

Integración de control predictivo multivariable, control estadístico de procesos y redes neuronales artificiales para la detección y gestión de cambios estructurales en procesos industriales MIMO

Integration of Multivariable Model Predictive Control, Statistical Process Control, and Artificial Neural Networks for the Detection and Management of Structural Changes in Industrial MIMO Processes

Carlos Ivan Prado Gardini 

Facultad de Ingeniería, Universidad Tecnológica del Perú, Av. Petit Thouars 116, Lima 15046. Lima, Perú.

* Autor correspondiente: gestionpyg@gmail.com (C. Prado)

DOI: [10.17268/scien.inge.2026.02.04](https://doi.org/10.17268/scien.inge.2026.02.04)

RESUMEN

La presente investigación aborda la detección y supervisión de cambios estructurales en procesos industriales multivariables MIMO mediante una arquitectura integrada que combina control predictivo multivariable, control estadístico de procesos y redes neuronales artificiales. El objetivo es mejorar la discriminación operativa entre perturbaciones externas, condiciones operativas esperadas y cambios estructurales internos del proceso, preservando un desempeño adecuado de regulación en lazo cerrado. La metodología se basa en simulaciones controladas y reproducibles de un proceso MIMO bajo escenarios sistemáticamente diseñados, que incluyen perturbaciones escalonadas, activación de restricciones operativas y derivas internas de parámetros. El control predictivo multivariable actúa como mecanismo de regulación, mientras que el control estadístico de procesos supervisa la estabilidad estadística mediante indicadores multivariables aplicados a residuos del modelo. Las redes neuronales artificiales se emplean como modelos de referencia no lineales con fines de consistencia estructural, sin intervenir directamente en la acción de control. Los resultados evidencian que la arquitectura MPC+ANN+MSPC redujo la ocupación de alarma post evento de 0,9834 a 0,1492 en el escenario S5, manteniendo valores comparables de RMSE, MAE y esfuerzo de control respecto al MSPC lineal. Se concluye que la integración propuesta es una herramienta robusta y viable para la supervisión avanzada de procesos industriales MIMO.

Palabras clave: control predictivo multivariable; control estadístico de procesos; redes neuronales artificiales; procesos MIMO; supervisión de procesos.

ABSTRACT

This research addresses the detection and monitoring of structural changes in multivariable MIMO industrial processes through an integrated architecture that combines multivariable model predictive control, statistical process control, and artificial neural networks. The objective is to improve operational discrimination among external disturbances, expected operating conditions, and internal structural changes in the process, while preserving adequate closed-loop regulation performance. The methodology is based on controlled and reproducible simulations of a MIMO process under systematically designed scenarios, including step disturbances, activation of operational constraints, and internal parameter drifts. Multivariable model predictive control acts as the regulation mechanism, whereas statistical process control supervises statistical stability through multivariate indicators applied to model residuals. Artificial neural networks are employed as nonlinear reference models for structural consistency assessment, without directly intervening in the control action. The results show that the MPC+ANN+MSPC architecture reduced the post-event alarm occupancy from 0.9834 to 0.1492 in Scenario S5, while maintaining RMSE, MAE, and control effort values comparable to those of the linear MSPC scheme. It is concluded that the proposed integration is a robust and viable tool for advanced supervision of MIMO industrial processes.

Keywords: multivariable model predictive control; statistical process control; artificial neural networks; MIMO processes; process supervision.



1. INTRODUCCIÓN

Los procesos industriales modernos se caracterizan por una creciente complejidad dinámica, una alta interacción entre variables y una operación bajo condiciones cambiantes de carga, calidad de materia prima y restricciones operativas. En sectores como la industria química, petroquímica, energética, agroindustrial y de manufactura avanzada, estos procesos suelen modelarse como sistemas multivariantes de múltiples entradas y múltiples salidas (Multiple-Input Multiple-Output, MIMO), en los cuales pequeñas desviaciones pueden propagarse rápidamente a través del sistema, generando pérdidas económicas, degradación de la calidad del producto o riesgos operativos significativos (Schwenzer et al., 2021).

