Sliding Mode Controller to SISO Chemical Processes. *Journal of Automation and Control*, 3(1), 1-9. <https://doi.org/10.12691/automation-3-1-1>
- Kontodimos, I., Evaggelou, C., Margaritis, N., Grammelis, P., & Goula, M. (2025). Dark Fermentation and Anaerobic Digestion for H₂ and CH₄ Production, from Food Waste Leachates. *Methane*, 4(2), 11. <https://doi.org/10.3390/methane4020011>
- Koundi, M., El Fadil, H., Lassioui, A., & El Asri, Y. (2025). Adaptive Sliding Mode Control of an Interleaved Buck Converter–Proton Exchange Membrane Electrolyzer for a Green Hydrogen Production System. *Processes*, 13(3), 795. <https://doi.org/10.3390/pr13030795>
- Kroeger, C. M., Ejima, K., Hannon, B. A., Halliday, T. M., McComb, B., Teran-Garcia, M., Dawson, J. A., King, D. B., Brown, A. W., & Allison, D. B. (2021). Persistent confusion in nutrition and obesity research about the validity of classic nonparametric tests in the presence of heteroscedasticity: evidence of the problem and valid alternatives. *The American Journal of Clinical Nutrition*, 113(3), 517-524. <https://doi.org/10.1093/ajcn/nqaa357>
- Kumar, M., Pandit, S., Patel, V., & Das, D. (2022). Maximization of Energy Recovery from Starch Processing Wastewater by Thermophilic Dark Fermentation Coupled with Microbial fuel Cell Technology. <https://doi.org/10.1101/2022.10.25.513786>

- Kuterbekov, K. A., Bekmyrza, K. Z., Kabyshev, A. M., Kubenova, M. M., & Shokatian-Beiragh, M. (2024). Fuzzy controller system utilization to increase the hydrogen production bioreactor capacity: toward sustainability and low carbon technology. *International Journal of Low-Carbon Technologies*, 19, 667-675. <https://ideas.repec.org/a/oup/ijlctc/v19y2024ip667-675.html>
- Lara-Musule, A., Alvarez-Sanchez, E., Trejo-Aguilar, G., Acosta-Dominguez, L., Puebla, H., & Hernandez-Martinez, E. (2021). Diagnosis and Monitoring of Volatile Fatty Acids Production from Raw Cheese Whey by Multiscale Time-Series Analysis. *Applied Sciences*, 11(13), 5803. <https://doi.org/10.3390/app11135803>
- Levy, A., Shalom, B. R., & Chalamish, M. (2025). A guide to similarity measures and their data science applications. *Journal of Big Data*, 12(1), 188. <https://doi.org/10.1186/s40537-025-01227-1>
- Li, H., Wang, H., Tian, Y., & Christov, N. (2025). Maximum extrem biogas yield prediction based tracking control for two-stage anaerobic digestion using CKF robust observer feedback. *Journal of Process Control*, 155, 103558. <https://doi.org/10.1016/j.jprocont.2025.103558>
- Li, W., Cai, T., Lu, X., Han, Y., kudisi, D., Chang, G., Dong, K., & Zhen, G. (2023). Two-Phase improves Bio-hydrogen and Bio-methane production of anaerobic membrane bioreactor from waste activated sludge with digestate recirculation. *Chemical Engineering Journal*, 452, 139547. <https://doi.org/10.1016/j.cej.2022.139547>
- Li, Y., Ng, K. C., Murray-Smith, D. J., Gray, G. J., & Sharman, K. C. (1996). Genetic algorithm automated approach to the design of sliding mode control systems. *International Journal of Control*, 63(4), 721-739. <https://doi.org/10.1080/00207179608921865>
- Liu, W., Ye, H., & Yang, X. (2023). Model-Free Adaptive Sliding Mode Control Method for Unmanned Surface Vehicle Course Control. *Journal of Marine Science and Engineering*, 11(10), 1904. <https://doi.org/10.3390/jmse11101904>
- Lopez, J. (s.f.). Effect of Heterogeneity of Variance on the performance of ANOVA F-test and its Alternatives: Simulation Based Study. <https://doi.org/10.15760/HONORS.806>
- López Pérez, P. A., Neria-González, M. I., & Aguilar López, R. (2015). Increasing the bio-hydrogen production in a continuous bioreactor via nonlinear feedback controller.

