

Estrategias avanzadas de control de procesos químicos: una vigilancia tecnológica

Yarod Andrey Soler Hernández y Lourdes Mildreth Mayorga Meza

Trabajo de Grado para Optar el Título de Ingeniero Químico

Director

Omar Andrés Benavides Prada

Prof. Escuela de Ingeniería Química

Universidad Industrial de Santander
Facultad de Ingenierías Físicoquímicas
Escuela de Ingeniería Química
Bucaramanga

2026

Dedicatoria

A mis padres, Martha Hernández y Nelson Soler, por su apoyo constante, su dedicación y por confiar en mí en cada etapa de mi formación académica y personal. Su presencia ha sido fundamental para que pueda llegar hasta este punto, y su ejemplo de perseverancia y responsabilidad ha guiado cada uno de mis esfuerzos.

A mi compañera de vida, Erika Duarte, por su apoyo incondicional, su paciencia y su presencia constante durante este proceso académico. Su acompañamiento fue esencial para culminar este camino, y su confianza en mí permitió mantener la motivación en los momentos más exigentes.

A ustedes les dedico este título, pues este logro es fruto del apoyo, la confianza y la fortaleza que me brindaron a lo largo de todo este camino.

-Yarod Soler

Dedicatoria

*A Dios, por iluminar cada uno de mis pasos y ser mi guía constante en este camino académico.
A mis padres, Nelly Meza y Ariel Mayorga, a quienes les debo la vida y gran parte de lo que hoy
soy. Han sido mi guía, mi refugio y mi mayor inspiración. Gracias por su amor incondicional,
por cada sacrificio realizado en silencio, por sus enseñanzas, su confianza y por impulsarme a
perseguir mis sueños desde el primer momento.*

*Este logro también les pertenece a ustedes, porque detrás de cada meta alcanzada están su
esfuerzo, dedicación y apoyo constante.*

*A mi hermano, Santiago, por ser mi compañero de vida y una de las mayores alegrías de mi
existencia. Gracias por cada sonrisa, por cada momento compartido y por recordarme siempre
el valor de la familia. Eres, sin duda, el regalo más hermoso que nuestros padres me han dado.*

Con todo mi amor y gratitud

-Lourdes Mayorga

Agradecimientos

A mi director de tesis, el ingeniero Omar Andrés Benavides Prada, por permitirme aprender de sus conocimientos, por su paciencia y su orientación constante, fundamentales para el desarrollo de este trabajo.

A la Universidad Industrial de Santander (UIS), mi alma mater, por haberme formado de manera integral como ingeniero químico, por brindarme los recursos académicos y el espacio para desarrollar esta investigación, y por todos los conocimientos y valores que llevo conmigo.

A mi madre, Martha Hernández, por su amor incondicional, por sus sacrificios silenciosos que me han permitido llegar hasta aquí, por su compañía eterna en cada momento de mi vida y por creer en mí incluso cuando yo mismo dudaba de mis capacidades. Su fortaleza ha sido mi ejemplo y su apoyo, mi motor constante a lo largo de todos estos años.

A mi padre, Nelson Soler, por su apoyo incondicional, sus sacrificios y por creer en mí en cada paso de este proceso.

A mi compañera de vida, Erika Duarte, por enseñarme lo que significa ser amado con sinceridad, por el amor profundo que me ha dado fuerza en los momentos más difíciles, por su paciencia infinita cuando más lo necesitaba y por estar siempre a mi lado sin condiciones. Su presencia en mi vida ha transformado mi manera de ver el mundo y me ha hecho una mejor persona.

A mi hermano, Kevin Soler, por ser mi segundo padre, por su generosidad y su amor, ofreciendo siempre su apoyo sin esperar nada a cambio, y por inculcar en mí, desde siempre, la curiosidad por lo desconocido

A mi compañera de tesis y amiga, Lourdes Mayorga, por su compañía, su disposición incansable, su responsabilidad y su apoyo incondicional durante este proceso.

A mis amigos y compañeros de la universidad, por los momentos de apoyo, estudio conjunto y por hacer más llevadero este proceso académico.

-Yarod Soler

Agradecimientos

A la Universidad Industrial de Santander, mi alma mater, por brindarme las herramientas, los espacios y las oportunidades necesarias para crecer no solo como profesional, sino también como persona.

Al Ingeniero Omar Benavides Prada por su orientación, disposición y acompañamiento durante el desarrollo de este trabajo.

A mis padres, quienes han sido el pilar fundamental de mi existencia. Gracias por su amor incondicional, por los sacrificios realizados para apoyarme en cada etapa de mi formación y por creer en mí incluso cuando yo misma dudaba de mis capacidades.

A mis amigos y compañeros de carrera Silvi y Freddy, por compartir conmigo este camino lleno de retos, aprendizajes y experiencias inolvidables. Gracias por su apoyo constante, sus palabras de ánimo, su compañía y por convertir esta etapa en una experiencia memorable llena de hermosos recuerdos.

A Laura, por su valiosa presencia en mi vida. Gracias por tu amistad sincera, por tu apoyo incondicional y por estar a mi lado tanto en los momentos de alegría como en los días difíciles. Me llevo no solo los recuerdos compartidos, sino también la fortuna de haber encontrado en ti una amiga que dejó una huella profunda en mi corazón.

A Karen, por ser mucho más que una amiga. Gracias por tu compañía incondicional, tu apoyo sincero y por ser mi hogar lejos de casa. Gracias por escucharme en los momentos donde no sabía que hacer, celebrar conmigo cada logro y recordarme mi fortaleza cuando más lo necesitaba.

A Yarod, por ser más que un compañero de tesis. Gracias por tu compromiso, dedicación y apoyo constante en cada etapa de este trabajo. Gracias por compartir ideas, esfuerzos y

aprendizajes, me siento muy orgullosa de nuestro trabajo en equipo y de poder compartir contigo este logro.

Finalmente, dedico unas palabras especiales a quienes, aunque ya no están físicamente conmigo, continúan acompañándome a través de su recuerdo y su amor. A mi tía María Nelcy, quien siempre admiró mis capacidades y confió plenamente en mi potencial. Y a mi abuelo José de los Reyes, quien partió de este mundo creyendo en su nieta y en todo lo que podía llegar a alcanzar. Aunque la vida no nos permita estar juntos en este momento su recuerdo vive en mi corazón.

-Lourdes Mayorga

Tabla de Contenido

Introducción	20
Estado del arte.....	22
1. Objetivos	23
1.1 Objetivo General	23
1.2 Objetivos Específicos.....	23
2. Metodología	24
2.1 Selección de fuentes de información y diseño de la ecuación de búsqueda	24
2.2 Organización y análisis bibliométrico de la literatura	25
2.3 Identificación de desafíos y análisis TRL	26
3. Resultados y discusión	27
3.1 Resultados protocolo PRISMA.....	27
3.2 Análisis bibliométrico	28
3.3 Indicadores clave para evaluar el control avanzado.....	30
3.4 Control predictivo basado en modelo (<i>MPC</i>).....	31
3.4.1 <i>LMPC/EMPC/LEMPC</i>	33
3.4.2 <i>Modelado híbrido dinámico</i>	39
3.4.3 <i>Control predictivo basado en redes neuronales (NNMPC)</i>	42
3.5 Lógica difusa.....	46
3.5.1 <i>Modelado difuso de Takagi-Sugeno</i>	46
3.6 Control basado en aprendizaje por refuerzo (<i>RL</i>)	49

4. Análisis TRL	50
5. Conclusiones	54
Referencias Bibliográficas	56
Apéndices.....	62

Lista de Tablas

Tabla 1. Criterios de inclusión y exclusión.....	25
Tabla 2. Aplicaciones industriales y de investigación de LMPC, EMPC y LEMPC.....	37
Tabla 3. Nivel TRL de las tecnologías analizadas para el control avanzado de procesos químicos	50

Pág.

Lista de Figuras

Figura 1. Esquema metodológico	24
Figura 2. Diagrama de flujo metodología PRISMA	27
Figura 3. Mapa bibliométrico de palabras clave mediante VOSviewer	29
Figura 4. Estrategia de un controlador MPC	31
Figura 5. Metodología de identificación incremental	40
Figura 6. Arquitectura de una red neuronal empleada en un esquema NNMPC.....	43
Figura 7. Arquitectura convencional MPC vs arquitectura ANN con verificación de restricciones.	44
Figura 8. Esquema del controlador dinámico por modo deslizante (DSMC) basado en un multimodelo difuso de Takagi-Sugeno.	47

Pág.

Lista de Apéndices

Apéndice A. Ítems metodología PRISMA.....	62
Apéndice B. Descripción de los Niveles de Madurez Tecnológica (TRL).....	66
Apéndice C. Mapa de distribución geográfica de los autores de los artículos seleccionados	67
Apéndice D. Reinforcement Learning (RL)	68
Apéndice E. Formulación de reglas difusas para el modelo de Takagi-Sugeno.....	70

Pág.

Glosario

AHMPC (*Adaptive Hybrid Model Predictive Control*): control predictivo híbrido con adaptación, que ajusta la contribución del componente basado en datos según el dominio de validez del modelo.

ANFIS (*Adaptive Neuro-Fuzzy Inference System*): sistema de inferencia neurodifuso adaptativo que combina redes neuronales y lógica difusa.

ANN (*Artificial Neural Network*): red neuronal artificial empleada para aproximar relaciones no lineales o inciertas en procesos químicos.

CARIMA (*Controlled Auto-Regressive Integrated Moving Average*): modelo discreto usado en control predictivo generalizado para representar la dinámica del proceso.

CSTR (Continuous Stirred-Tank Reactor): reactor continuo de tanque agitado, ampliamente usado como sistema de referencia en control de procesos químicos.

DAE (*Differential Algebraic Equations*): ecuaciones diferenciales-algebraicas usadas para describir procesos dinámicos con restricciones algebraicas.

DCS (*Distributed Control System*) sistema de automatización industrial que supervisa y controla procesos en tiempo real mediante estaciones, controladores y redes distribuidas a lo largo de la planta.

DL-SAC (*Deep Learning-Based Scheduling-Adaptive Controller*): controlador adaptativo a la programación basado en aprendizaje profundo.

DMC (*Dynamic Matrix Control*): estrategia clásica de control predictivo basada en modelo.

DQN (*Deep Q-Network*): método de aprendizaje por refuerzo profundo para estimar políticas de control con acciones discretas.

DSMC (*Dynamic Sliding Mode Control*): control dinámico por modo deslizante.

DWC (*Dividing Wall Column*): columna de pared divisoria usada en separación de mezclas.

EMPC (*Economic Model Predictive Control*): control predictivo orientado a optimizar un criterio de desempeño económico.

FMMC-DSMC (*Fuzzy Multi-Model based Dynamic Sliding Mode Control*): controlador dinámico por modo deslizante basado en un multimodelo difuso.

FNN (*Feedforward Neural Network*): red neuronal de avance directo.

FOPDT (*First Order Plus Dead Time*): modelo de primer orden con tiempo muerto.

GPC (*Generalized Predictive Control*): control predictivo generalizado.

HMPC (*Hybrid Model Predictive Control*): control predictivo basado en un modelo híbrido que combina principios físicos y datos.

HPGR (*High Pressure Grinding Rolls*): prensa de rodillos de alta presión.

IAE (*Integral Absolute Error*): error integral absoluto; mide la desviación acumulada entre la salida y la referencia.

ILC (*Iterative Learning Control*): control por aprendizaje iterativo.

ISE (*Integral Squared Error*): integral del error cuadrático; mide el error acumulado dando mayor peso a las desviaciones grandes.

ITAE (*Integral of Time-weighted Absolute Error*): error integral absoluto ponderado por el tiempo; penaliza más los errores persistentes.

LEMPC (*Lyapunov-Based Economic Model Predictive Control*): control predictivo económico con restricciones de estabilidad basadas en Lyapunov.

LMAC (*Latent Variable Model-Free Advanced Control*): control avanzado libre de modelo basado en variables latentes.

LMPC (*Lyapunov-Based Model Predictive Control*): control predictivo basado en Lyapunov que incorpora restricciones explícitas de estabilidad.

LSTM (*Long Short-Term Memory*): tipo de red neuronal recurrente adecuada para capturar dependencias temporales.

MAPE (*Mean Absolute Percentage Error Total*): indicador global de error porcentual absoluto medio total.

MDP (*Markov Decision Process*): proceso de decisión de Markov, marco matemático usado en aprendizaje por refuerzo.

MIMO (*Multi-Input Multi-Output*): sistema con múltiples entradas y múltiples salidas.

MPC (*Model Predictive Control*): control predictivo basado en modelo.

MSE (*Mean Squared Error*): error cuadrático medio.

NARX (*Nonlinear AutoRegressive with eXogenous inputs*): modelo autorregresivo no lineal con entradas exógenas.

NMPC (*Nonlinear Model Predictive Control*): control predictivo no lineal.

NNMPC (*Neural Network Model Predictive Control*): control predictivo basado en redes neuronales.

NRTL (*Non-Random Two-Liquid*): modelo termodinámico de dos líquidos no aleatorios usado para estimar coeficientes de actividad en equilibrio vapor-líquido.

NRMSE (*Normalized Root Mean Square Error*): raíz del error cuadrático medio normalizado.

PCA (*Principal Component Analysis*): análisis de componentes principales.

PBMPC (*Physics-Based Model Predictive Control*): control predictivo basado en un modelo físico.

PI (*Proportional-Integral*): controlador proporcional-integral.

PID (*Proportional-Integral-Derivative*): controlador proporcional-integral-derivativo.

PLS (*Partial Least Squares*): mínimos cuadrados parciales.

PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*): guía metodológica para la elaboración y el reporte de revisiones sistemáticas y metaanálisis.

PWM (*Pulse Width Modulation*): modulación por ancho de pulso.

RL (*Reinforcement Learning*): aprendizaje por refuerzo.

RNN (*Recurrent Neural Network*): red neuronal recurrente.

SMC (*Sliding Mode Control*): control por modo deslizante.

SISO (*Single-Input Single-Output*): sistema con una entrada y una salida.

TCLab (*Temperature Control Lab*): plataforma experimental de control de temperatura empleada para validación en tiempo real.

TD3 (*Twin-Delayed Deep Deterministic Policy Gradient*): algoritmo actor-crítico de aprendizaje por refuerzo usado en problemas de control con acciones continuas.

TRL (*Technology Readiness Level*): nivel de madurez tecnológica usado para evaluar el grado de desarrollo de una tecnología.

TS (*Takagi-Sugeno*): modelo difuso basado en reglas y modelos locales lineales.

TVu (*Total Variation of control action*): variación total de la acción de control; refleja el esfuerzo o la agresividad del controlador.