La literatura reciente destaca que este nivel de complejidad dinámica y acoplamiento multivariable limita severamente la efectividad de estrategias de control convencionales, especialmente cuando los procesos operan cerca de sus límites físicos y económicos. En este contexto, el Control Predictivo Basado en Modelo (Model Predictive Control, MPC) se ha consolidado como una de las estrategias de control avanzado más empleadas a nivel industrial, debido a su capacidad para anticipar el comportamiento futuro del proceso, manejar restricciones explícitas y coordinar de forma óptima múltiples variables manipuladas en sistemas multivariantes complejos (Hernandez et al., 2024; Rivero-Contreras et al., 2025; Schwenzer et al., 2021).

Asimismo, investigaciones recientes evidencian una evolución progresiva del MPC hacia arquitecturas más avanzadas e híbridas, en las que se incorporan modelos no lineales y técnicas de aprendizaje automático con el objetivo de mejorar la robustez, la adaptabilidad y el desempeño del control bajo condiciones operativas altamente variables y estructuralmente complejas (Huang et al., 2023).

La literatura reciente respalda de manera consistente al Control Predictivo Basado en Modelo (Model Predictive Control, MPC) como una de las estrategias más robustas para la gestión de procesos industriales multivariantes con restricciones explícitas y elevada complejidad dinámica. Diversos estudios de revisión y aplicaciones industriales han validado su capacidad para optimizar simultáneamente el desempeño dinámico del proceso y el cumplimiento de restricciones operativas, consolidando su adopción en sectores como energía, petróleo y gas, procesos químicos complejos y procesos industriales de gran escala (Schwenzer et al., 2021; Castelletti et al., 2023; Yu & Long, 2024).

Estos trabajos evidencian que el MPC puede ofrecer un equilibrio favorable entre calidad de control y eficiencia computacional, incluso en escenarios caracterizados por una fuerte interacción multivariable y regímenes operativos exigentes. No obstante, la literatura también coincide en señalar que el desempeño del MPC depende de manera crítica de la fidelidad del modelo interno utilizado para la predicción y de su adecuada correspondencia con la dinámica real del proceso (Schwenzer et al., 2021; Jung et al., 2023). En este contexto, diversos autores advierten que, si bien el MPC puede mantener un seguimiento adecuado de las referencias y una operación estable en lazo cerrado, su acción regulatoria puede ocultar degradaciones estructurales progresivas del proceso, tales como desajustes planta–modelo, variaciones paramétricas lentas, degradación de actuadores o dinámicas internas no modeladas (Fiedler et al., 2023).

En procesos industriales MIMO, un controlador MPC puede mantener un desempeño regulatorio aceptable sin evidenciar cambios estructurales internos no observables, como desajustes planta–modelo, deriva paramétrica, deterioro de actuadores, envejecimiento de sensores o dinámicas no modeladas. Esto dificulta distinguir entre perturbaciones operativas compensables y modificaciones persistentes de la estructura dinámica del proceso.

La brecha principal radica en la limitada disponibilidad de esquemas integrados que combinen control predictivo multivariable, control estadístico multivariante y modelos neuronales no lineales para detectar, diagnosticar y gestionar tempranamente dichos cambios en procesos acoplados. Esta limitación evidencia una insuficiente articulación entre regulación, monitoreo y diagnóstico estructural, especialmente relevante en sectores industriales peruanos como minería, energía, agua, cemento y agroindustria, donde predominan alta complejidad dinámica, variabilidad operativa y crecientes necesidades de digitalización.