- International Journal of Hydrogen Energy*, 40(48), 17224-17230. <https://doi.org/10.1016/j.ijhydene.2015.09.106>
- López-Peréz, P. A., Rodríguez-Mata, A. E., Hernández-González, O., Amabilis-Sosa, L. E., Baray-Arana, R., & Leon-Borges, J. (2022). Design of a Robust sliding mode controller for bioreactor cultures in overflow metabolism via an interdisciplinary approach. *Open Chemistry*, 20(1), 120-129. <https://doi.org/10.1515/chem-2021-0098>
- MacMillan, A., Preston, D., Wolfe, J., & Yu, S. (2022, octubre). 13.1: Estadísticas básicas: media, mediana, promedio, desviación estándar, puntuaciones z y valor p. [https://espanol.libretexts.org/Bookshelves/Ingenieria/Ingenieria_Industrial_y_de_Sistemas/Libro%3A_Din%C3%A1mica_y_Control_de_Procesos_Qu%C3%ADmicos_\(Woolf\)/13%3A_Estad%C3%ADsticas_y_antecedentes_probabil%C3%ADsticos/13.01%3A_Estad%C3%ADsticas_b%C3%A1sicas](https://espanol.libretexts.org/Bookshelves/Ingenieria/Ingenieria_Industrial_y_de_Sistemas/Libro%3A_Din%C3%A1mica_y_Control_de_Procesos_Qu%C3%ADmicos_(Woolf)/13%3A_Estad%C3%ADsticas_y_antecedentes_probabil%C3%ADsticos/13.01%3A_Estad%C3%ADsticas_b%C3%A1sicas)
- Mandalika, A. S., Chou, K. J., & Decker, S. R. (2024). Biohydrogen: prospects for industrial utilization and energy resiliency in rural communities. *Frontiers in Industrial Microbiology*, 2. <https://doi.org/10.3389/finmi.2024.1428686>
- Manohar, K. (2020, noviembre). PID tuning using Machine Learning. <https://medium.com/@maohar502/pid-tuning-using-machine-learning-6cf6f7fe5690>
- Martínez-Fraile, C., Muñoz, R., Simorte, M. T., Sanz, I., & Garcia-Depraect, O. (2025). Biohydrogen Production from the Organic Fraction of Municipal Solid Waste Via Thermophilic Lactate-Driven Dark Fermentation. <https://doi.org/10.2139/ssrn.5212601>
- MATLAB. (s.f.). How the Genetic Algorithm Works. <https://www.mathworks.com/help/gads/how-the-genetic-algorithm-works.html>
- Mavrinac, M., Lorencin, I., Car, Z., & Šercer, M. (2022). Genetic Algorithm-Based Parametrization of a PI Controller for DC Motor Control. *Tehnički glasnik*, 16(1), 16-22. <https://doi.org/10.31803/tg-20201119185015>
- Mazzoli, R., Pescarolo, S., Gilli, G., Gilardi, G., & Valetti, F. (2024). Hydrogen production pathways in Clostridia and their improvement by metabolic engineering. *Biotechnology Advances*, 73, 108379. <https://doi.org/10.1016/j.biotechadv.2024.108379>
- Mirzal, A., Yoshii, S., & Furukawa, M. (2006). PID Parameters Optimization by Using Genetic Algorithm: A Study on Time-delay Systems. *ISTECS Journal*, 8, 34-43.

- Mishra, P., Wahid, Z. A., Karim, A., Pant, K. K., Ghosh, P., Kumar, D., & Singh, L. (2022). Chronological perspective on fermentative-hydrogen from hypothesis in early nineteenth century to recent developments: a review. *Biomass Conversion and Biorefinery*, 12(9), 3711-3723. <https://doi.org/10.1007/s13399-020-01180-4>
- Mohamed, M. A. E., Jagatheesan, K., & Anand, B. (2023). Modern PID/FOPID controllers for frequency regulation of interconnected power system by considering different cost functions. *Scientific Reports*, 13(1), 14084. <https://doi.org/10.1038/s41598-023-41024-5>
- Mohanakrishna, G., Sneha, N. P., Rafi, S. M., & Sarkar, O. (2023). Dark fermentative hydrogen production: Potential of food waste as future energy needs. *The Science of the Total Environment*, 888, 163801. <https://doi.org/10.1016/j.scitotenv.2023.163801>
- Moin, N. (1995). Sliding mode control design using genetic algorithms. *1st International Conference on Genetic Algorithms in Engineering Systems: Innovations and Applications (GALESIA)*, 1995, 238-244. <https://doi.org/10.1049/cp:19951055>
- Mokhtarani, B., Zanganeh, J., & Moghtaderi, B. (2025). A Review on Biohydrogen Production Through Dark Fermentation, Process Parameters and Simulation. *Energies*, 18(5), 1092. <https://doi.org/10.3390/en18051092>
- Morales, L., Estrada, J. S., Herrera, M., Rosales, A., Leica, P., Gamboa, S., & Camacho, O. (2022). Hybrid Approaches-Based Sliding-Mode Control for pH Process Control. *ACS Omega*, 7(49), 45301-45313. <https://doi.org/10.1021/acsomega.2c05756>
- Moura, F. R., De Medeiros, J. L., & Araújo, O. D. Q. F. (2022). Acetone–Butanol–Ethanol Fermentation Phenomenological Models for Process Studies: Parameter Estimation and Multi-Response Model Reduction with Statistical Analysis. *Processes*, 10(10), 1978. <https://doi.org/10.3390/pr10101978>
- Mudzanani, K. E., Phadi, T. T., Iyuke, S. E., & Daramola, M. O. (2023). Enhancing Methane Production through Anaerobic Co-Digestion of Sewage Sludge: A Modified ADM1 Model Approach. *Fermentation*, 9(9), 833. <https://doi.org/10.3390/fermentation9090833>
- Nirmala, N., Praveen, G., AmitKumar, S., SundarRajan, P., Baskaran, A., Priyadharsini, P., SanjayKumar, S., Dawn, S., Pavithra, K. G., Arun, J., & Pugazhendhi, A. (2023). A review on biological biohydrogen production: Outlook on genetic strain enhancements,