Resumen

Título: Estrategias avanzadas de control de procesos químicos: una vigilancia tecnológica*

Autor: Benavides Prada Omar Andrés, Mayorga Meza Lourdes Mildreth, Soler Hernandez Yarod Andrey**

Palabras Clave: control avanzado de procesos, control predictivo basado en modelo, aprendizaje por refuerzo, lógica difusa, modelado híbrido dinámico, redes neuronales.

Descripción: se realizó una revisión sistemática sobre las estrategias avanzadas de control de procesos químicos, con el objetivo de analizar y sintetizar los enfoques más relevantes reportados en la literatura reciente, identificando tendencias tecnológicas, principales metodologías, desafíos de implementación y nivel de madurez industrial. La metodología se basó en el protocolo PRISMA, complementado con un análisis bibliométrico para reconocer patrones de investigación y avances en el área. Los resultados evidenciaron un creciente interés por metodologías orientadas a mejorar el desempeño dinámico, la robustez y la adaptabilidad de los procesos químicos, especialmente frente a sistemas no lineales y multivariables. Entre las estrategias más destacadas se identificaron el control predictivo basado en modelo (MPC) y sus variantes LMPC, EMPC y LEMPC, el control predictivo basado en redes neuronales (NNMPC), el modelado híbrido dinámico y su aplicación en esquemas HMPC, el aprendizaje por refuerzo (RL) y la lógica difusa, incluyendo el modelado de Takagi-Sugeno (TS). Aunque estas metodologías muestran un alto potencial de aplicación industrial, su adopción a gran escala continúa limitada por la exigencia computacional, la disponibilidad de datos, la necesidad de garantizar seguridad operativa y la dificultad de integración con la infraestructura existente.

*Trabajo de Grado

**Facultad de ingenierías fisicoquímicas. Escuela de ingeniería química. Director: Omar Andrés Benavides Prada. Prof. Escuela de Ingeniería Química.

Abstract

Title: *Advanced Control Strategies for Chemical Processes: A Technology Watch**

Author: Benavides Prada Omar Andrés, Mayorga Meza Lourdes Mildreth, Soler Hernandez Yarod Andrey**

Key Words: *advanced process control, model predictive control, reinforcement learning, fuzzy logic, dynamic hybrid modeling, neural networks.*

Description: a systematic review was conducted on advanced chemical process control strategies in order to analyze and synthesize the most relevant approaches reported in recent literature, identifying technological trends, main methodologies, implementation challenges, and the maturity level of these technologies. The methodology was based on the PRISMA protocol and was complemented by a bibliometric analysis to identify research patterns and advances in the field. The results showed growing interest in methodologies aimed at improving dynamic performance, robustness, and adaptability of chemical processes, especially under nonlinear and multivariable conditions. The most prominent strategies identified were model predictive control (MPC), neural network model predictive control (NNMPC), dynamic hybrid modeling, reinforcement learning (RL), and fuzzy logic, including Takagi-Sugeno (TS) modeling. Although these methodologies show strong industrial application potential, their large-scale adoption remains limited by computational demand, data availability, the need to ensure operational safety, and the difficulty of integration with existing automation infrastructure.

* Bachelor's Thesis

** Faculty of Physicochemical Engineering. Chemical Engineering Department. Director: Omar Andrés Benavides Prada. Chemical Engineering Department

Introducción

En la actualidad, la industria química enfrenta una serie de desafíos crecientes relacionados con la eficiencia operativa, la sostenibilidad y la seguridad en plantas de procesos fuertemente automatizadas. El aumento en la complejidad de las operaciones, así como la necesidad de aplicar la intensificación de procesos y la integración de nuevas tecnologías digitales, ha promovido el desarrollo de sistemas de control más robustos, con mejor capacidad de predicción y adaptabilidad (Qin & Badgwell, 2003). Aunque los controladores PID han sido durante décadas la columna vertebral del control de procesos por su simplicidad y confiabilidad, su desempeño se ve limitado cuando se aplican a sistemas con múltiples variables, no lineales y con fuerte dependencia entre variables de operación (Åström & Hägglund, 2001).

Esta situación ha impulsado un creciente interés por las estrategias avanzadas de control, tales como el control predictivo por modelo (MPC), los métodos de control libre de modelo basado en variables latentes (LMAC), el control por aprendizaje iterativo (ILC) y los esquemas híbridos que implementan inteligencia artificial. Dentro de estos esquemas se destacan los controladores neuronales predictivos, los cuales usan redes neuronales profundas para aproximar modelos no lineales complejos de proceso (Yu & Gomm, 2003); los controladores difusos (*fuzzy controllers*), que permiten gestionar incertidumbre mediante reglas lingüísticas (Fileti et al., 2007); los métodos neuro-difusos (ANFIS), que combinan el aprendizaje automático con lógica difusa para mejorar la adaptabilidad frente a cambios en la dinámica del sistema (Sarhadi et al., 2016); y los controladores reforzados, basados en *reinforcement learning*, que optimizan sistemas de control mediante interacción continua con el proceso, aprendiendo estrategias de control directamente a partir de datos operacionales (Nian et al., 2020).

En el contexto colombiano, los avances en el control de procesos se han desarrollado a un ritmo más lento que en otros países. Además, en el escenario académico local, la escuela de Ingeniería Química de la Universidad Industrial de Santander reporta solo 3 trabajos al control predictivo en los últimos 10 años: Castillo y Guerrero (2018) propusieron y analizaron un esquema de control DMC para una torre de destilación de crudos industrial; Alcalá y Suárez (2023) diseñaron e implementaron un sistema de control predictivo tipo DMC de lazo simple (SISO) para un tanque de calentamiento con agitación continua; y López y Velasco (2024) extendieron esta línea de trabajo con el diseño y simulación de un sistema de control DMC multivariable (MIMO).

Teniendo en cuenta lo anterior, una vigilancia tecnológica contribuye al fortalecimiento académico y científico en la Escuela de Ingeniería Química; en un entorno donde la industria demanda soluciones cada vez más sofisticadas para el control avanzado de procesos, disponer de una síntesis actualizada del estado del arte permitirá orientar futuros trabajos de investigación, promover la adopción de tecnologías emergentes y priorizar líneas de desarrollo con alto potencial de impacto. Además, es posible identificar las metodologías más prometedoras para su escalabilidad industrial, considerando criterios como desempeño dinámico, resistencia a perturbaciones, costo computacional y facilidad de implementación. Por lo tanto, la presente investigación busca responder a la siguiente pregunta: ¿cuál es el nivel de madurez tecnológica (TRL) de las estrategias avanzadas de control de procesos químicos y qué desafíos limitan su implementación industrial?

Estado del arte

El control de procesos ha evolucionado desde configuraciones basadas en controladores PID hasta la incorporación de estrategias como el control predictivo basado en modelos (MPC) y su integración en plataformas inteligentes de automatización, lo cual marca una tendencia hacia la digitalización, el análisis en tiempo real y la mejora continua de las operaciones (Bequette, 2019).

Revisiones recientes muestran estrategias de control basadas en MPC junto con redes neuronales, con el fin de modelar dinámicas complejas (Ren *et al.*, 2022). Sin embargo, autores señalan que el aprendizaje automático introduce retos en seguridad y costo computacional (Hewing *et al.*, 2020), lo cual implica la integración del control de procesos con el análisis de riesgos, y la necesidad de verificación formal previa a su implementación en planta. Otros enfoques van hacia estrategias orientadas a mejorar la calidad de modelado y la toma de decisiones en entornos con alta variabilidad, incluyendo análisis estadístico para inferir variables difíciles de medir en línea (Wu *et al.*, 2023), o métodos híbridos modelo-datos que combinan conocimiento fenomenológico con aprendizaje automático (Thosar *et al.*, 2025).

Por otra parte, el protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) se ha empleado como marco metodológico para revisiones sistemáticas. El protocolo plantea 27 ítems organizados en etapas clave: formulación de la pregunta, estrategia de búsqueda, selección de estudios, extracción y análisis de datos, y reporte de resultados. Dicha metodología ha sido aplicada en vigilancias tecnológicas sobre producción de hidrógeno verde a partir de biomasa (Fajardo, 2023), métodos de captura de CO₂ (Quiroz & Charris, 2024), o separación de CO₂ mediante membranas (Lizcano & Celis, 2025), demostrando que el uso de PRISMA asegura trazabilidad y reproducibilidad del proceso de selección.

1. Objetivos

1.1 Objetivo General

Elaborar una revisión sistemática de metodologías avanzadas para el control de procesos químicos.

1.2 Objetivos Específicos

Implementar el protocolo PRISMA para fijar criterios de selección, clasificación y análisis de la información.

Desarrollar un análisis bibliométrico sobre los avances tecnológicos de estrategias avanzadas de control de procesos químicos.

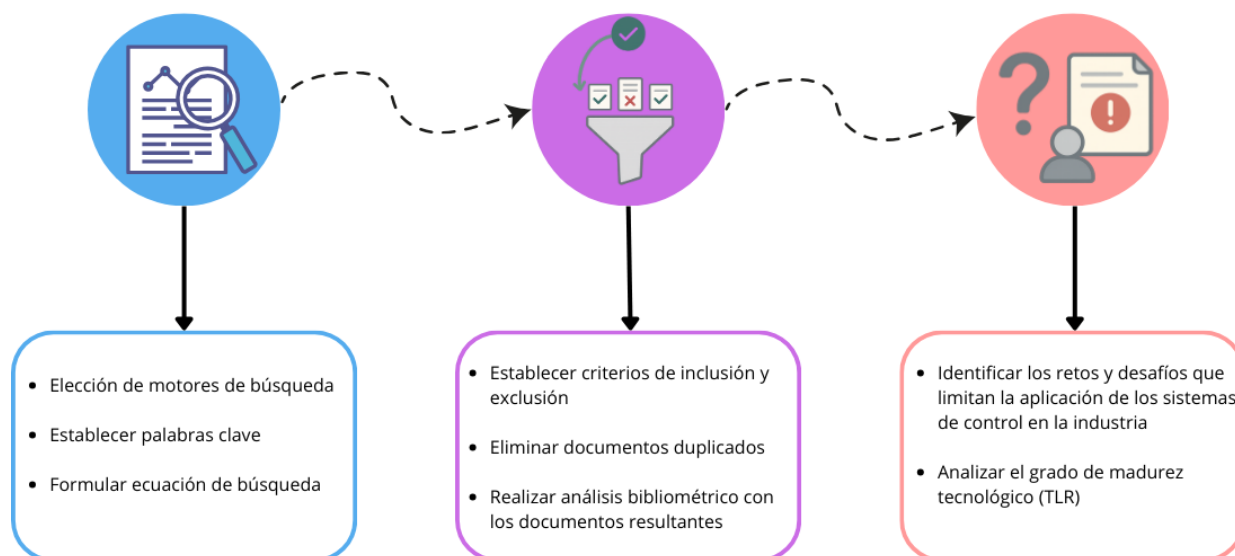
Identificar los desafíos actuales para la implementación de técnicas avanzadas de control de procesos químicos.

2. Metodología

Esta vigilancia tecnológica se desarrolló conforme a las directrices establecidas por el protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*). Se contemplan un total de 27 ítems (Apéndice A), organizados en siete etapas fundamentales: formulación de la pregunta de investigación, búsqueda de artículos, selección de estudios pertinentes, recopilación de datos, valoración del riesgo de sesgo, análisis de datos y presentación de los hallazgos (Page *et al.*, 2021). Para apoyar este proceso, se emplearon herramientas especializadas que permitieron sistematizar la información obtenida y facilitar su análisis, conforme a la metodología ilustrada en la Figura 1.

Figura 1.

Esquema metodológico



2.1 Selección de fuentes de información y diseño de la ecuación de búsqueda

Se seleccionaron dos motores de búsqueda principales: Scopus y ScienceDirect, teniendo en cuenta las licencias ofrecidas por la Universidad Industrial de Santander. Scopus se eligió por

su amplia cobertura multidisciplinaria y su fortaleza en citación e indexación, mientras que ScienceDirect se priorizó por el acceso a textos completos de revistas clave en ingeniería y procesos químicos. Con base en la pregunta de investigación, se diseñaron ecuaciones de búsqueda estructuradas mediante palabras clave y operadores booleanos. En Scopus se empleó la siguiente estrategia: TITLE-ABS-KEY ("process control" OR "advanced process control") AND ("chemical process"), y en ScienceDirect, se utilizó la ecuación: ("process control") OR ("advanced process control") AND ("chemical process"), lo que permitió la recuperación inicial de los documentos relevantes para el periodo de análisis establecido. Posteriormente, los registros obtenidos fueron sometidos a los criterios de inclusión y exclusión definidos para la revisión (Tabla 1).

Tabla 1.

Criterios de inclusión y exclusión

Inclusión	Exclusión
Todo artículo con respaldo científico que aborden procesos avanzados de control.	Artículos que no traten control avanzado.
Publicaciones del año 2022 a 2026.	Publicaciones anteriores al año 2022
Artículos del área de ingeniería química	Trabajos de disciplinas ajenas
Documentos con texto completo disponible en bases de datos científicas ofrecidas por la universidad	Documentos sin acceso a texto completo
Inglé y/o español	Artículos en idiomas que no sean posible su comprensión o traducción confiable

2.2 Organización y análisis bibliométrico de la literatura

Después de aplicar cada uno de los criterios de inclusión y exclusión en los distintos motores de búsqueda, las referencias fueron exportadas en formato BibTex para su posterior procesamiento. En la primera fase se identificaron y eliminaron los documentos duplicados; posteriormente, se realizó un filtrado para conservar únicamente capítulos de libros, artículos de revisión, editoriales y otros tipos de documentos considerados relevantes para el estudio. Por

último, se realizó una revisión manual de cada registro, considerando el título, el resumen y las palabras claves de cada artículo, con el propósito de eliminar aquellos documentos que no se relacionaran directamente con el objetivo principal de la investigación. La base de datos depurada fue gestionada mediante Rayyan, una herramienta gratuita basada en inteligencia artificial para la organización y filtrado de referencias bibliográficas. Como resultado de este proceso se seleccionaron 64 artículos que cumplían plenamente con los criterios establecidos, considerados para su lectura completa y el posterior análisis bibliométrico y bibliográfico.

2.3 Identificación de desafíos y análisis TRL

Una vez consolidada la base de datos final, se procedió a identificar las principales estrategias avanzadas de control aplicadas en procesos químicos reportadas en la literatura. De manera complementaria, se identificaron los desafíos técnicos y operativos que limitan la implementación y el escalado en entornos industriales. Además, se realizó un análisis del nivel de madurez tecnológica (*Technology Readiness Levels*, TRL), una metodología que permite evaluar el grado de desarrollo mediante una escala de nueve niveles, donde el Nivel 1 corresponde a los principios teóricos o la idea inicial, mientras que el Nivel 9 indica que la tecnología ha alcanzado una madurez completa y se encuentra lista para ser implementada en aplicaciones industriales.