Con el fin de complementar los esquemas de control, el Control Estadístico de Procesos (Statistical Process Control, SPC), particularmente en su formulación multivariante (Multivariate Statistical Process Control, MSPC), se ha consolidado como una metodología robusta para la supervisión de la estabilidad estadística de procesos industriales complejos mediante técnicas estadísticas avanzadas. Herramientas clásicas como el estadístico T2 de Hotelling, el error cuadrático de predicción (Squared Prediction Error, SPE) y el Análisis de Componentes Principales (Principal Component Analysis, PCA) permiten detectar desviaciones respecto a un comportamiento nominal a partir de datos históricos, mediante la reducción de la dimensionalidad y el análisis de las correlaciones entre variables del proceso. La literatura reciente respalda ampliamente esta aproximación. En particular, se ha reportado que el estadístico T2 de Hotelling constituye el indicador MSPC más utilizado en aplicaciones industriales, evidenciando su relevancia práctica y su capacidad para integrar múlti-

ples variables en un único índice de supervisión (Ueda & Souza, 2022). Asimismo, el PCA ha demostrado ser altamente eficaz para representar sistemas multivariantes en espacios de menor dimensión, facilitando un monitoreo más preciso y eficiente del proceso al preservar la estructura de correlación dominante (Vega et al., 2022). De forma complementaria, se han propuesto extensiones avanzadas del MSPC, como el PCA direccional, las cuales mejoran significativamente las capacidades diagnósticas del sistema de supervisión, acelerando la detección de fallos y permitiendo una identificación más precisa de las variables responsables de las desviaciones observadas (Li et al., 2021).

Sin embargo, los enfoques clásicos de supervisión de procesos basados en control estadístico multivariable presentan limitaciones estructurales cuando se enfrentan a dinámicas no lineales, acoplamientos fuertes entre variables y cambios persistentes en el comportamiento del proceso. Estudios recientes en monitoreo de procesos industriales señalan que los métodos estadísticos tradicionales, aun en sus variantes multivariantes, tienden a perder sensibilidad ante dinámicas complejas y no estacionarias, lo que dificulta la discriminación entre perturbaciones externas transitorias y cambios estructurales internos del sistema (Melo et al., 2024).

Estas limitaciones han motivado el uso de modelos alternativos capaces de representar explícitamente la no linealidad y la dinámica del proceso. En particular, las redes neuronales artificiales han demostrado una elevada capacidad para modelar procesos industriales complejos, capturando relaciones dinámicas y no lineales que no son fácilmente representables mediante modelos lineales o basados en primeros principios. Su aplicación ha sido ampliamente documentada en tareas de detección y diagnóstico de fallos, predicción y modelado dinámico, tanto en procesos benchmark como en aplicaciones industriales reales (Cavalcanti et al., 2021; Wang et al., 2022; Zheng et al., 2022).

Además de las redes neuronales artificiales, la literatura reporta alternativas para el modelado no lineal, la supervisión estructural y la detección de fallas en procesos MIMO, tales como SVM/SVR, procesos gaussianos, bosques aleatorios, modelos neurodifusos, DPCA, Kernel PCA y arquitecturas LSTM. Estas técnicas ofrecen capacidades complementarias en aproximación no lineal, clasificación de anomalías, tratamiento de incertidumbre, análisis temporal e interpretación de patrones dinámicos. No obstante, en este estudio se seleccionan las RNA por su equilibrio entre capacidad de aproximación no lineal, compatibilidad con esquemas MPC–MSPC, implementación fuera de línea e integración no intrusiva en el lazo de control. Por tanto, la RNA no se asume como una alternativa universalmente superior, sino como una opción metodológicamente adecuada para la supervisión estructural temprana en procesos industriales MIMO.

No obstante, la literatura especializada también advierte que la incorporación directa de modelos neuronales profundos en esquemas de control o supervisión puede introducir desafíos relevantes asociados a la interpretabilidad, la estabilidad en lazo cerrado y la aceptación industrial. En particular, trabajos recientes destacan la necesidad de evaluar cuidadosamente la integración de modelos neuronales dentro de arquitecturas de control predictivo, con el fin de garantizar estabilidad, trazabilidad y desempeño consistente del sistema bajo condiciones operativas variables (Ren et al., 2022). Estas consideraciones refuerzan la conveniencia de enfoques híbridos que combinen la robustez de los métodos estadísticos con la capacidad de representación no lineal de las redes neuronales.