- reactor model and techno-economics analysis. *Science of The Total Environment*, 896, 165143. <https://doi.org/10.1016/j.scitotenv.2023.165143>
- NREL/VirtualEngineering. (2025, septiembre). <https://github.com/NREL/VirtualEngineering>
- Nwobi, F. (s.f.). Power comparison of ANOVA and Kruskal–Wallis tests when error assumptions are violated. *Advances in Methodology and Statistics*. <https://doi.org/10.51936/LTGT2135>
- Obando, C., Rojas, R., Ulloa, F., & Camacho, O. (2023). Dual-Mode Based Sliding Mode Control Approach for Nonlinear Chemical Processes. *ACS Omega*, 8(10), 9511-9525. <https://doi.org/10.1021/acsomega.2c08201>
- Oh, K., & Seo, J. (2022). Development of a Sliding-Mode-Control-Based Path-Tracking Algorithm with Model-Free Adaptive Feedback Action for Autonomous Vehicles. *Sensors*, 23(1), 405. <https://doi.org/10.3390/s23010405>
- Omeke, W. C., Mbamalu, E. E., & Uwagbaoje, O. F. (2024). Design and Mechanical Analysis of a Continuous Stirred Tank Reactor (CSTR) for the Optimum Operation and Production of Propylene Glycol from Propylene Oxide Hydrolysis. *Sustainable Chemical Engineering*, 367-383. <https://doi.org/10.37256/sce.5220244713>
- Ouyang, T., Ma, F., Zhu, B., Ji, P., & Lian, L. (2022). Fuzzy Sliding Mode Control for Microbial Fuel Cells. *Machines*, 10(5), 320. <https://doi.org/10.3390/machines10050320>
- Palomo-Briones, R., Celis, L. B., Méndez-Acosta, H. O., Bernet, N., Trably, E., & Razo-Flores, E. (2019). Enhancement of mass transfer conditions to increase the productivity and efficiency of dark fermentation in continuous reactors. *Fuel*, 254, 115648. <https://doi.org/10.1016/j.fuel.2019.115648>
- Parra, R., Chicaiza-Ortiz, C., Herrera-Feijoo, R. J., Arellano-Yasaca, D. V., Lee, L.-C., Supetulan, R. X., & Marti-Herrero, J. (2025). Advancements of Biohydrogen Production Based on Anaerobic Digestion: Technologies, Substrates, and Future Prospects. *Sci*, 7(2), 52. <https://doi.org/10.3390/sci7020052>
- Pätsi, T., Ohenoja, M., Kukkasniemi, H., Vuolio, T., Österberg, P., Merikoski, S., Joutsijoki, H., & Ruusunen, M. (2023). Comparison of Single Control Loop Performance Monitoring Methods. *Applied Sciences*, 13(12), 6945. <https://doi.org/10.3390/app13126945>