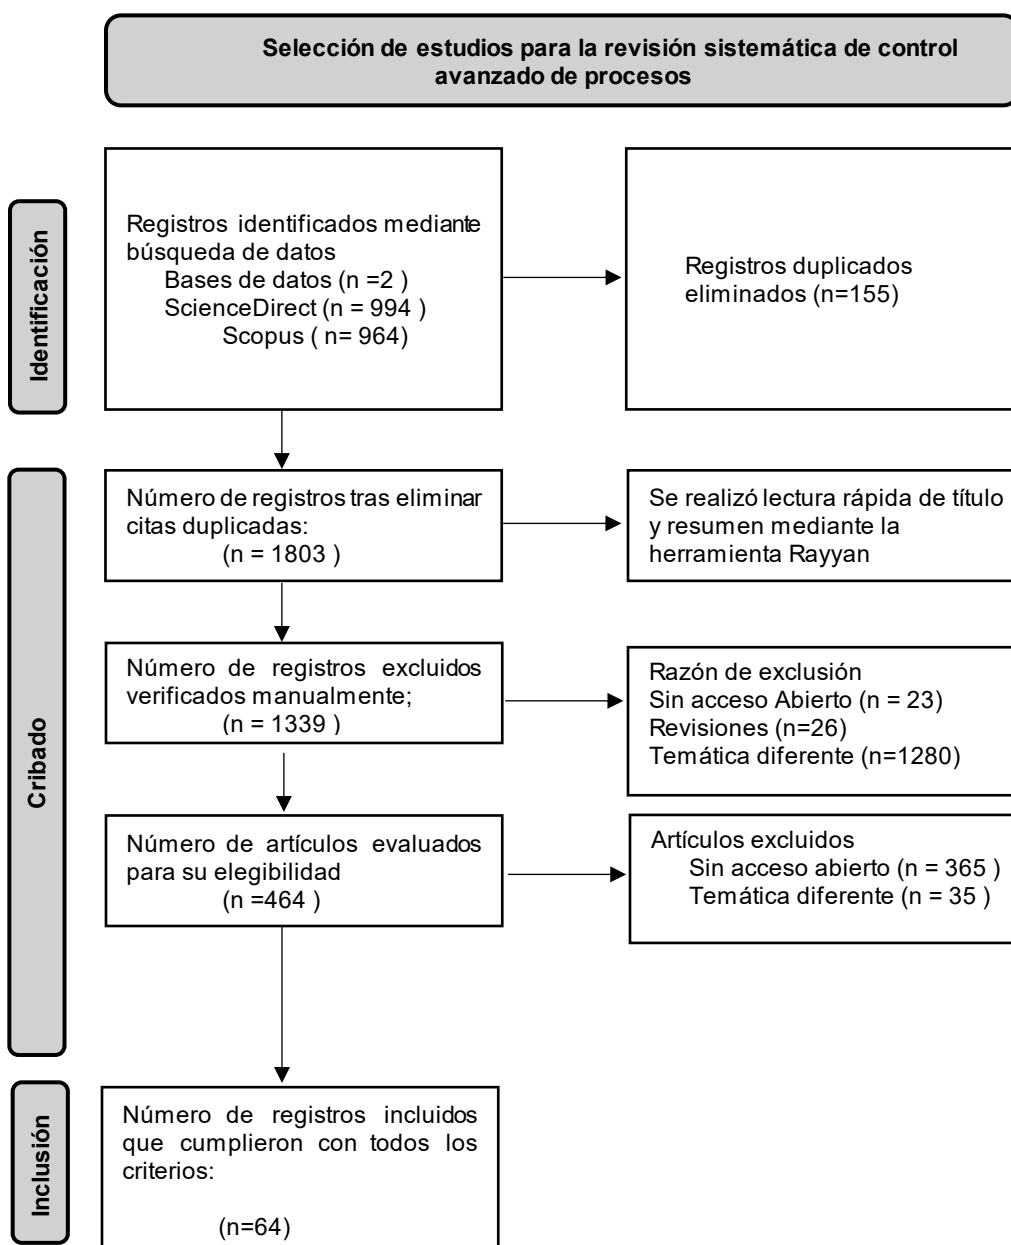
3. Resultados y discusión

3.1 Resultados protocolo PRISMA

La Figura 2 presenta el diagrama que resume la aplicación del protocolo PRISMA.

Figura 2.

Diagrama de flujo metodología PRISMA



Mediante el uso de Rayyan se identificaron y eliminaron registros duplicados; luego, los artículos fueron sometidos a un primer proceso de cribado basado en la revisión del título y palabras claves, con el objetivo de evaluar su pertinencia respecto a los criterios de inclusión y exclusión previamente definidos. Tras esta etapa, 464 artículos fueron considerados potencialmente relevantes, los cuales fueron evaluados para verificar el cumplimiento estricto de los criterios de elegibilidad, siendo excluidos 400 documentos: 365 por no disponer de acceso al texto completo y 35 por no abordar directamente problemas de control avanzado de procesos o por centrarse exclusivamente en actividades de modelado, monitoreo u optimización sin implementación de una estrategia de control en lazo cerrado.

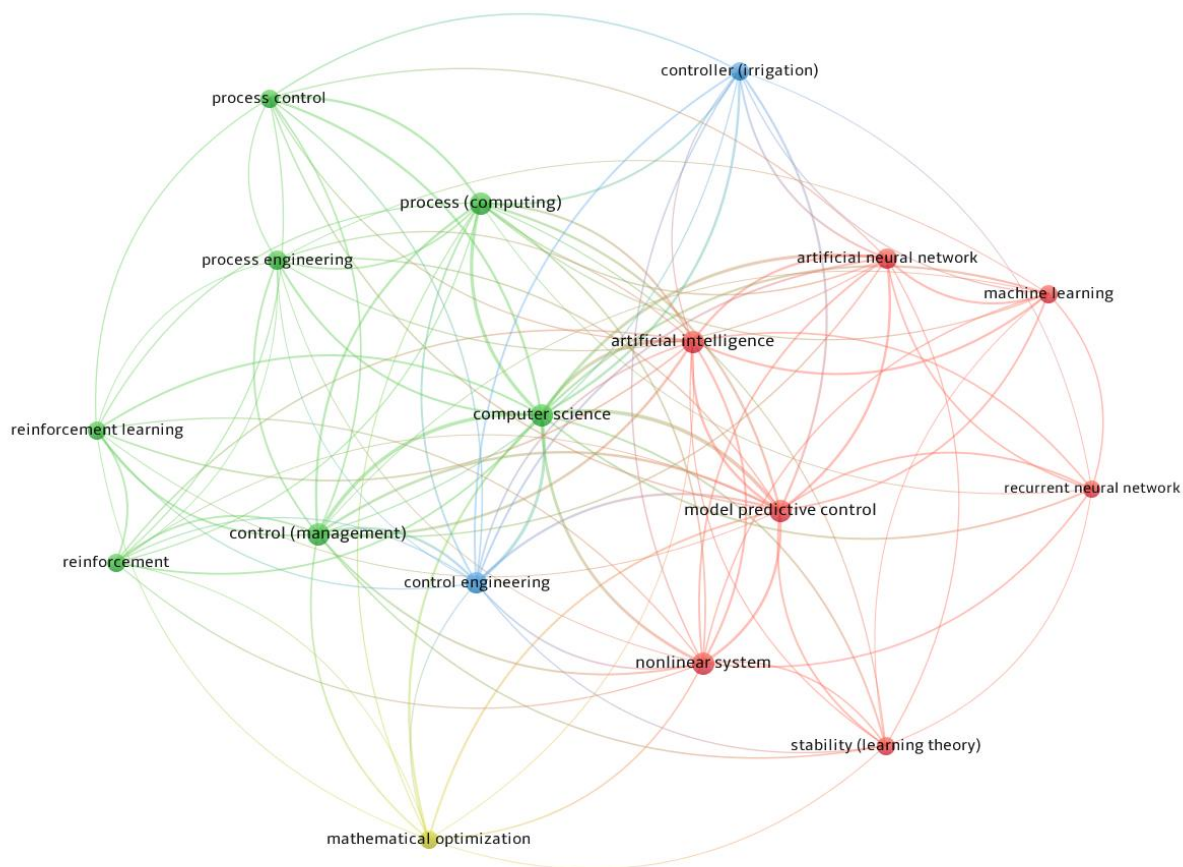
3.2 Análisis bibliométrico

Como parte del análisis bibliométrico se elaboró un mapa de distribución geográfica de las publicaciones científicas relacionadas (véase el Apéndice C). En este contexto, Estados Unidos se posiciona como el país con mayor número de publicaciones (31.1 %), lo que refleja su liderazgo en el desarrollo y aplicación de estrategias avanzadas de control en sectores industriales altamente automatizados, así como una fuerte inversión en investigación y desarrollo. Así mismo, China y Singapur, con el 13.3 % cada uno, destacan como actores relevantes en este campo. En el caso de China, este crecimiento puede asociarse al acelerado proceso de industrialización, la modernización de sus sistemas productivos y la adopción de técnicas de control avanzado para mejorar la eficiencia, la seguridad y la sostenibilidad. Por su parte, la participación destacada de Singapur puede relacionarse con su enfoque estratégico en innovación tecnológica, digitalización industrial y desarrollo de sistemas de control inteligentes. La Figura 3 presenta el mapa de coocurrencia de palabras clave asociado a las publicaciones sobre control avanzado de procesos, donde se identifican varios clústeres temáticos interrelacionados.

Se observa una fuerte centralidad de términos como *artificial intelligence*, *control engineering* y *model predictive control*, lo que evidencia su papel fundamental en la investigación actual del área. La relación entre conceptos como *machine learning*, *reinforcement learning* y *artificial neural networks*, muestra cómo las técnicas de inteligencia artificial se articulan con los métodos de control, fortaleciendo su aplicación en sistemas cada vez más complejos. Finalmente, la conexión con disciplinas como matemáticas, física y ciencias de la computación resalta el carácter interdisciplinario del control avanzado de procesos.

Figura 3.

Mapa bibliométrico de palabras clave mediante VOSviewer



3.3 Indicadores clave para evaluar el control avanzado.

La evaluación del desempeño dinámico se centra en cuatro métricas ampliamente aceptadas en el control predictivo de procesos basado en modelos: el error integral absoluto (IAE), que mide la desviación acumulada total entre la variable controlada y el *setpoint* durante toda la respuesta transitoria; el error integral ponderado en el tiempo (ITAE), que otorga mayor importancia a los errores persistentes y favorece respuestas rápidas con oscilaciones mínimas (Sarhadi, 2025); el sobreimpulso, entendido como el máximo exceso de la respuesta por encima del valor final deseado, expresado en porcentaje respecto a dicho valor; y el tiempo de asentamiento, definido como el intervalo necesario para que la salida permanezca permanentemente dentro de una banda estrecha ($\pm 5\%$) alrededor de su valor final (Khelifi & Bessaad, 2024). Los indicadores IAE e ITAE no presentan rangos universales que permitan establecer, de manera absoluta, si un controlador es adecuado o no, dado que sus valores dependen de factores como la escala de la variable controlada, la magnitud del cambio de referencia y la dinámica propia del proceso. En consecuencia, ambos índices se emplean, principalmente, como criterios de comparación relativa entre distintas estrategias de control evaluadas bajo condiciones equivalentes. Bajos valores de IAE reflejan una menor desviación acumulada respecto al *setpoint*, mientras que un ITAE pequeño indica, además, una reducción más rápida de los errores persistentes en el tiempo (Soza Mamani & Prado Romo, 2025).

Adicionalmente, puede incorporarse el error cuadrático medio (MSE) como métrica complementaria, definido como el promedio de los cuadrados del error entre la salida del proceso y la referencia durante el intervalo de evaluación. A diferencia del IAE, el MSE da mayor peso a las desviaciones grandes debido a que el error se eleva al cuadrado, por lo que resulta útil para


identificar respuestas con picos pronunciados, oscilaciones o errores transitorios de elevada magnitud (Bannoud et al., 2022).

3.4 Control predictivo basado en modelo (MPC)

Según Camacho & Bordons, (2004), el control predictivo basado en modelo es la forma más general de formular el problema de control en el dominio del tiempo. El MPC no designa un único algoritmo, sino una familia de métodos que comparten tres elementos: (i) el uso explícito de un modelo para predecir el comportamiento futuro del proceso, (ii) la minimización de una función objetivo, y (iii) la utilización de un horizonte de predicción finito y deslizante. El horizonte de predicción finito implica que el controlador estima la evolución futura del proceso únicamente durante un número limitado de instantes, y se denomina deslizante porque, en cada instante de muestreo, se actualiza utilizando la información más reciente del sistema, desplazándose hacia adelante en el tiempo. De esta manera, el cálculo del control se realiza de forma repetitiva a medida que el proceso evoluciona.

Figura 4.

Estrategia de un controlador MPC



Nota. Adaptado de (Camacho y Bordons, 2004)

La estrategia MPC representada en la Figura 4 puede describirse como un ciclo repetitivo compuesto por tres etapas principales: predicción, optimización y realimentación. En cada instante de muestreo t , el controlador ejecuta los siguientes pasos: utiliza el modelo del proceso para predecir las salidas futuras durante un horizonte de predicción N . Estas predicciones $\hat{y}(t + k | t)$ dependen de la información ya conocida hasta el instante t y de las señales de control futuras $u(t + k | t)$ que aún deben determinarse. Con las predicciones disponibles, el MPC calcula una secuencia de control futura eligiendo aquella que minimiza un criterio de desempeño para mantener el proceso lo más cerca posible de una trayectoria de referencia futura. Típicamente, este criterio se formula como una función cuadrática del error entre salida predicha y la referencia, e incorpora además un término que penaliza los cambios de control para evitar acciones excesivas.