A pesar de estos avances, persiste un vacío científico relevante: la ausencia de una arquitectura integrada, metodológicamente controlada y experimentalmente validada que permita distinguir de forma consistente perturbaciones externas de cambios estructurales internos en sistemas MIMO, sin comprometer el desempeño de la regulación automática ni introducir complejidad innecesaria en el lazo de control. En particular, se identifica una carencia de enfoques que utilicen redes neuronales artificiales como modelos de referencia no lineales con fines de supervisión estructural, integradas de forma no intrusiva junto con MPC y MSPC, y evaluadas mediante métricas cuantitativas,

reproducibles y alineadas con la práctica industrial. En respuesta a esta problemática, el presente estudio propone y evalúa una arquitectura integrada para la detección y gestión de cambios estructurales en procesos industriales MIMO, combinando control predictivo multivariable, control estadístico de procesos y redes neuronales artificiales. El objetivo principal es demostrar que dicha integración permite discriminar perturbaciones externas de cambios estructurales internos, mejorar la detección temprana de desviaciones severas y reducir la tasa de falsas alarmas, sin afectar significativamente el desempeño de regulación ni incrementar el esfuerzo de control. La contribución fundamental radica en el uso de ANN como modelos de referencia no lineales para la evaluación de consistencia estructural, validados mediante un diseño experimental controlado y reproducible, utilizando métricas coherentes con la literatura científica y con las exigencias del entorno industrial.

2. METODOLOGÍA

2.1 Objeto de estudio

El objeto de estudio de la presente investigación es la detección y gestión de cambios estructurales internos en procesos industriales multivariables acoplados, modelados como sistemas de múltiples entradas y múltiples salidas (MIMO), que operan bajo condiciones dinámicas y restricciones operativas. El interés central no radica únicamente en la identificación de desviaciones estadísticas, sino en el análisis causal de alteraciones persistentes en la relación dinámica entrada-salida que define el comportamiento nominal del proceso. En este contexto, el estudio se orienta a evaluar el desempeño de una arquitectura integrada de control y supervisión, compuesta por Control Predictivo Basado en Modelo (MPC), Control Estadístico de Procesos Multivariado (MSPC) y Redes Neuronales Artificiales (ANN), con el objetivo de discriminar perturbaciones externas y condiciones operativas esperadas de cambios estructurales internos del proceso, preservando simultáneamente un desempeño adecuado de regulación en lazo cerrado.

El análisis experimental se desarrolla sobre el Shell Heavy Oil Fractionator (SHOF), un benchmark industrial MIMO ampliamente utilizado en la literatura especializada en control predictivo multivariable para la evaluación de estrategias avanzadas de control, supervisión y optimización. El SHOF representa un proceso dinámico acoplado de tres variables manipuladas y tres variables controladas, caracterizado por interacciones cruzadas, retardos de transporte y restricciones operativas, constituyendo un entorno de prueba representativo de procesos industriales reales de gran escala. Dicho benchmark se emplea exclusivamente como planta de simulación, permitiendo la generación controlada de escenarios nominales y no nominales bajo condiciones completamente reproducibles, sin constituir en sí mismo el objeto de estudio de la investigación.

2.1 Enfoque metodológico y diseño experimental

La investigación adopta un enfoque cuantitativo, experimental y reproducible, basado en simulaciones controladas del benchmark SHOF. Se implementa un diseño experimental sistemático, en el cual se definen escenarios operativos mutuamente excluyentes, permitiendo evaluar de manera aislada y comparativa el comportamiento de cada componente de la arquitectura propuesta frente a perturbaciones externas y cambios estructurales internos.