- Prabakar, D., Manimudi, V. T., Suvetha K, S., Sampath, S., Mahapatra, D. M., Rajendran, K., & Pugazhendhi, A. (2018). Advanced biohydrogen production using pretreated industrial waste: Outlook and prospects. *Renewable and Sustainable Energy Reviews*, 96, 306-324. <https://doi.org/10.1016/j.rser.2018.08.006>
- Preud'homme, G., Duarte, K., Dalleau, K., Lacomblez, C., Bresso, E., Smaïl-Tabbone, M., Couceiro, M., Devignes, M.-D., Kobayashi, M., Huttin, O., Ferreira, J. P., Zannad, F., Rossignol, P., & Girerd, N. (2021). Head-to-head comparison of clustering methods for heterogeneous data: a simulation-driven benchmark. *Scientific Reports*, 11(1), 4202. <https://doi.org/10.1038/s41598-021-83340-8>
- Puiman, L., Almeida Benalcázar, E., Picioreanu, C., Noorman, H. J., & Haringa, C. (2023). Downscaling Industrial-Scale Syngas Fermentation to Simulate Frequent and Irregular Dissolved Gas Concentration Shocks. *Bioengineering*, 10(5), 518. <https://doi.org/10.3390/bioengineering10050518>
- Ramasamy, G., Goodman, A. H., Lahuri, H. M., Md Shah, S. S., & Sabil, K. M. (2022). Process simulation of anaerobic digestion for methane production using aspen plus. *IOP Conference Series: Materials Science and Engineering*, 1257(1), 012002. <https://doi.org/10.1088/1757-899X/1257/1/012002>
- Ramli, N. M., & Mohamad, M. S. (2017). Modelling for Temperature Non-Isothermal Continuous Stirred Tank Reactor Using Fuzzy Logic. *International Journal of Environmental and Ecological Engineering*, 11(2), 169-175. <https://publications.waset.org/vol/122>
- Ramprakash, B., Lindblad, P., Eaton-Rye, J. J., & Incharoensakdi, A. (2022). Current strategies and future perspectives in biological hydrogen production: A review. *Renewable and Sustainable Energy Reviews*, 168, 112773. <https://doi.org/10.1016/j.rser.2022.112773>
- Regueira-Marcos, L., Garcia-Depraect, O., & Munoz, R. (2024). Continuous Two-Stage Lactate-Driven Dark Fermentation Process for Enhanced Biohydrogen Production from Food Waste. <https://doi.org/10.2139/ssrn.4893234>
- Regueira-Marcos, L., Munoz, R., & Garcia-Depraect, O. (2023). Continuous Lactate-Driven Dark Fermentation of Restaurant Food Waste: Process Characterization and New Insights on Transient Feast/Famine Perturbations. <https://doi.org/10.2139/ssrn.4443158>

- Renaudie, M., Dumas, C., Vuilleumier, S., & Ernst, B. (2021). Biohydrogen production in a continuous liquid/gas hollow fiber membrane bioreactor: Efficient retention of hydrogen producing bacteria via granule and biofilm formation. *Bioresource Technology*, 319, 124203. <https://doi.org/10.1016/j.biortech.2020.124203>
- Rezk, H., Olabi, A. G., Abdelkareem, M. A., Alami, A. H., & Sayed, E. T. (2023). Optimal Parameter Determination of Membrane Bioreactor to Boost Biohydrogen Production-Based Integration of ANFIS Modeling and Honey Badger Algorithm. <https://www.h2knowledgecentre.com/content/journal4908>
- Ri, P.-C., Kim, J.-S., Kim, T.-R., Pang, C.-H., Mun, H.-G., Pak, G.-C., & Ren, N.-Q. (2019). Effect of hydraulic retention time on the hydrogen production in a horizontal and vertical continuous stirred-tank reactor. *International Journal of Hydrogen Energy*, 44(33), 17742-17749. <https://doi.org/10.1016/j.ijhydene.2019.05.136>
- Rincón, A., Erazo Ordoñez, C. C., Londoño, F., Olivar Tost, G., & Angulo, F. (2014). A New Robust Controller with Applications to Bioreactors (S. Wen, Ed.). *Mathematical Problems in Engineering*, 2014(1), 375928. <https://doi.org/10.1155/2014/375928>
- Roeva, O., Chorukova, E., & Kabaivanova, L. (2025). Advanced Mathematical Modeling of Hydrogen and Methane Production in a Two-Stage Anaerobic Co-Digestion System. *Mathematics*, 13(10), 1601. <https://doi.org/10.3390/math13101601>
- Saha, R., Bhattacharya, D., & Mukhopadhyay, M. (2022). Enhanced production of biohydrogen from lignocellulosic feedstocks using microorganisms: A comprehensive review. *Energy Conversion and Management: X*, 13, 100153. <https://doi.org/10.1016/j.ecmx.2021.100153>
- Sardella, M. F., Serrano, E., Camacho, O., & Scaglia, G. (2021). Improvement of Linear Algebra Controllers using Sliding Surface Concepts: Applications to Chemical Processes. *IEEE Latin America Transactions*, 19(8), 1299-1306. <https://doi.org/10.1109/TLA.2021.9475860>
- Sarhadi, P. (2025). On the Standard Performance Criteria for Applied Control Design: PID, MPC or Machine Learning Controller? [arXiv:2503.14379], (arXiv:2503.14379). <https://doi.org/10.48550/arXiv.2503.14379>