Aunque se calcula una secuencia completa de acciones futuras, el MPC aplica únicamente la primera señal de control. En el siguiente instante $(t + 1)$, al disponerse de una nueva medición del proceso, se actualizan las predicciones y se recalcula una nueva secuencia de control. La señal aplicada en ese nuevo instante puede diferir de la prevista en t . Una de las estructuras más representativas es el Control Predictivo Generalizado (GPC), donde el comportamiento dinámico del proceso se describe mediante un modelo discreto de tipo CARIMA (*Controlled Auto-Regressive Integrated Moving Average*):

$$A(z^{-1})y(t) = B(z^{-1})z^{-d}u(t - 1) + C(z^{-1})\frac{e(t)}{\Delta} \quad (\text{Ec.1})$$

Donde, $\Delta = 1 - z^{-1}$ denota el operador de diferencias discretas, el cual expresa la variación de una señal de un instante de muestreo al siguiente; $u(t)$ y $y(t)$ representan, respectivamente, la entrada y la salida del sistema; z^{-1} es un retardo de un período de muestreo, por lo que z^{-d} representa un retardo de d períodos de muestreo y se asocia al tiempo muerto del proceso; y $e(t)$ es una perturbación no medida del proceso, modelada como ruido blanco de media

cero (señal aleatoria sin sesgo que recoge efectos no modelados del proceso). La Ecuación 1 no calcula directamente la señal de control; a partir de este modelo se obtienen las predicciones futuras de la salida, que posteriormente se emplean para determinar la secuencia de control. Finalmente, A , B y C son polinomios en el operador de retardo z^{-1} : el primero describe la dinámica propia de la salida, el segundo la influencia de la variable manipulada, y el tercero se asocia con las perturbaciones. Como la caracterización dinámica de las perturbaciones es estocástica (no puede predecirse su comportamiento), en esta formulación se considera $C(z^{-1}) = 1$.

La Ecuación 2 define la función de costo J del GPC; es decir, el criterio de optimización que se minimiza para calcular la secuencia futura de control, con el fin de que la salida predicha siga la trayectoria de referencia y se eviten variaciones excesivas en la variable manipulada.

$$J = \sum_{j=N_1}^{N_2} \delta(j) [\hat{y}(t+j/t) - w(t+j)]^2 + \sum_{j=1}^{N_u} \lambda(j) [\Delta u(t+j-1)]^2 \quad (\text{Ec.2})$$

En esta expresión, $\hat{y}(t+j/t)$ es la predicción de la salida del sistema j pasos hacia adelante, calculada en el instante t ; $w(t+j)$ es la trayectoria de referencia futura; N_1 y N_2 definen el intervalo de predicción; y N_u es el horizonte de control, entendido como el número de incrementos futuros de control que se calculan explícitamente. Los términos $\delta(j)$ y $\lambda(j)$ son parámetros de sintonización: $\delta(j)$ pondera el error de seguimiento entre la salida predicha y la referencia, y $\lambda(j)$ evita acciones bruscas de control.

3.4.1 LMPC/EMPC/LEMPC

El *Lyapunov-Based Model Predictive Control* (LMPC) constituye la formulación base dentro de esta familia de estrategias de control predictivo para sistemas no lineales. Su rasgo distintivo es que incorpora condiciones de estabilidad dentro del problema de optimización, de modo que el cálculo de la acción de control depende del desempeño dinámico y del mantenimiento de propiedades de estabilidad en lazo cerrado. A partir de esta formulación, el *Economic Model*

Predictive Control (EMPC) sustituye el objetivo clásico de seguimiento por una función económica, mientras que el *Lyapunov-Based Economic Model Predictive Control* (LEMPC) conserva el objetivo económico y añade restricciones de estabilidad basadas en una función de Lyapunov, la cual es una función que permite verificar si la trayectoria del proceso evoluciona hacia una zona del equilibrio o se aleja de ella (Oyama *et al.*, 2022).

$$\dot{x}(t) = f(x(t), u(t), w(t)) \quad (\text{Ec.3})$$

La Ecuación 3 representa un sistema no lineal donde x corresponde a las variables de estado del modelo, u la variable manipulada y w una perturbación acotada. El vector de estado reúne el conjunto mínimo de variables que describen la condición dinámica del sistema en cada instante (concentraciones, temperaturas, presiones, etc). La rapidez de cambio del sistema depende del estado actual del propio proceso, de la acción de control aplicada y de la perturbación. El diseño del controlador parte de la existencia de una ley de control auxiliar estabilizante $h(x)$ y de una función de Lyapunov $V(x)$ descrita como:

$$\alpha_1(|x|) \leq V(x) \leq \alpha_2(|x|) \quad (\text{Ec.4})$$

$$\frac{\partial V(x)}{\partial x} f(x, h(x), 0) \leq -\alpha_3(|x|) \quad (\text{Ec.5})$$

$$\left| \frac{\partial V(x)}{\partial(x)} \right| \leq \alpha_4(|x|) \quad (\text{Ec.6})$$

En términos físicos, $h(x)$ traduce el estado actual del proceso en una acción de control admisible u que tiende a corregir las desviaciones y a llevar el sistema de regreso a una región estable, mientras que la función de Lyapunov permite evaluar si la trayectoria del proceso se aproxima o se aleja del equilibrio. Según la Ecuación (4), $V(x)$ queda acotada entre funciones de clase K , lo que indica que toma valores positivos y crece con la magnitud del estado; esto se interpreta como una medida de qué tan alejado se encuentra el sistema de una condición estable. La derivada de $V(x)$ a lo largo de la dinámica del sistema bajo la ley auxiliar $h(x)$ resulta negativa

(Ecuación 5), implicando que, cuando se aplica esa ley de control, la evolución del proceso mantiene una tendencia hacia una región estable. En la Ecuación (6) se impone una cota al gradiente de $V(x)$, asegurando un comportamiento regular de esta función dentro de la región analizada. En este contexto, α_1 , α_2 , α_3 y α_4 son funciones continuas, estrictamente crecientes y nulas en el origen, utilizadas para formalizar matemáticamente las cotas de estabilidad. La llamada región de interés corresponde al subconjunto del espacio de estados en el que estas propiedades se consideran válidas y dentro del cual se desea garantizar operación estable. A partir de estas condiciones puede definirse la región de estabilidad $\Omega_\rho = \{x \in D: V(x) \leq \rho\}$, donde D representa el dominio del espacio de estados en el que se realiza el análisis y ρ es una cota positiva que fija el valor máximo admisible de la función de Lyapunov. Esta región es una zona de operación alrededor del equilibrio donde el sistema puede caracterizarse como estable bajo las hipótesis adoptadas en el diseño (Abdullah & Christofides, 2023; Alnajdi *et al.*, 2023; Oyama *et al.*, 2022)

El LMPC minimiza un costo de seguimiento o regulación, un índice de desempeño que penaliza la desviación del proceso respecto al estado deseado y, según la formulación, también el esfuerzo de control requerido para corregirla. Su función es seleccionar acciones que mejoren la respuesta dinámica sin perder de vista las restricciones del sistema.

$$\min_{u(\cdot) \in S(\Delta)} \int_{t_k}^{t_k+N} L(\tilde{x}(t), u(t)) dt \quad (\text{Ec.7})$$

Sujeto a:

$$\dot{\tilde{x}}(t) = \hat{f}(\tilde{x}(t), u(t)) \quad (\text{Ec.8})$$

$$\dot{V}(x(t_k), u) \leq V\left(x(t_k), \dot{h}(x(t_k))\right), \quad \text{si } x(t_k) \in \Omega_\rho \setminus \Omega_{\rho_e} \quad (\text{Ec.9})$$

$$V(\tilde{x}(t)) \leq \rho_e, \quad \forall t \in [t_k, t_k + N] \quad \text{si } x(t_k) \in \Omega_{\rho_e} \quad (\text{Ec.10})$$

Donde, \hat{f} representa el modelo predictivo utilizado por el controlador para estimar la evolución futura del sistema dentro del horizonte de predicción. La Ecuación (7) es el problema de optimización que resuelve el LMPC en cada instante de muestreo: su propósito es determinar la trayectoria de control futura $u(\cdot)$ que minimiza un índice acumulado de desempeño a lo largo del horizonte de predicción. En esta formulación, $L(\tilde{x}(t), u(t))$ es el costo instantáneo, el cual penaliza la desviación del sistema respecto al comportamiento deseado y el esfuerzo de control asociado. La Ecuación (7) no describe una variable física aislada, sino el criterio que utiliza el controlador para seleccionar la acción más conveniente. En esta ley de control, las restricciones de Lyapunov son las que diferencian al LMPC de un MPC no lineal convencional, ya que incorporan condiciones adicionales orientadas a preservar la estabilidad del sistema y el desempeño dinámico. La región interna Ω_{ρ_e} corresponde a un subconjunto de la región de estabilidad, más próximo al equilibrio, dentro del cual se busca que la evolución del sistema permanezca acotada y con comportamiento estable. La restricción de la Ecuación (10) actúa cuando el estado aún no ha ingresado a la región interna Ω_{ρ_e} ; esta condición obliga a que la evolución del sistema continúe orientándose hacia una zona estable de operación. La restricción de la Ecuación (11) opera cuando el estado se encuentra dentro de esa región interna y exige que la trayectoria predicha permanezca en ella durante el horizonte de predicción. Es decir, una restricción impulsa la convergencia y la otra evita que se salga de ella (Abdullah & Christofides, 2023; Oyama et al., 2022).

Sobre esta formulación base, el EMPC introduce un cambio específico en la función objetivo. En lugar de minimizar un costo de seguimiento, el problema pasa a optimizar una función económica $L_e(\tilde{x}, u)$, asociada, por ejemplo, con costo operativo, consumo energético, productividad o rendimiento. Su forma general puede expresarse como:

$$\min_{u(\cdot) \in S(\Delta)} \int_{t_k}^{t_k+N} L_e(\tilde{x}(t), u(t)) dt \quad (\text{Ec.11})$$

Sujeto al mismo modelo predictivo y a las mismas restricciones físicas del proceso. La principal ventaja de esta formulación es que orienta el control hacia metas directamente relevantes para la operación industrial. Sin embargo, la sola minimización de L_e no garantiza estabilidad, ya que una función económica no tiene por qué ser positiva definida ni penalizar explícitamente la distancia al equilibrio, entendida como qué tan lejos se encuentra el estado actual del proceso respecto a la condición estacionaria deseada (Oyama *et al.*, 2022). Por ello, el LEMPC surge para conciliar la optimización económica con la estabilidad en lazo cerrado, pues conserva la función objetivo económica del EMPC, pero añade restricciones de tipo Lyapunov que establecen condiciones adicionales para que las trayectorias predichas por el controlador sean viables desde el punto de vista físico y operativo, y compatibles con la estabilidad del sistema. La Tabla 2 resume varias aplicaciones de sistemas LMPC, EMPC y LEMPC a problemas concretos de control de procesos químicos.

Tabla 2.

Aplicaciones industriales y de investigación de LMPC, EMPC y LEMPC

Enfoque	Modelo predictivo / base del controlador	Aplicación o proceso	Variables / objetivo principal	Referencia
LEMPC	LEMPC con modelo no lineal y restricciones de estabilidad basadas en Lyapunov.	CSTR no isotérmico con reacción irreversible de segundo orden $A \rightarrow B$	Variable manipulada: C_{A0} (Concentración de A a la entrada) y Q (Calor) Variable controlada: C_A y T (Temperatura) Perturbaciones: disturbios acotados en las dinámicas del reactor Objetivo principal: Garantizar operación segura manteniendo el estado (real y medido) dentro de una región estable bajo ciberataques en sensores y actuadores, preservando a la	Oyama et al. (2022)

Enfoque	Modelo predictivo / base del controlador	Aplicación o proceso	Variables / objetivo principal	Referencia
			vez el desempeño económico del LEMPC	
LMPC	LSTM-based MPC con predictor LSTM para compensar retardos de entrada. El artículo define LSTM como un tipo de RNN.	CSTR de segundo orden con corriente de recirculación.	Variable manipulada: C_{A_0} (Concentración de A a la entrada) y Q (Calor) Variable controlada: C_A y T (Temperatura) Perturbaciones: retardos en estado (d_1) y en entrada (d_2) Objetivo principal: estabilizar el sistema y llevarlo al estado estacionario, compensando retardos de estado y de entrada.	Alnajdi et al. (2023)
LMPC / LEMPC	Modelo no lineal obtenido mediante SINDy (<i>Sparse Identification of Nonlinear Dynamics</i>) con actualización en línea disparada por error. El artículo indica que el ejemplo químico se demuestra bajo el marco de LEMPC.	CSTR no isotérmico con conversión catalítica $A \rightarrow B$ y desactivación del catalizador.	Variables manipuladas: ΔC_{A_0} , ΔQ (calor) Variable controlada: C_A y T (Temperatura) Perturbaciones: disturbios acotados y cambios de planta (desactivación del catalizador) Objetivo principal: optimizar la producción de B y mantener las trayectorias en la región de estabilidad.	Abdullah y Christofides (2023)
EMPC	Modelos lineales empíricos identificados con pruebas escalón en el punto nominal y estimación de estados con filtro de Kalman	Circuito de molienda con prensa de rodillos de alta presión (HPGR), molino de bolas y flotación	Variables manipuladas: caudal de mineral M , velocidad de rodillos v , presión del HPGR P , caudal de pulpa V , caudal de agua al tanque $V_{w,1}$ y caudal de agua al molino $V_{w,2}$ Variables controladas: nivel del HPGR L , presión del hidrociclón P_c , fracción de sólidos χ_s y nivel del tanque L_t .	Thivierge et al. (2023)

Enfoque	Modelo predictivo / base del controlador	Aplicación o proceso	Variables / objetivo principal	Referencia
			<p>Perturbaciones: tamaño de alimentación del mineral y dureza del mineral.</p> <p>Objetivo principal: comparar desempeño económico y consumo específico de energía.</p>	

3.4.2 Modelado híbrido dinámico

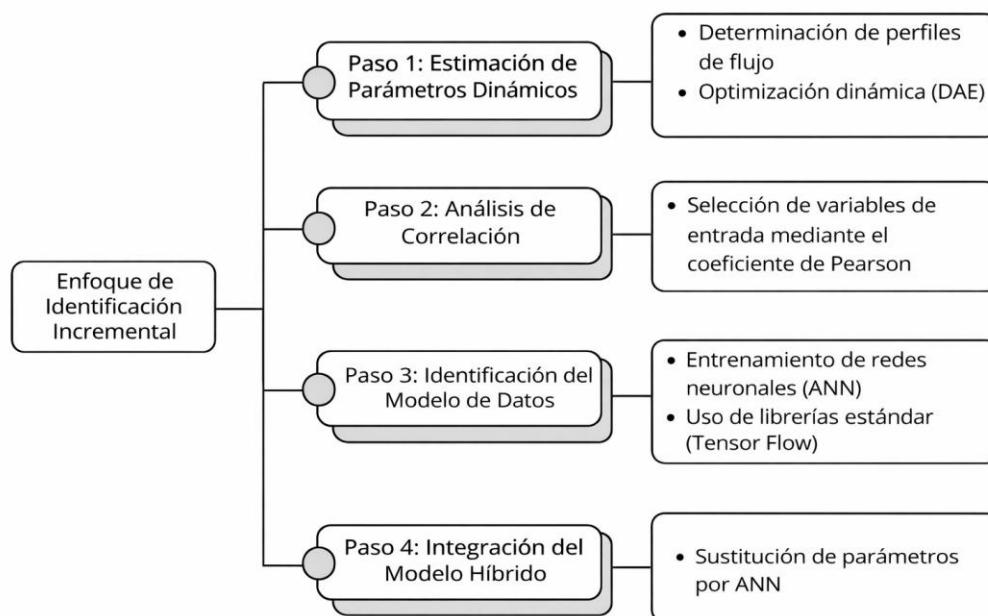
El modelado híbrido dinámico es una técnica de identificación y representación de procesos en la que se integra una estructura basada en principios físicos, expresada a través de ecuaciones diferenciales y/o algebraicas, con componentes construidos a partir de datos experimentales, tales como modelos de aprendizaje automático – redes neuronales - (Caspari *et al.*, 2026; Pinto *et al.*, 2022). Esto permite mejorar la descripción de dinámicas que no pueden ser representadas con suficiente precisión mediante una formulación basada en las leyes físicas, particularmente en presencia de no linealidades, incertidumbres paramétricas, perturbaciones no medidas e interacciones complejas entre variables. Si bien no corresponde a una estrategia de control en sí misma, la formulación obtenida puede emplearse en MPC.

Las redes neuronales artificiales (ANN) se usan frecuentemente para aproximar términos inciertos, desconocidos o no lineales, como cinéticas de reacción, coeficientes de transferencia o efectos no modelados. Mediante una metodología de identificación incremental, las ANN mapean la relación entre variables de estado y parámetros inciertos; una vez entrenadas, se integran a la estructura basada en principios físicos del proceso, expresada mediante ecuaciones diferenciales y/o algebraicas (DAE). La Figura 5 resume la metodología de identificación incremental empleada en la construcción del modelo híbrido dinámico. En la primera etapa, los términos inciertos se estiman mediante la resolución de un problema de optimización dinámica, formulado para que la

respuesta del modelo reproduzca adecuadamente los datos experimentales; con este fin, se incorpora un término de regularización que penaliza cambios bruscos en los valores estimados de esos parámetros entre intervalos consecutivos y favorece perfiles temporalmente suaves y físicamente plausibles. Posteriormente, se realiza un análisis de correlación para identificar las variables de entrada con mayor influencia sobre los parámetros estimados; a partir de esta selección, se entrena un modelo basado en datos (ANN) capaz de representar las dinámicas que no son descritas con suficiente precisión por las ecuaciones de conservación y las relaciones fenomenológicas. Finalmente, el modelo entrenado se integra en la estructura física del proceso mediante la sustitución de los parámetros inciertos, y se valida su capacidad de representación.

Figura 5.

Metodología de identificación incremental



El uso de redes neuronales enfrenta desafíos cuando el modelo incorpora un número elevado de variables de entrada, de estado o variables retardadas. Zhao *et al.*, (2023) señalan que el aumento del número de variables de entrada puede generar problemas de sobreajuste,

incrementar el costo computacional y dificultar la interpretación del modelo, lo cual se conoce como *curse of dimensionality*. Los autores proponen identificar subconjuntos de variables relevantes para el entrenamiento de la ANN, basándose en medidas estadísticas independientes del modelo.

Por otra parte, Elsheikh *et al.*, (2024) plantean un enfoque de MPC basado en un modelo híbrido confiable, en el que un modelo físico simplificado describe la dinámica principal del proceso (columna de destilación) y un componente basado en datos se utiliza para compensar las discrepancias entre las predicciones del modelo físico y el comportamiento real del proceso. El modelo físico se fundamenta en balances de materia por etapa (Ecuación 12), relaciones de flujo líquido entre etapas (Ecuación 13) y ecuaciones de equilibrio vapor-líquido (Ecuación 14).

$$\frac{dc_{i,j}^x}{dt} = \frac{1}{M_i} (V_{i+1}c_{i+1,j}^y - V_i c_{i,j}^y + F_i z_j^{feed} + L_{i-1}c_{i-1,j}^x - L_i c_{i,j}^x), \text{ (Ec. 12)}$$

$$\forall i = \{1, \dots, N_s\}, j = 1 \dots N_{comp} = 4$$

$$L_i = F_i + L_{i-1}, \quad \forall i = \{1, \dots, N_s\} \text{ (Ec. 13)}$$

$$c_{i,j}^y = \frac{\delta_{i,j}(c_i^x, T_i) P_{j,i}^s c_{i,j}^x}{P_i} \text{ (Ec. 14)}$$

El componente basado en datos emplea una ANN como elemento de predicción. Los autores generaron dos conjuntos de datos mediante el software de simulación UniSim Design, bajo un esquema de control predictivo basado en un modelo físico simplificado (PBMPC). El primer conjunto de datos se obtuvo tras 60 horas de operación y alta variabilidad dinámica en la composición y flujo de alimentación; para el segundo conjunto analizaron 15 horas de operación con composición de alimentación constante y perturbaciones de flujo menos frecuentes. El modelo obtenido, aunque preciso en las regiones donde fue entrenada la ANN, tiene una capacidad de extrapolación limitada si el proceso entra en una zona de operación desconocida (fuertes oscilaciones en el caudal de alimentación, por ejemplo); esto implica que, un modelo puramente

basado en datos puede perder confiabilidad fuera de su dominio de validez. Para superar esa limitación, la estrategia híbrida combina ambos modelos (Ecuación 15): el modelo físico genera la predicción base del sistema y el modelo basado en datos estima el error de esa predicción.

$$\tilde{y}_{k+1} = y_{k+1} + \gamma_{k+1}e_{k+1} \quad (\text{Ec. 15})$$

Donde, \tilde{y}_{k+1} es la salida del modelo híbrido; y_{k+1} es la salida del modelo físico; e_{k+1} es la corrección estimada por el modelo basado en datos; y γ_{k+1} es un factor de ponderación que regula la contribución del modelo basado en datos. Este factor reduce gradualmente la influencia del modelo basado en datos cuando el sistema opera fuera del dominio de validez, de modo que el controlador vuelve a apoyarse principalmente en la robustez del modelo físico.


3.4.3 Control predictivo basado en redes neuronales (NNMPC)

El NNMPC es una variante del MPC en la que el modelo dinámico del proceso, o una aproximación de la ley de control, se representa mediante una ANN. La red neuronal aprende, a partir de datos, la relación no lineal entre variables, y posteriormente se incorpora al esquema predictivo para anticipar la evolución del sistema en un horizonte finito (Bannoud *et al.*, 2022). La Figura 6 muestra la estructura general de ANN, donde las variables de entrada se propagan a través de capas ocultas hasta generar las salidas predichas del modelo neuronal. En estos esquemas conviene distinguir tres etapas: entrenamiento, entendido como el ajuste de pesos y sesgos de la red a partir de una base de datos; validación, utilizada para verificar el desempeño del modelo con datos no empleados directamente en el ajuste y detectar problemas de sobreajuste; e inferencia, correspondiente al uso en línea de la red para generar predicciones o proponer acciones de control.(Bannoud *et al.*, 2022; Khurram Faridi *et al.*, 2024). El diseño y entrenamiento de estas

redes se realiza en software como MATLAB o Python 3.7, junto con sus bibliotecas KERAS y TensorFlow.

Figura 6.

Arquitectura de una red neuronal empleada en un esquema NNMPC.



Nota. adaptada de Bannoud et al. (2022).

La ley de control está definida por la Ecuación 16. La integral es un índice acumulado de desempeño en el horizonte de predicción y su función es cuantificar, de manera conjunta, la desviación de la salida - $\hat{y}(t)$ - respecto al valor deseado y el esfuerzo de control requerido para corregirla - $u(t)$ -; por lo tanto, su minimización busca un compromiso entre precisión de seguimiento, suavidad de la acción de control y cumplimiento de restricciones.

$$\min_u \int_{t_k}^{t_k+N_h} L(\hat{y}(t), u(t)) dt \quad (\text{Ec. 16})$$

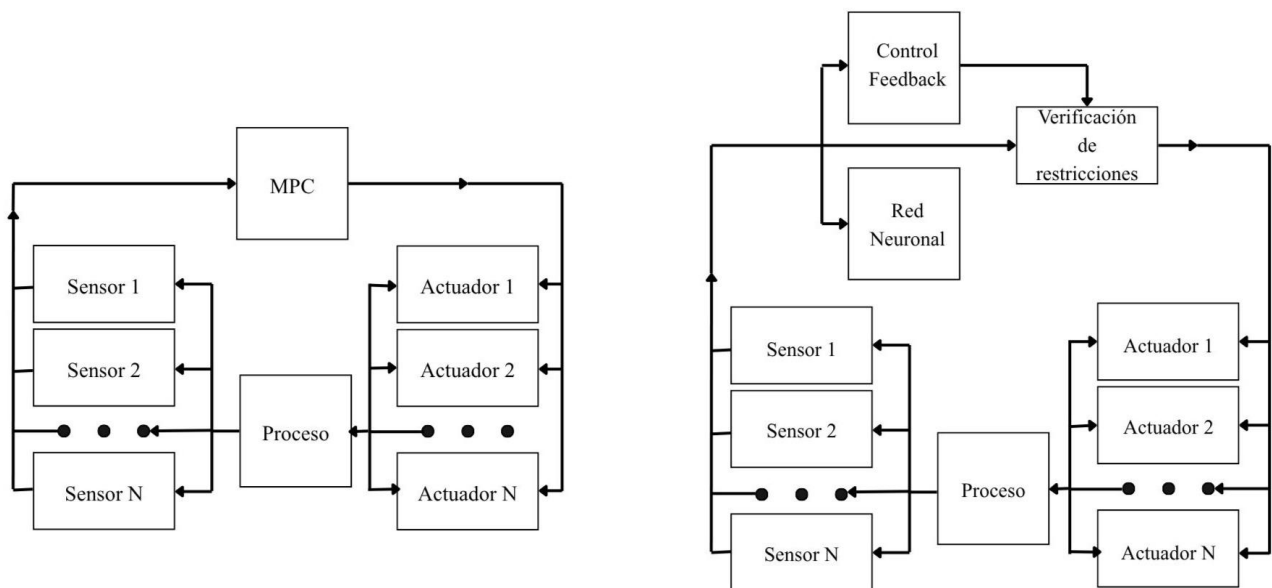
Sujeto a:

$$\hat{x}(t) = F_\theta(\hat{x}(t), u(t)), \quad \hat{y}(t) = h_\theta(\hat{x}(t)), \quad u(t) \in \mathbf{U}$$

El término $L(\hat{y}(t), u(t))$ es la función de costo instantáneo; $\hat{x}(t)$ representa el vector de estados predichos, el conjunto de variables internas con las que el modelo describe la evolución dinámica del proceso; F_θ y h_θ son las funciones parametrizadas del modelo neuronal, donde F_θ describe la evolución dinámica de los estados y h_θ su correspondencia con las salidas; N_h es el horizonte de predicción; y U es el conjunto de restricciones admisibles sobre las variables manipuladas. Un ejemplo representativo de este enfoque fue reportado por Khurram Faridi *et al.*, (2024) para un proceso de gasificación de biomasa en lecho fluidizado. Se empleó una red con el fin de predecir la evolución de la temperatura en tres regiones espaciales del gasificador. La función objetivo del controlador penaliza la desviación cuadrática entre la temperatura predicha y su valor de referencia (*set point*), así como las variaciones de los caudales de biomasa, aire primario y aire secundario, con el propósito de evitar acciones de control excesivamente bruscas, reportando errores estacionarios inferiores al 1.5 % y tiempos de respuesta menores a 5 s.

Figura 7.

Arquitectura convencional MPC vs arquitectura ANN con verificación de restricciones.



Nota. Adaptada de Khodaverdian *et al.*, (2025).

Por otra parte, cuando el control predictivo no lineal (NMPC) se formula con modelos de alta fidelidad, múltiples restricciones y horizontes de predicción amplios, su implementación en línea puede resultar costosa desde el punto de vista computacional, ya que en cada instante de muestreo debe resolverse un problema de optimización no lineal cuya complejidad crece con la dimensión del sistema y con el número de variables y restricciones. Khodaverdian *et al.*, (2026) propusieron una arquitectura en la que una red neuronal aproxima la acción de control del MPC, mientras un bloque externo verifica si la acción calculada satisface restricciones de estabilidad. La Figura 7 resume esta arquitectura de control: la red neuronal genera una acción candidata, un bloque de validación comprueba su admisibilidad y, si esta no satisface las condiciones de estabilidad, la señal se reemplaza mediante un controlador de respaldo estabilizante. Esta organización permite entender con claridad que la estabilidad no queda integrada en el entrenamiento de la red, sino que se garantiza en una etapa posterior a la inferencia.

Bannoud *et al.*, (2022) desarrollaron un NNMPC para un circuito cerrado de molienda seca con molino de bolas, caracterizado por altos tiempos muertos y fuerte interacción entre variables; en comparación con esquemas convencionales y con un MPC lineal, los autores reportaron reducciones de hasta 79 % en sobreimpulso y 74.2 % en tiempo de asentamiento. Otra aplicación es la reportada por El Qassime *et al.*, (2026) para un reactor CSTR multiproducto; el estudio muestra la capacidad de modificar la acción de control conforme cambian decisiones operativas como la secuencia de productos, las tasas de producción y los valores de referencia (*set points*) asociados, con un NRMSE (raíz del error cuadrático medio normalizado por sus siglas en inglés) de 1.19 % y una reducción cercana al 98.8 % en el tiempo de cálculo en línea frente a un NMPC, debido a que la red neuronal reemplaza la resolución repetitiva del problema de optimización por una evaluación algebraica mucho más rápida.