- Sharma, P., Ghosh, U. K., & Ray, A. K. (2016). Kinetic Model for Anaerobic Digestion of Distillery Spent Wash. *American Journal of Chemical Engineering*, 4(6), 139-146. <https://doi.org/10.11648/j.ajche.20160406.11>
- Shatz, I. (2024). Assumption-checking rather than (just) testing: The importance of visualization and effect size in statistical diagnostics. *Behavior Research Methods*, 56(2), 826-845. <https://doi.org/10.3758/s13428-023-02072-x>
- Silva Neto, J. V. D., Elaiuy, M. L. C., & Nour, E. A. A. (2019). ADM1 approach to the performance optimisation and biogas H₂S prediction of a large-scale anaerobic reactor fed on sugarcane vinasse. *Water Science and Technology*, 80(9), 1774-1786. <https://doi.org/10.2166/wst.2019.434>
- Sinha, A., & Mishra, R. K. (2018). Control of a nonlinear continuous stirred tank reactor via event triggered sliding modes [arXiv:1712.03360], (arXiv:1712.03360). <https://doi.org/10.48550/arXiv.1712.03360>
- Sivagurunathan, P., Kumar, G., Bakonyi, P., Kim, S.-H., Kobayashi, T., Xu, K. Q., Lakner, G., Tóth, G., Nemestóthy, N., & Bélafi-Bakó, K. (2016). A critical review on issues and overcoming strategies for the enhancement of dark fermentative hydrogen production in continuous systems. *International Journal of Hydrogen Energy*, 41(6), 3820-3836. <https://doi.org/10.1016/j.ijhydene.2015.12.081>
- Soares, J. F., Confortin, T. C., Todero, I., Mayer, F. D., & Mazutti, M. A. (2020). Dark fermentative biohydrogen production from lignocellulosic biomass: Technological challenges and future prospects. *Renewable and Sustainable Energy Reviews*, 117, 109484. <https://doi.org/10.1016/j.rser.2019.109484>
- Souissi, A. (2021). Adaptive sliding mode control of a PEM fuel cell system based on the super twisting algorithm. *Energy Reports*, 7, 3390-3399. <https://doi.org/10.1016/j.egy.2021.05.069>
- Sreemahadevan, S., Sivakumar, K. V., & Palanisamy, M. (2024). Evaluation of the Open Source Process Simulator DWSIM for Bioprocess Simulation. *Periodica Polytechnica Chemical Engineering*, 68(2), 195-202. <https://doi.org/10.3311/PPch.23166>

- Talapko, D., Talapko, J., Eric, I., & Skrlec, I. (2023). Biological Hydrogen Production from Biowaste Using Dark Fermentation, Storage and Transportation. *Energies*, 16(8), 3321. <https://doi.org/10.3390/en16083321>
- Tapia-Venegas, E., Ramirez-Morales, J. E., Silva-Illanes, F., Toledo-Alarcón, J., Paillet, F., Escudie, R., Lay, C.-H., Chu, C.-Y., Leu, H.-J., Marone, A., Lin, C.-Y., Kim, D.-H., Trably, E., & Ruiz-Filippi, G. (2015). Biohydrogen production by dark fermentation: scaling-up and technologies integration for a sustainable system. *Reviews in Environmental Science and Bio/Technology*, 14(4), 761-785. <https://doi.org/10.1007/s11157-015-9383-5>
- Times, C. (2025, febrero). Continuous Stirred Tank Reactor (CSTR): Principles, Assumptions, and Applications. <https://chemicaltimes.in/2025/02/26/continuous-stirred-tank-reactor-cstr-principles-assumptions-and-applications/>
- Todoric, M., & Mastelic, T. (2023). Comparison of Similarity Measures for Trajectory Clustering - Aviation Use Case. *Journal of Communications Software and Systems*, 19(2), 178-187. <https://doi.org/10.24138/jcomss-2022-0116>
- Trevisan, A. P., Lied, E. B., Fuess, L. T., Zaiat, M., de Souza, W. G., Gomes, S. D., & Gomes, B. M. (2024). Improving the Continuous Multiple Tube Reactor: an Innovative Bio-reactor Configuration with Great Potential for Dark Fermentation Processes. *Applied Biochemistry and Biotechnology*, 196(1), 457-477. <https://doi.org/10.1007/s12010-023-04553-3>
- Tukey's range test. (2025, julio). https://en.wikipedia.org/w/index.php?title=Tukey%27s_range_test&oldid=1299739052
- Vasudevan, S., & Rangaiah, G. P. (2010). Criteria for Performance Assessment of Plantwide Control Systems. *Industrial and Engineering Chemistry Research*, 49(19), 9209-9221. <https://doi.org/10.1021/ie1001795>
- Veljkovic, K. (2024). Comparing Confidence Intervals for the Mean of Symmetric and Skewed Distributions. *Symmetry*, 16(11), 1424. <https://doi.org/10.3390/sym16111424>
- Vidovic, S. (2019). Dataset for tree congruence: quantifying similarity between dendrogram topologies. <https://doi.org/10.5258/SOTON/D1069>

- Vongkampang, T., Sreenivas, K., Grey, C., & Van Niel, E. W. J. (2023). Immobilization techniques improve volumetric hydrogen productivity of *Caldicellulosiruptor* species in a modified continuous stirred tank reactor. *Biotechnology for Biofuels and Bioproducts*, 16(1), 25. <https://doi.org/10.1186/s13068-023-02273-8>
- Wang, B., Wang, Z., Chen, T., & Zhao, X. (2020). Development of Novel Bioreactor Control Systems Based on Smart Sensors and Actuators. *Frontiers in Bioengineering and Biotechnology*, 8, 7. <https://doi.org/10.3389/fbioe.2020.00007>
- Weide, T., Hernández Regalado, R. E., Brüggling, E., Wichern, M., & Wetter, C. (2020). Biohydrogen Production via Dark Fermentation with Pig Manure and Glucose Using pH-Dependent Feeding. *Chemical Engineering and Technology*, 43(8), 1578-1587. <https://doi.org/10.1002/ceat.201900678>
- Wicmandy, M., & Tellez-Schmill, R. (2024, diciembre). How to Optimize Green Hydrogen Production Systems Using Dynamic Simulations. <https://www.kbc.global/resources/blog/how-to-optimize-green-hydrogen-production-systems-using-dynamic-simulations/>
- Wilcox, R. R., & Rousselet, G. A. (2023). An Updated Guide to Robust Statistical Methods in Neuroscience. *Current Protocols*, 3(3), e719. <https://doi.org/10.1002/cpz1.719>
- Wodolazski, A., & Smoliński, A. (2022). Bio-Hydrogen Production in Packed Bed Continuous Plug Flow Reactor—CFD-Multiphase Modelling. *Processes*, 10(10), 1907. <https://doi.org/10.3390/pr10101907>
- Wodołażski, A., & Smoliński, A. (2022). Bio-Hydrogen Production in Packed Bed Continuous Plug Flow Reactor—CFD-Multiphase Modelling. *Processes*, 10(10), 1907. <https://doi.org/10.3390/pr10101907>
- Xu, Q., Wang, G., & Fang, S. (2025). Fast Terminal Sliding Mode Control Based on a Novel Fixed-Time Sliding Surface for a Permanent Magnet Arc Motor. *Actuators*, 14(9), 423. <https://doi.org/10.3390/act14090423>
- Yahaya, E., Nandong, J., & Yeo, W. S. (2023). Biohydrogen production: A new controllability criterion for analyzing the impacts of dark fermentation conditions (A. Saptoro, R. Nagarajan, J. Lau, Y. Tiong, V. Rowtho, C. Selvan, A. Tan & C. Koh, Eds.). *MATEC Web of Conferences*, 377, 01010. <https://doi.org/10.1051/mateconf/202337701010>