3.5 Lógica difusa

La lógica difusa constituye una estrategia de control basada en reglas lingüísticas que permite representar, de manera aproximada, el conocimiento del proceso y traducirlo en acciones de control para sistemas no lineales, inciertos o difíciles de modelar con precisión. A diferencia del modelado híbrido dinámico, que corresponde principalmente a una técnica de identificación y representación del proceso, la lógica difusa sí puede emplearse directamente como estrategia de control o integrarse con otras metodologías avanzadas. En el contexto de los procesos químicos, su principal utilidad radica en que permite manejar no linealidades, cambios en el punto de operación, perturbaciones y restricciones sin depender de forma exclusiva de un modelo fenomenológico exacto (Herrera *et al.*, 2025; D. Li *et al.*, 2023; Xavier *et al.*, 2025)

3.5.1 Modelado difuso de Takagi-Sugeno

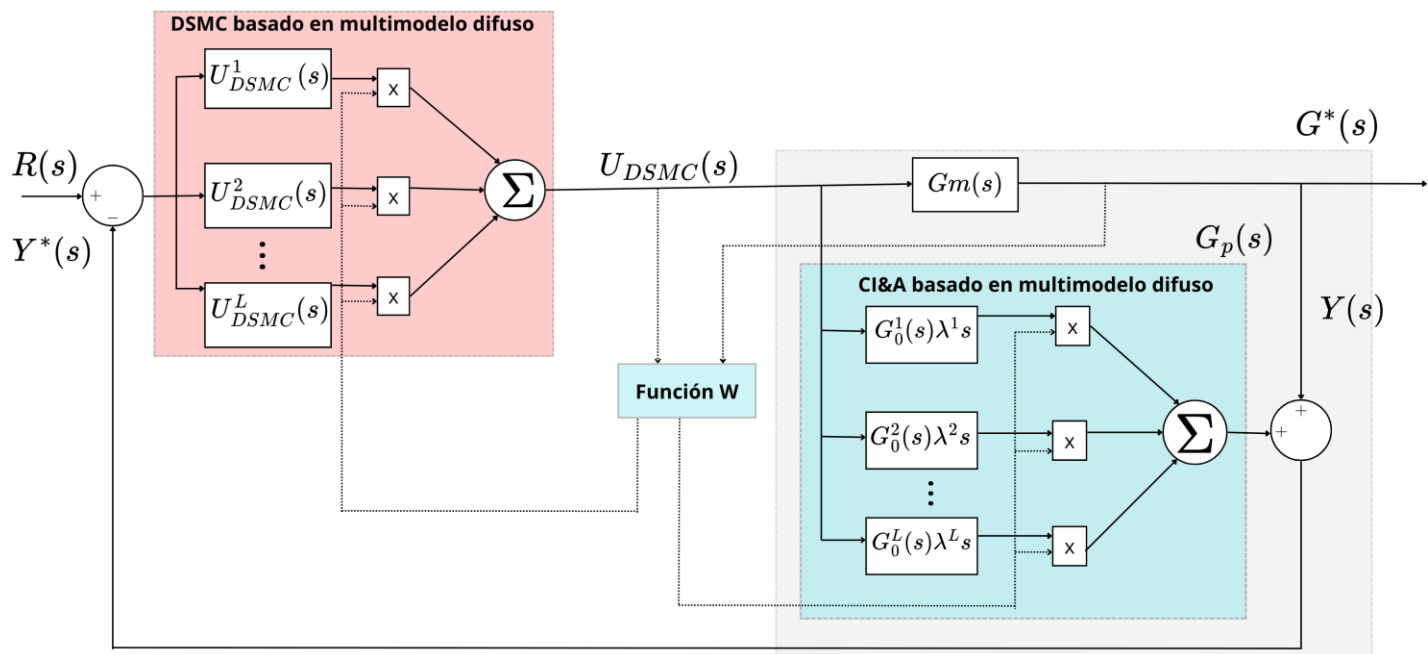
El modelado de Takagi-Sugeno (TS) es una técnica de representación de sistemas no lineales que consiste en descomponer la dinámica global del proceso en un conjunto de modelos locales lineales, cada uno válido en una región de operación específica. Estos modelos locales son activados y combinados mediante reglas difusas, que son enunciados lingüísticos condicionales de tipo si-entonces (*IF-ELSE*), que establecen en qué condiciones del proceso se utiliza un determinado modelo local (J. Li *et al.*, 2024). Tales condiciones se establecen a partir de las variables de premisa; es decir, variables medibles que permiten identificar en qué región de operación se encuentra el proceso. De este modo, la respuesta total del proceso se construye a partir de una interpolación suave entre las distintas dinámicas locales, lo que permite describir procesos químicos complejos y facilita el diseño de estrategias de control (Herrera *et al.*, 2025).

La Figura 8 presenta la arquitectura general del controlador dinámico por modo deslizante basado en un multimodelo difuso de Takagi-Sugeno. En esta estructura, la señal global de control

$U_{DSMC}(s)$ se obtiene a partir de la combinación difusa de varios controladores locales; para ello se emplea una función de ponderación difusa (W), la cual determina el grado de activación de cada modelo local y de cada compensador local según la región de operación del proceso. Así mismo, la dinámica del proceso a controlar se representa mediante el multimodelo $G_m(s)$, mientras que la salida del proceso $Y(s)$ y la salida del compensador $G_p(s)$ dan lugar a la dinámica equivalente $G^*(s)$, la cual representa el modelo empleado para la síntesis del controlador.

Figura 8.

Esquema del controlador dinámico por modo deslizante (DSMC) basado en un multimodelo difuso de Takagi-Sugeno.



Nota. Adaptada a partir de Herrera *et al.*, (2025).

La Ecuación 17 representa la dinámica equivalente global capturada por el controlador, obtenida como una combinación ponderada de los modelos locales del multimodelo difuso. En ella, K_j , τ_j y t_{0j} son la ganancia, la constante de tiempo y el retardo del modelo local j , respectivamente, mientras que λ_j es un parámetro de ajuste del compensador; $\beta_j(z)$ representa el

grado de activación de la regla difusa asociada al modelo J ; y $G^*(s)$ describe la relación entre la salida equivalente $Y^*(s)$ y la acción de control $U(s)$, permitiendo que la dinámica del sistema varíe suavemente entre distintas regiones de operación.

$$G^*(s) = \sum_{j=1}^L \left[\frac{K_j \left[\left(\lambda_j - \frac{t_{0j}}{2} \right) s + 1 \right]}{(\tau_j s + 1) \left(\frac{t_{0j}}{2} s + 1 \right)} \right] \beta_j(z) \quad (\text{Ec. 17})$$

En el Apéndice E se presenta la formulación general de las reglas difusas del modelo Takagi-Sugeno. Una aplicación representativa de la lógica difusa en procesos químicos corresponde al control de sistemas con retardo prolongado. Herrera *et al.*, (2025) validaron su propuesta una plataforma experimental de control térmico en configuración SISO, cuyo objetivo fue regular la temperatura del sistema mediante la manipulación de la potencia del calentador. Los autores realizaron tres pruebas para evaluar el desempeño del controlador. En la prueba de seguimiento de referencia se analizaron los cambios en el *setpoint* para verificar la capacidad del sistema de seguir la señal deseada; en la prueba de incertidumbre se evaluó el comportamiento del controlador ante variaciones o errores en los parámetros del proceso; y en la prueba de perturbación se examinó su respuesta frente a alteraciones externas aplicadas al sistema. En los tres escenarios evaluados se compararon tres estrategias de control: i) el control por modo deslizante convencional (SMC); ii) el control dinámico por modo deslizante (DSMC); y iii) el control dinámico por modo deslizante basado en un multimodelo difuso (FMMC-DSMC), con el fin de adaptar la acción de control a las distintas regiones de operación del proceso. El esquema FMMC-DSMC presentó el mejor desempeño en términos de precisión, error acumulado y esfuerzo de control, sobretodo en el escenario de perturbaciones externas; esta estrategia reduce el error de seguimiento y mantiene una acción de control menos agresiva, en comparación con los esquemas de control SMC y DSMC.

3.6 Control basado en aprendizaje por refuerzo (*RL*)

Otra estrategia de control en investigación es el aprendizaje por refuerzo (*Reinforcement Learning*, *RL*), la cual consiste en que un elemento (agente) que interactúa con el proceso para aprender una ley de control, ajusta sus acciones a partir de la experiencia acumulada durante la operación. En el contexto de los procesos químicos, este enfoque resulta atractivo por su capacidad para manejar no linealidades, incertidumbre operativa y dificultades de modelado. Sin embargo, su implementación práctica aún enfrenta desafíos importantes, entre ellos la exploración segura, la garantía de estabilidad en línea y la transferencia efectiva desde entornos de simulación hacia aplicaciones industriales (Bras *et al.*, 2024; Hassanpour *et al.*, 2025; Park *et al.*, 2026). Una discusión más detallada sobre sus fundamentos teóricos se presenta en el Apéndice D.

4. Análisis TRL

Como parte del análisis comparativo de las estrategias avanzadas de control identificadas en esta revisión sistemática, se aplicó la metodología de niveles de madurez tecnológica (*Technology Readiness Levels*, TRL) con el propósito de estimar el grado de desarrollo alcanzado por cada enfoque y su cercanía a una eventual implementación industrial. El análisis se orientó al tipo de validación alcanzada, considerando si la estrategia fue evaluada mediante formulación teórica, simulación dinámica, validación en banco experimental, utilización de datos de planta o implementación en un entorno industrial real. De este modo, la clasificación se apoya en una escala de nueve niveles (Apéndice B), donde el TRL 1 corresponde a principios básicos o idea inicial y el TRL 9 a una tecnología plenamente operable y comercializada.

Tabla 3.

Nivel TRL de las tecnologías analizadas para el control avanzado de procesos químicos

Tipo de tecnología	Rango TRL	Tecnología más avanzada
LMPC / EMPC / LEMPC	4–5	(Thivierge <i>et al.</i> , 2023): EMPC aplicado a un circuito de molienda con HPGR, molino de bolas y flotación, evaluado completamente en un circuito simulado para comparar desempeño económico y consumo específico de energía (TRL 5).
NNMPC	4–5	(Khurram Faridi <i>et al.</i> , 2024): controlador basado en red neuronal para gasificación de biomasa; el modelo LSTM se entrenó con mediciones de un gasificador piloto, y el desempeño del controlador se evaluó en lazo cerrado mediante un modelo CFD del proceso (TRL 5).
Modelado híbrido dinámico / HMPC	5–6	(Caspari <i>et al.</i> , 2026): modelo híbrido dinámico integrado con MPC, con tres casos de estudio, incluyendo uno en una planta de investigación real, donde el modelo híbrido se valida con datos medidos y se usa como modelo del controlador (TRL 6).

Aprendizaje por refuerzo (RL)	4–8	(Park <i>et al.</i> , 2026): implementación de offline <i>reinforcement learning</i> para el control de una columna de separación de pared divisoria industrial, con preentrenamiento usando datos históricos, estudios de simulación y experimentos en una planta petroquímica real (TRL 8)
Lógica difusa / Takagi-Sugeno	4–5	(Herrera <i>et al.</i> , 2025): control difuso multimodelo validado mediante experimentos en tiempo real sobre TCLab, utilizado como banco experimental para evaluar modelado y desempeño del controlador (TRL 5).

Las estrategias analizadas en este trabajo, resumidas en la Tabla 3, evidencian en conjunto un nivel de madurez tecnológica intermedio. En términos generales, la mayor parte de los desarrollos identificados se concentra entre los niveles TRL 4 y 6, indicando que, aunque estas tecnologías han superado la fase puramente conceptual y han sido sometidas a validaciones computacionales, de laboratorio o en entornos relevantes, todavía no alcanzan una adopción industrial amplia y sostenida. Este comportamiento es consistente con lo observado en el trabajos de Ramírez & Ramírez, (2025), donde se observa que muchas propuestas tecnológicas, pese a su alto potencial técnico, permanecen en etapas computacionales o de validación experimental limitada, con barreras asociadas a la escalabilidad, los costos operativos y la adaptación a condiciones industriales reales.

Las variantes basadas en MPC, en particular LMPC, EMPC y LEMPC, así como los enfoques de NNMPC, se ubican en rangos de madurez intermedios: estudios de simulación rigurosa, validaciones en lazo cerrado y entornos experimentales controlados, pero con transición todavía limitada hacia aplicaciones industriales plenamente documentadas. Esto sugiere que, aunque estas familias presentan un desarrollo metodológico sólido y resultados prometedores en términos de estabilidad, optimización y desempeño dinámico, su escalado depende aún de etapas adicionales de verificación en condiciones operativas más cercanas a planta.

El modelado híbrido dinámico, entendido como tecnología habilitante de esquemas predictivos más robustos, exhibe una posición relativamente más avanzada dentro del conjunto analizado. Esto se debe a que su desarrollo no se limita únicamente a la comparación teórica de modelos, sino que ya incorpora casos de integración con control predictivo en entornos de investigación con mayor cercanía a la operación real. En consecuencia, esta familia tecnológica muestra una transición más clara desde la validación computacional hacia escenarios preindustriales, lo que justifica su ubicación en un rango TRL de 5 a 6.

Por otra parte, la lógica difusa y los modelos Takagi-Sugeno se mantienen en un nivel intermedio, apoyados por validaciones en simulación y experimentos en tiempo real sobre plataformas de laboratorio, aunque todavía con evidencia limitada de despliegue industrial sostenido. En contraste, el aprendizaje por refuerzo (RL) presenta una mayor dispersión en madurez tecnológica: coexisten desarrollos todavía centrados en prueba de concepto, entrenamiento seguro o validación en entornos controlados, junto con casos de mayor avance, como el de Park *et al.*, (2026), quienes lo implementaron en una columna industrial de pared divisoria (DWC) dentro de una planta petroquímica real. Esta heterogeneidad justifica el rango amplio asignado (TRL 4 a 8).

De acuerdo con lo anterior, la vigilancia tecnológica sugiere que, aunque las estrategias avanzadas de control presentan una base teórica sólida y un desarrollo algorítmico robusto, la mayoría permanece en etapas de simulación, laboratorio o validación en entornos de investigación. Esto se refleja en trabajos como los de Thivierge *et al.*, (2023) y Khurram Faridi *et al.*, (2024), donde las propuestas se evalúan en circuitos simulados o en esquemas de validación controlada, mientras que Caspari *et al.*, (2026) y Park *et al.*, (2026) presentan un mayor acercamiento a condiciones reales de operación. Esa diferencia entre desarrollo metodológico y adopción

industrial también puede reconocerse en un contexto regional real: según reportes de la literatura (Barón & Velasco, 2021; Urzola *et al.*, 2015), en la refinería de Barrancabermeja hay una incorporación progresiva de estrategias de control avanzado; por una parte, herramientas de monitoreo, integración de datos y análisis operacional en tiempo real, soportadas en plataformas como PI System, PI Vision y PI Datalink, y por otra la aplicación de técnicas de control DCS (múltiples controladores conectados entre sí en red operando coordinadamente) en las unidades de alquilación y MPC en hidrocracking. Esto refuerza la idea de que la principal barrera no es la falta de innovación conceptual, sino la validación, integración y escalado progresivo en plantas reales.