- Yu, Q., Wang, J., Huang, W., Li, X., Liu, Z., & Dong, H. (2024). Sliding Mode Integral Separation PID Control for Hydrogen Fuel Cell Systems. *Applied Sciences*, 14(17), 7650. <https://doi.org/10.3390/app14177650>
- Zhang, D., Dechatiwongse, P., Del-Rio-Chanona, E. A., Hellgardt, K., Maitland, G. C., & Vassiliadis, V. S. (2015). Analysis of the cyanobacterial hydrogen photoproduction process via model identification and process simulation. *Chemical Engineering Science*, 128, 130-146. <https://doi.org/10.1016/j.ces.2015.01.059>
- Zhang, Q., Jiao, Y., He, C., Ruan, R., Hu, J., Ren, J., Toniolo, S., Jiang, D., Lu, C., Li, Y., Man, Y., Zhang, H., Zhang, Z., Xia, C., Wang, Y., Jing, Y., Zhang, X., Lin, R., Li, G., . . . Tahir, N. (2024). Biological fermentation pilot-scale systems and evaluation for commercial viability towards sustainable biohydrogen production. *Nature Communications*, 15(1), 4539. <https://doi.org/10.1038/s41467-024-48790-4>
- Zhao, K., Liu, W., Yin, T., Zhou, R., Dai & Gang Huang, W. (2022). Model-Free Sliding Mode Control for PMSM Drive System Based on Ultra-Local Model. *Energy Engineering*, 119(2), 767-780. <https://doi.org/10.32604/EE.2021.018617>
- Zhu, Q. (2021). Complete model-free sliding mode control (CMFSMC). *Scientific Reports*, 11(1), 22565. <https://doi.org/10.1038/s41598-021-01871-6>
- Zlateva, P. (2021). Sliding mode control of wastewater treatment process with activated sludge under extreme weather events. *IOP Conference Series: Earth and Environmental Science*, 776(1), 012001. <https://doi.org/10.1088/1755-1315/776/1/012001>

ANEXO A: Clasificación de patrones de comportamiento

La Tabla 28 detalla la comparación entre las tres metodologías empleadas para clasificar los patrones de comportamiento de los controladores (inspección visual, reglas estadísticas y dendrogramas) para cada uno de los 25 casos de estudio determinísticos. Esta información complementa el análisis presentado en la sección 5.6.1 y justifica la selección final del método de clasificación por dendrogramas para la estratificación del desempeño.

Tabla 28: Comparación de clasificaciones por tipo de metodología

Caso	Visual	Estadísticos	Dendrograma
E1	Subgrupo	Subgrupo	Subgrupo
E2	Pareja	Pareja	Pareja
E3	Subgrupo	Subgrupo	Pareja
E4	Subgrupo	Ambiguo	Agrupamiento
E5	Diferenciado	Ambiguo	Agrupamiento
E6	Pareja	Subgrupo	Subgrupo
E7	Pareja	Ambiguo	Agrupamiento
E8	Subgrupo	Subgrupo	Agrupamiento
E9	Subgrupo	Pareja	Subgrupo
P1	Diferenciado	Subgrupo	Pareja
P10	Subgrupo	Pareja	Subgrupo
P11	Subgrupo	Pareja	Subgrupo
P12	Subgrupo	Pareja	Subgrupo
P13	Subgrupo	Pareja	Subgrupo
P14	Subgrupo	Pareja	Subgrupo
P15	Subgrupo	Pareja	Subgrupo

Tabla 29: Comparación de clasificaciones por tipo de metodología (continuación)

Caso	Visual	Estadísticos	Dendrograma
P16	Subgrupo	Ambiguo	Diferenciado
P2	Diferenciado	Subgrupo	Pareja
P3	Pareja	Subgrupo	Subgrupo
P4	Subgrupo	Ambiguo	Diferenciado
P5	Diferenciado	Subgrupo	Pareja
P6	Pareja	Pareja	Pareja
P7	Subgrupo	Pareja	Subgrupo
P8	Subgrupo	Pareja	Subgrupo
P9	Subgrupo	Pareja	Subgrupo

ANEXO B: Análisis descriptivo para categorías especiales

En esta sección se agrupan las tablas de estadísticos descriptivos (media, mediana, desviación estándar, mínimo y máximo) para las métricas de desempeño de los controladores en las categorías de perturbaciones ambientales (Tabla 30) y de fugas (Tabla 31). Estos datos proporcionan el detalle numérico completo que sustenta el análisis y las conclusiones presentadas para los casos especiales en la sección 5.6.3.

Tabla 30: Análisis descriptivo para la categoría de Ambiental

Metrica*	Grupo	Media	Mediana	Desviación	Mínimo	Máximo
ESS	Representante	-2.86E-01	-2.86E-01	2.78E-04	-2.87E-01	-2.86E-01
ESS	C4	-2.00E-04	-1.64E-04	2.50E-04	-5.20E-04	4.60E-05
Amplitud	Representante	-3.80E-01	-3.80E-01	2.85E-04	-3.80E-01	-3.79E-01
Amplitud	C4	-9.73E-02	-9.73E-02	1.80E-04	-9.76E-02	-9.72E-02
Chattering	Representante	-1.75E-01	-1.75E-01	5.45E-06	-1.75E-01	-1.75E-01
Chattering	C4	-1.85E-01	-1.85E-01	1.60E-05	-1.85E-01	-1.85E-01