5. Conclusiones

La revisión permitió identificar que la producción científica reciente en control avanzado de procesos químicos se concentra, principalmente, en Estados Unidos, China y Singapur, mostrando que el desarrollo de estas metodologías está fuertemente asociado con entornos industriales de alta automatización, inversión sostenida en investigación y adopción de tecnologías digitales. En este sentido, las investigaciones sobre control avanzado no se distribuyen de manera homogénea, sino que se concentra en países con mayor capacidad para integrar modelado, automatización e inteligencia artificial en problemas reales de ingeniería química.

Las investigaciones sobre control avanzado de proceso se enfocan en control predictivo basado en modelo (MPC) y sus variantes LMPC, EMPC y LEMPC, el modelado híbrido dinámico integrado con MPC, el control predictivo basado en redes neuronales (NNMPC), el aprendizaje por refuerzo (RL) y la lógica difusa. Estas estrategias han sido evaluadas en reactores CSTR, circuitos de molienda, gasificación de biomasa, columnas de destilación y sistemas con múltiples restricciones operativas. En términos comparativos, el MPC destaca por su capacidad para manejar restricciones y anticipar el comportamiento del proceso; los enfoques híbridos mejoran la representación de dinámicas complejas al combinar balances físicos con datos; las redes neuronales y el RL ofrecen flexibilidad frente a no linealidades y cambios operativos; y la lógica difusa resulta útil cuando existe incertidumbre o conocimiento heurístico del proceso.

Finalmente, la revisión mostró que la principal barrera no es la falta de propuestas metodológicas, sino la dificultad de transferirlas desde simulación, laboratorio o entornos de investigación hacia condiciones industriales reales. La mayor parte de las estrategias revisadas se ubica en niveles intermedios de madurez tecnológica, con validaciones en simulación, banco experimental, planta piloto o estudios de factibilidad, y una evidencia limitada de despliegue

sostenido en operación industrial. Entre los desafíos más reiterados se encuentran la necesidad de mayor validación experimental, la integración con la infraestructura de automatización existente, la disponibilidad de datos operacionales confiables, la exigencia de seguridad y estabilidad en línea, y la carga computacional de los esquemas más complejos.

Referencias Bibliográficas

- Abdullah, F., & Christofides, P. D. (2023). Real-time adaptive sparse-identification-based predictive control of nonlinear processes. *Chemical Engineering Research and Design*, *196*, 750-769. <https://doi.org/10.1016/j.cherd.2023.07.011>
- Abou El Qassime, M., Shokry, A., Espuña, A., & Moulines, E. (2026). Development of approximate scheduling-adaptive controllers for multi-products continuous chemical processes using deep learning techniques and model predictive control. *Computers & Chemical Engineering*, *204*, 109359. <https://doi.org/10.1016/j.compchemeng.2025.109359>
- Alnajdi, A., Suryavanshi, A., Alhajeri, M. S., Abdullah, F., & Christofides, P. D. (2023). Machine learning-based predictive control of nonlinear time-delay systems: Closed-loop stability and input delay compensation. *Digital Chemical Engineering*, *7*, 100084. <https://doi.org/10.1016/j.dche.2023.100084>
- Åström, K. J., & Hägglund, T. (2001). The future of PID control. *Control Engineering Practice*, *9*(11), 1163-1175. [https://doi.org/10.1016/S0967-0661\(01\)00062-4](https://doi.org/10.1016/S0967-0661(01)00062-4)
- Bannoud, M. A., Martins, T. D., & Dos Santos, B. F. (2022a). Control of a closed dry grinding circuit with ball mills using predictive control based on neural networks. *Digital Chemical Engineering*, *5*, 100064. <https://doi.org/10.1016/j.dche.2022.100064>
- Bannoud, M. A., Martins, T. D., & Dos Santos, B. F. (2022b). Control of a closed dry grinding circuit with ball mills using predictive control based on neural networks. *Digital Chemical Engineering*, *5*, 100064. <https://doi.org/10.1016/j.dche.2022.100064>

- Barón Vergara & Velasco Cardozo. (2021). *Diseño e implementación de un modelo estandarizado de análisis operacional en la refinería Barrancabermeja ECOPETROL S.A. usando los software PI DATALINK y PI VISION*. Universidad Industrial de Santander.
- Bequette, B. W. (2019). Process control practice and education: Past, present and future. *Computers & Chemical Engineering*, 128, 538-556. <https://doi.org/10.1016/j.compchemeng.2019.06.011>
- Bras, E. H., Louw, T. M., & Bradshaw, S. M. (2024). Safe, visualizable reinforcement learning for process control with a warm-started actor network based on PI-control. *Journal of Process Control*, 144, 103340. <https://doi.org/10.1016/j.jprocont.2024.103340>
- Caspari, A., Bierweiler, T., Fadda, S., Labisch, D., Nauta, M., Wagner, F., Warmbold, M., & Pantelides, C. C. (2026). Dynamic hybrid modeling: Incremental identification and model predictive control. *Computers & Chemical Engineering*, 204, 109413. <https://doi.org/10.1016/j.compchemeng.2025.109413>
- Elsheikh, M., Ortmanns, Y., Hecht, F., Roßmann, V., Krämer, S., & Engell, S. (2024). *Trustworthy Data-Driven Model Predictive Control Using a Hybrid Model with Monitoring and Adaptation of the Domain of Validity*. SSRN. <https://doi.org/10.2139/ssrn.5037915>
- Fajardo, H. K. P. (s. f.). *PRODUCCIÓN DE HIDRÓGENO VERDE A PARTIR BIOMASA RESIDUAL: UNA VIGILANCIA TECNOLÓGICA*.
- Fileti, A. M. F., Antunes, A. J. B., Silva, F. V., Silveira, V., & Pereira, J. A. F. R. (2007). Experimental investigations on fuzzy logic for process control. *Control Engineering Practice*, 15(9), 1149-1160. <https://doi.org/10.1016/j.conengprac.2007.01.009>

- Hassanpour, H., Corbett, B., & Mhaskar, P. (2025). A practical reinforcement learning control design for nonlinear systems with input and output constraints. *Computers & Chemical Engineering*, *201*, 109248. <https://doi.org/10.1016/j.compchemeng.2025.109248>
- Herrera, M., Camacho, O., & Prado, A. (2025). Fuzzy multi-model based dynamic sliding mode control for chemical process with long-time delay. *Results in Engineering*, *25*, 104193. <https://doi.org/10.1016/j.rineng.2025.104193>
- Khelifi Otmane, K., & Bessaad, T. (2024). Transient response improvement of predictive control under time domain constraints. *Heliyon*, *10*(23), e40260. <https://doi.org/10.1016/j.heliyon.2024.e40260>
- Khodaverdian, A., Gohil, D., & Christofides, P. D. (2026). Uniting neural network-based control and model predictive control: Application to a large-scale nonlinear process. *Computers & Chemical Engineering*, *204*, 109396. <https://doi.org/10.1016/j.compchemeng.2025.109396>
- Khurram Faridi, I., Tsotsas, E., Heineken, W., Koegler, M., & Kharaghani, A. (2024). Development of a neural network model predictive controller for the fluidized bed biomass gasification process. *Chemical Engineering Science*, *293*, 120000. <https://doi.org/10.1016/j.ces.2024.120000>
- Li, D., Wang, Y., Liu, Y.-J., & Liu, L. (2023). IBLFs-based adaptive fuzzy control for Continuous Stirred Tank Reactors with full state constraints and actuator faults. *Journal of Process Control*, *124*, 14-24. <https://doi.org/10.1016/j.jprocont.2023.02.002>
- Li, J., Fang, X., Zhang, Z., Wang, Y., Liu, X., & Zhang, M. (2024). Fault detection observer design for Takagi–Sugeno fuzzy systems with finite-frequency specifications. *ISA Transactions*, *155*, 274-285. <https://doi.org/10.1016/j.isatra.2024.10.010>

- Nian, R., Liu, J., & Huang, B. (2020). A review On reinforcement learning: Introduction and applications in industrial process control. *Computers & Chemical Engineering*, *139*, 106886. <https://doi.org/10.1016/j.compchemeng.2020.106886>
- Oyama, H., Messina, D., Rangan, K. K., & Durand, H. (2022). Lyapunov-Based Economic Model Predictive Control for Detecting and Handling Actuator and Simultaneous Sensor/Actuator Cyberattacks on Process Control Systems. *Frontiers in Chemical Engineering*, *4*, 810129. <https://doi.org/10.3389/fceng.2022.810129>
- Park, J., Choi, W., Kim, D. I., Park, H. E., & Lee, J. M. (2026). Real-world implementation of offline reinforcement learning for process control in industrial dividing wall column. *Computers & Chemical Engineering*, *204*, 109383. <https://doi.org/10.1016/j.compchemeng.2025.109383>
- Pinto, J., Mestre, M., Ramos, J., Costa, R. S., Striedner, G., & Oliveira, R. (2022). A general deep hybrid model for bioreactor systems: Combining first principles with deep neural networks. *Computers & Chemical Engineering*, *165*, 107952. <https://doi.org/10.1016/j.compchemeng.2022.107952>
- Qin, S. J., & Badgwell, T. A. (2003). A survey of industrial model predictive control technology. *Control Engineering Practice*, *11*(7), 733-764. [https://doi.org/10.1016/S0967-0661\(02\)00186-7](https://doi.org/10.1016/S0967-0661(02)00186-7)
- Ren, Y. M., Alhajeri, M. S., Luo, J., Chen, S., Abdullah, F., Wu, Z., & Christofides, P. D. (2022). A tutorial review of neural network modeling approaches for model predictive control. *Computers & Chemical Engineering*, *165*, 107956. <https://doi.org/10.1016/j.compchemeng.2022.107956>

- Sarhadi, P. (2025). *On the Standard Performance Criteria for Applied Control Design: PID, MPC or Machine Learning Controller?* (arXiv:2503.14379). arXiv. <https://doi.org/10.48550/arXiv.2503.14379>
- Sarhadi, P., Rezaie, B., & Rahmani, Z. (2016). Adaptive predictive control based on adaptive neuro-fuzzy inference system for a class of nonlinear industrial processes. *Journal of the Taiwan Institute of Chemical Engineers*, 61, 132-137. <https://doi.org/10.1016/j.jtice.2015.03.019>
- Soza Mamani, K. M., & Prado Romo, A. J. (2025). Integrating Model Predictive Control with Deep Reinforcement Learning for Robust Control of Thermal Processes with Long Time Delays. *Processes*, 13(6), 1627. <https://doi.org/10.3390/pr13061627>
- Thivierge, A., Bouchard, J., & Desbiens, A. (2023). Comparing economic model predictive control to basic and advanced regulatory control on a simulated high-pressure grinding rolls, ball mill, and flotation circuit. *Journal of Process Control*, 122, 159-171. <https://doi.org/10.1016/j.jprocont.2023.01.005>
- Urzola et al. (2015). *Optimización del proceso de alquilación mediante la determinación de parámetros a partir del método simplex en la refinería de ECOPETROL S.A en Barrancabermeja.*
- Xavier, J., Henry Barath, M. A., Patnaik, S. K., Panda, R. C., & Panda, A. (2025). Hybrid model using bond graph-TCN network and event triggered predictive control of pH neutralization process. *ISA Transactions*, 156, 639-654. <https://doi.org/10.1016/j.isatra.2024.11.025>
- Yu, D. L., & Gomm, J. B. (2003). Implementation of neural network predictive control to a multivariable chemical reactor. *Control Engineering Practice*, 11(11), 1315-1323. [https://doi.org/10.1016/S0967-0661\(02\)00258-7](https://doi.org/10.1016/S0967-0661(02)00258-7)

Zhao, T., Zheng, Y., & Wu, Z. (2023). Feature selection-based machine learning modeling for distributed model predictive control of nonlinear processes. *Computers & Chemical Engineering*, *169*, 108074. <https://doi.org/10.1016/j.compchemeng.2022.108074>

Apéndices

Apéndice A.

Ítems metodología PRISMA

Sección	Ítem	Ítem de la lista de verificación
TÍTULO		
Título	1	Identificar la publicación como una revisión sistemática.
RESUMEN		
Resumen estructurado	2	Ver la lista de verificación para resúmenes estructurados de la declaración PRISMA 2020
INTRODUCCIÓN		
Justificación	3	Describir la justificación de la revisión en el contexto del conocimiento existente.
Objetivos	4	Proporcionar una declaración explícita de los objetivos o las preguntas que aborda la revisión.
MÉTODOS		
Criterios de elegibilidad	5	Especificar los criterios de inclusión y exclusión de la revisión y cómo se agruparon los estudios para la síntesis.
Fuentes de información	6	Especificar todas las bases de datos, registros, sitios web, organizaciones, listas de referencias y otros recursos de búsqueda o consulta para identificar los estudios. Especificar la fecha en la que cada recurso se buscó o consultó por última vez.
Estrategia de búsqueda	7	Presentar las estrategias de búsqueda completas de todas las bases de datos, registros y sitios web, incluyendo cualquier filtro y los límites utilizados.
Proceso de selección de los estudios	8	Especificar los métodos utilizados para decidir si un estudio cumple con los criterios de inclusión de la revisión, incluyendo cuántos autores de la revisión cribaron cada registro y cada publicación recuperada, si trabajaron de manera independiente y, si procede, los detalles de las herramientas de automatización utilizadas en el proceso.
Proceso de extracción de los datos	9	Indicar los métodos utilizados para extraer los datos de los informes o publicaciones, incluyendo cuántos revisores recopilaron datos de cada publicación, si trabajaron de manera independiente, los procesos para obtener o confirmar los datos por parte de los investigadores del estudio y, si procede, los detalles de las herramientas de automatización utilizadas en el proceso.
Lista de los datos	10a	Enumerar y definir todos los desenlaces para los que se buscaron los datos. Especificar si se buscaron todos los resultados compatibles con cada dominio del desenlace (por ejemplo, para todas las escalas de medida, puntos

		temporales, análisis) y, de no ser así, los métodos utilizados para decidir los resultados que se debían recoger.
	10b	Enumerar y definir todas las demás variables para las que se buscaron datos (por ejemplo, características de los participantes y de la intervención, fuentes de financiación). Describir todos los supuestos formulados sobre cualquier información ausente (missing) o incierta.
Evaluación del riesgo de sesgo de los estudios individuales	11	Especificar los métodos utilizados para evaluar el riesgo de sesgo de los estudios incluidos, incluyendo detalles de las herramientas utilizadas, cuántos autores de la revisión evaluaron cada estudio y si trabajaron de manera independiente y, si procede, los detalles de las herramientas de automatización utilizadas en el proceso.
Medidas del efecto	12	Especificar, para cada desenlace, las medidas del efecto (por ejemplo, razón de riesgos, diferencia de medias) utilizadas en la síntesis o presentación de los resultados.
Métodos de síntesis	13a	Describir el proceso utilizado para decidir qué estudios eran elegibles para cada síntesis (por ejemplo, tabulando las características de los estudios de intervención y comparándolas con los grupos previstos para cada síntesis [ítem n.º 5]).
	13b	Describir cualquier método requerido para preparar los datos para su presentación o síntesis, tales como el manejo de los datos perdidos en los estadísticos de resumen o las conversiones de datos.
	13c	Describir los métodos utilizados para tabular o presentar visualmente los resultados de los estudios individuales y su síntesis.
	13d	Describir los métodos utilizados para sintetizar los resultados y justificar sus elecciones. Si se ha realizado un metanálisis, describir los modelos, los métodos para identificar la presencia y el alcance de la heterogeneidad estadística, y los programas informáticos utilizados.
	13e	Describir los métodos utilizados para explorar las posibles causas de heterogeneidad entre los resultados de los estudios (por ejemplo, análisis de subgrupos, metarregresión).
	13f	Describir los análisis de sensibilidad que se hayan realizado para evaluar la robustez de los resultados de la síntesis.
Evaluación del sesgo en la publicación	14	Describir los métodos utilizados para evaluar el riesgo de sesgo debido a resultados faltantes en una síntesis (derivados de los sesgos en las publicaciones).
Evaluación de la certeza de la evidencia	15	Describir los métodos utilizados para evaluar la certeza (o confianza) en el cuerpo de la evidencia para cada desenlace.
RESULTADOS		
Selección de los estudios	16a	Describir los resultados de los procesos de búsqueda y selección, desde el número de registros identificados en la

		búsqueda hasta el número de estudios incluidos en la revisión, idealmente utilizando un diagrama de flujo (ver figura 1).
	16b	Citar los estudios que aparentemente cumplían con los criterios de inclusión, pero que fueron excluidos, y explicar por qué fueron excluidos.
Características de los estudios	17	Citar cada estudio incluido y presentar sus características.
Riesgo de sesgo de los estudios individuales	18	Presentar las evaluaciones del riesgo de sesgo para cada uno de los estudios incluidos.
Resultados de los estudios individuales	19	Presentar, para todos los desenlaces y para cada estudio: a) los estadísticos de resumen para cada grupo (si procede) y b) la estimación del efecto y su precisión (por ejemplo, intervalo de credibilidad o de confianza), idealmente utilizando tablas estructuradas o gráficos.
Resultados de la síntesis	20a	Para cada síntesis, resumir brevemente las características y el riesgo de sesgo entre los estudios contribuyentes.
	20b	Presentar los resultados de todas las síntesis estadísticas realizadas. Si se ha realizado un metanálisis, presentar para cada uno de ellos el estimador de resumen y su precisión (por ejemplo, intervalo de credibilidad o de confianza) y las medidas de heterogeneidad estadística. Si se comparan grupos, describir la dirección del efecto.
	20c	Presentar los resultados de todas las investigaciones sobre las posibles causas de heterogeneidad entre los resultados de los estudios.
	20d	Presentar los resultados de todos los análisis de sensibilidad realizados para evaluar la robustez de los resultados sintetizados.
Sesgos en la publicación	21	Presentar las evaluaciones del riesgo de sesgo debido a resultados faltantes (derivados de los sesgos en las publicaciones) para cada síntesis evaluada.
Certeza de la evidencia	22	Presentar las evaluaciones de la certeza (o confianza) en el cuerpo de la evidencia para cada desenlace evaluado.
DISCUSIÓN		
Discusión	23a	Proporcionar una interpretación general de los resultados en el contexto de otras evidencias.
	23b	Argumentar las limitaciones de la evidencia incluida en la revisión.
	23c	Argumentar las limitaciones de los procesos de revisión utilizados.
	23d	Argumentar las implicaciones de los resultados para la práctica, las políticas y las futuras investigaciones.
OTRA INFORMACIÓN		

Registro y protocolo	24a	Proporcionar la información del registro de la revisión, incluyendo el nombre y el número de registro, o declarar que la revisión no ha sido registrada.
	24b	Indicar dónde se puede acceder al protocolo, o declarar que no se ha redactado ningún protocolo.
	24c	Describir y explicar cualquier enmienda a la información proporcionada en el registro o en el protocolo.
Financiación	25	Describir las fuentes de apoyo financiero o no financiero para la revisión y el papel de los financiadores o patrocinadores en la revisión.
Conflicto de intereses	26	Declarar los conflictos de intereses de los autores de la revisión.
Disponibilidad de datos, códigos y otros materiales	27	Especificar qué elementos de los que se indican a continuación están disponibles al público y dónde se pueden encontrar: plantillas de formularios de extracción de datos, datos extraídos de los estudios incluidos, datos utilizados para todos los análisis, código de análisis, cualquier otro material utilizado en la revisión.

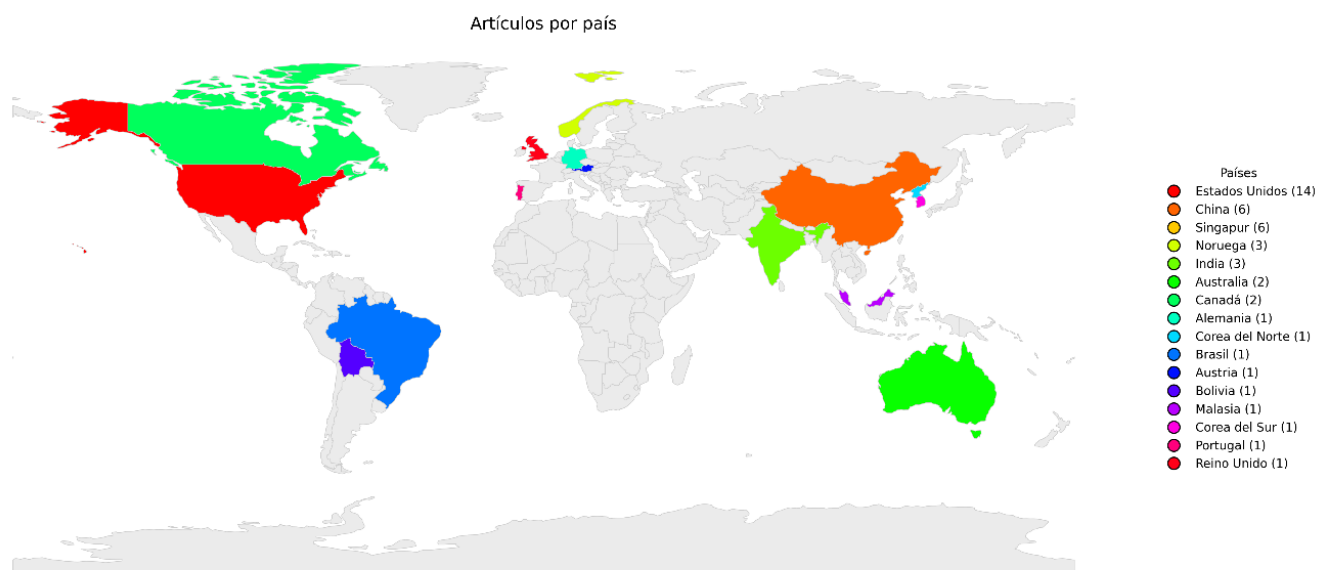
Apéndice B.

Descripción de los Niveles de Madurez Tecnológica (TRL)

Nivel TRL	Descripción
TRL 1	Nivel de madurez más bajo de un proyecto de innovación donde comienza la idea investigación científica básica y se inicia la transición a la investigación o idea aplicada.
TRL 2	La idea o investigación ya se ha aterrizado y los principios científicos están enfocados en áreas específicas de aplicación para definir el concepto.
TRL 3	Actividades de I+D incluyendo pruebas analíticas, pruebas de concepto a escala de laboratorio, orientadas a demostrar la factibilidad técnica de los proyectos de innovación.
TRL 4	Los componentes que integran determinado proyecto de innovación han sido identificados y se busca establecer si dichos componentes individuales cuentan con las capacidades para actuar de manera integrada, funcionando conjuntamente en un sistema.
TRL 5	Los elementos básicos de la innovación son integrados de manera que la configuración final es similar a su aplicación final, es decir que está listo para ser usado en la simulación de un entorno real. Se mejoran los modelos tanto técnicos como económicos del diseño inicial, se ha identificado adicionalmente aspectos de seguridad, limitaciones ambientales y/o regulatorios entre otros.
TRL 6	Se cuenta con prototipos piloto capaces de desarrollar todas las funciones necesarias dentro de un sistema determinado, habiendo superado pruebas de factibilidad en condiciones de operación o funcionamiento real.
TRL 7	El sistema se encuentra o está próximo a operar en escala pre-comercial. Es posible llevar a cabo la fase de identificación de aspectos relacionados con la fabricación, la evaluación del ciclo de vida, y la evaluación económica de las tecnologías, contando con la mayor parte de funciones disponibles para pruebas.
TRL 8	los sistemas están integrados, han sido probados en su forma final y bajo condiciones supuestas, habiendo alcanzado en muchos casos, el final del desarrollo del sistema.
TRL 9	En esta fase la innovación está en su fase final y es operable en un sin número de condiciones operativas, está probada y disponible para su comercialización y/o producción disponible para la sociedad. Entrega de producto o tecnología para producción en serie y comercialización.

Apéndice C.

Mapa de distribución geográfica de los autores de los artículos seleccionados



Apéndice D.

Reinforcement Learning (RL)

Es una estrategia de control basada en datos en la que un agente aprende una ley de decisión a partir de la interacción con el proceso. En cada instante, el agente observa el estado del sistema, aplica una acción de control y recibe una “recompensa” que resume qué tan conveniente fue esa decisión frente a los objetivos del proceso. El propósito del aprendizaje es ajustar progresivamente la ley de control para maximizar la recompensa acumulada. A diferencia del control predictivo basado en modelo, donde la acción de control se obtiene resolviendo en línea un problema de optimización, en RL se busca aprender una relación directa entre estado y acción, lo que puede reducir la carga computacional una vez entrenado el controlador (Khodaverdian et al., 2026; Park et al., 2026).

Desde el punto de vista teórico, muchos problemas de RL se representan como un proceso de decisión de Markov (MDP), definido por estados, acciones, recompensas, dinámica de transición y factor de descuento. En control de procesos, los estados corresponden a variables medidas o estimadas, las acciones a variables manipuladas, y la recompensa a una medida de desempeño asociada con estabilidad, seguimiento de referencia o economía. Para aproximar la ley de control óptima, el agente emplea funciones de valor, que cuantifican el retorno acumulado esperado a largo plazo. En este marco, métodos *on-policy* actualizan la ley de control usando datos generados por la misma ley que se está entrenando; mientras que métodos *off-policy* permiten aprender a partir de datos obtenidos con otra ley de control o con registros históricos de operación. Esta última característica ha favorecido el desarrollo del offline RL, especialmente relevante en ingeniería química porque reduce la necesidad de exploración riesgosa sobre la planta real (Khodaverdian et al., 2026; Park et al., 2026).

La principal dificultad de RL en procesos químicos es precisamente la exploración segura. En sistemas industriales, probar acciones poco convenientes puede afectar la calidad del producto, aumentar costos o comprometer la operación. Por eso, una parte importante del desarrollo reciente se ha orientado a métodos que incorporan restricciones, estabilidad y entrenamiento previo fuera de línea. Un ejemplo es el trabajo de Khodaverdian *et al.*, (2026), quienes proponen un marco en el que un controlador RL busca reemplazar al MPC cuando este resulta demasiado costoso computacionalmente. Para evitar pérdida de estabilidad, la acción del agente se verifica mediante una restricción basada en Lyapunov; si no satisface la condición requerida, se recurre a un controlador de respaldo de tipo LMPC. De esta manera, el enfoque combina la flexibilidad de RL con garantías explícitas de estabilidad en lazo cerrado. Los autores demuestran la viabilidad del método en un proceso químico no lineal de referencia y muestran que el controlador RL puede mantener buen desempeño con menor carga computacional que un MPC de horizonte largo.

Otra aplicación es la reportada por Park *et al.*, (2026) para una columna industrial de pared divisoria (DWC) en una planta petroquímica real. En ese sistema, el control convencional basado en un lazo en cascada tipo PID y la intervención manual resultaban insuficientes frente a perturbaciones, tiempos muertos y no linealidades; para enfrentar este problema, los autores formularon el control como un MDP y desarrollaron un esquema de *offline* RL en el que un agente fue preentrenado con datos históricos de operación. Los resultados mostraron control estable de temperatura y una razón de automatización de 93.11 %, lo que constituye una demostración sólida de la viabilidad práctica de RL en control de procesos químicos industriales.

Apéndice E.

Formulación de reglas difusas para el modelo de Takagi-Sugeno.

Un modelo difuso Takagi-Sugeno (TS) se basa en reglas difusas; es decir, enunciados lingüísticos condicionales del tipo si-entonces (*IF-THEN*) que integran conjuntos, lógica e inferencia difusos. Estas reglas desempeñan un papel fundamental en la representación del conocimiento y la experiencia del experto, además de establecer la relación entre las variables de entrada y las variables de salida del modelo difuso. La regla general del modelo Takagi-Sugeno según J. Li *et al.*, (2024) está dada por:

Regla i : SI $\xi_1(k)$ es M_{i1} , ... y $\xi_p(k)$ es M_{ip} , ENTONCES

$$\begin{cases} x(k+1) = A_i x(k) + B_i u(k) + F_i f(k) + D_{xi} d(k), \\ y(k) = C x(k) + D_f f(k) + D_y d(k), \quad i = 1, 2, \dots, z, \end{cases}$$

Donde, $\xi_1(k), \dots, \xi_p(k)$ son las variables de premisa medibles que describen la condición de operación del sistema en el instante k , mientras que M_{i1}, \dots, M_{ip} son los conjuntos difusos asociados a la regla i ; es decir, las etiquetas lingüísticas que determinan cuándo esa regla se activa. El término $x(k)$ representa el vector de estado del sistema y $x(k+1)$ su valor en el siguiente instante de muestreo; $u(k)$ es la entrada de control; $f(k)$ es la señal de falla; $d(k)$ es la perturbación; y $y(k)$ es la salida medida. Por su parte, A_i, B_i, F_i y D_{xi} son las matrices del modelo local lineal asociado a la regla i , que describen, respectivamente, la dinámica del estado, el efecto de la entrada, la influencia de la falla y el efecto de la perturbación sobre el estado. Además, C es la matriz de salida, y D_f y D_y relacionan la falla y la perturbación con la salida medida. Finalmente, $i = 1, 2, \dots, z$ indica que el sistema está descrito por un conjunto de z reglas difusas, cada una válida en una región de operación específica, cuya combinación permite representar la dinámica global del sistema no lineal.