Tabla 31: Análisis descriptivo para la categoría de Fugas

Metrica*	Grupo	Media	Mediana	Desviación	Mínimo	Máximo
ESS	Representante	-2.82E-01	-2.86E-01	6.60E-03	-2.86E-01	-2.75E-01
ESS	C4	-7.92E-03	-9.07E-05	1.38E-02	-2.38E-02	1.35E-04
Amplitud	Representante	-3.66E-01	-3.79E-01	2.28E-02	-3.80E-01	-3.40E-01
Amplitud	C4	-7.33E-02	-9.71E-02	4.14E-02	-9.73E-02	-2.55E-02
Chattering	Representante	-1.75E-01	-1.75E-01	1.34E-04	-1.75E-01	-1.75E-01
Chattering	C4	-1.85E-01	-1.85E-01	5.12E-04	-1.86E-01	-1.85E-01

ANEXO C: Análisis de normalidad para casos con ruido

Este anexo presentan las tablas completas (Tablas 32, 33 34, 35) con los resultados de la prueba de normalidad de Shapiro-Wilk ($\alpha=0.05$). La tabla detalla el p-valor para cada métrica (ESS, Amplitud y Chattering) en cada combinación de controlador y caso de estudio estocástico. Esta información es fundamental, ya que constituye la base para la selección de la prueba estadística apropiada en el análisis comparativo de la sección 5.7.3.

Tabla 32: Análisis de normalidad Shapiro-Wilk para C1

Controlador	Caso	Métrica	p_valor	Normalidad
C1	P17	ESS	0.05028389	Sí
C1	P17	Amplitud	0.59541897	Sí
C1	P17	Chattering	0.74943388	Sí
C1	E10	ESS	0.16551267	Sí
C1	E10	Amplitud	0.0786682	Sí
C1	E10	Chattering	0.00050812	No
C1	E11	ESS	0.72341348	Sí
C1	E11	Amplitud	0.29553783	Sí
C1	E11	Chattering	0.51538501	Sí
C1	E12	ESS	0.50594729	Sí
C1	E12	Amplitud	0.48179681	Sí
C1	E12	Chattering	0.15096041	Sí

Tabla 33: Análisis de normalidad Shapiro-Wilk para C2

Controlador	Caso	Métrica	p_valor	Normalidad
C2	P17	ESS	0.24935003	Sí
C2	P17	Amplitud	0.44986106	Sí
C2	P17	Chattering	0.97125195	Sí
C2	E10	ESS	0.00282611	No
C2	E10	Amplitud	0.01386795	No
C2	E10	Chattering	0.06142494	Sí
C2	E11	ESS	0.39348904	Sí
C2	E11	Amplitud	0.782933	Sí
C2	E11	Chattering	0.89554403	Sí
C2	E12	ESS	0.78082368	Sí
C2	E12	Amplitud	0.16646635	Sí
C2	E12	Chattering	0.72773688	Sí

Tabla 34: Análisis de normalidad Shapiro-Wilk para C3

Controlador	Caso	Métrica	p_valor	Normalidad
C3	P17	ESS	0.08219966	Sí
C3	P17	Amplitud	0.77036763	Sí
C3	P17	Chattering	0.26242174	Sí
C3	E10	ESS	0.17625528	Sí
C3	E10	Amplitud	0.16681955	Sí
C3	E10	Chattering	0.71245219	Sí
C3	E11	ESS	0.35113818	Sí
C3	E11	Amplitud	0.66479966	Sí
C3	E11	Chattering	0.3902668	Sí
C3	E12	ESS	0.26656502	Sí
C3	E12	Amplitud	0.02369976	No
C3	E12	Chattering	0.68030329	Sí

Tabla 35: Análisis de normalidad Shapiro-Wilk para C4

Controlador	Caso	Métrica	p_valor	Normalidad
C4	P17	ESS	0.17112254	Sí
C4	P17	Amplitud	0.42110148	Sí
C4	P17	Chattering	0.03597127	No
C4	E10	ESS	0.35322828	Sí
C4	E10	Amplitud	0.99395693	Sí
C4	E10	Chattering	0.04164853	No
C4	E11	ESS	0.98992403	Sí
C4	E11	Amplitud	0.53127683	Sí
C4	E11	Chattering	0.98504245	Sí
C4	E12	ESS	0.83662153	Sí
C4	E12	Amplitud	0.47010855	Sí
C4	E12	Chattering	0.730584	Sí