Todos los experimentos se ejecutan bajo condiciones estrictamente reproducibles, empleando semillas aleatorias fijas, parámetros explícitamente documentados y condiciones iniciales idénticas, lo que garantiza la trazabilidad, repetibilidad y verificabilidad de los resultados por parte de investigadores independientes.

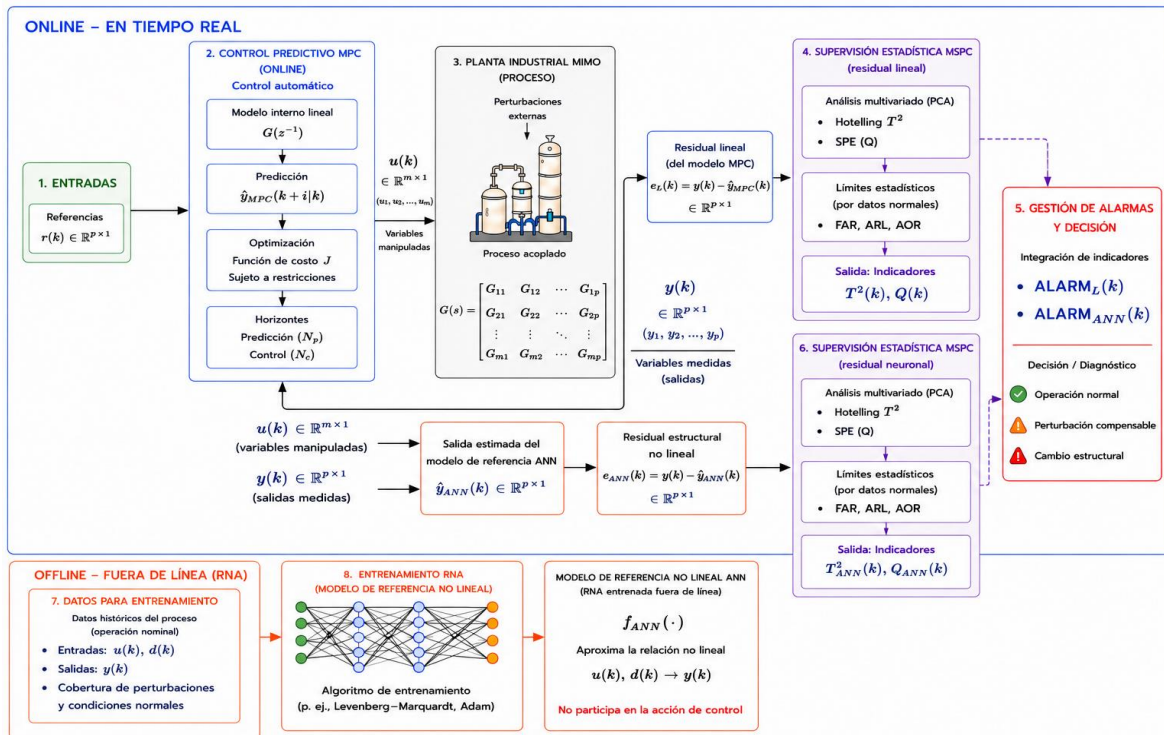


Figura 1. Arquitectura integrada MPC+MSPC+ANN propuesta para supervisión estructural de procesos industriales MIMO.

2.2 Control predictivo multivariable (MPC)

La regulación del proceso se implementa mediante Control Predictivo Basado en Modelo (MPC), el cual actúa como mecanismo principal de control en lazo cerrado en todos los escenarios evaluados. El MPC se diseña a partir de un modelo lineal nominal discreto del SHOF, incorporando explícitamente restricciones sobre las variables manipuladas y sus tasas de variación, en concordancia con prácticas industriales reales.

Los horizontes de predicción y control, así como los pesos asociados a las variables de salida y a las acciones de control, se mantienen constantes a lo largo de todos los experimentos, asegurando la comparabilidad directa entre escenarios y arquitecturas de supervisión. El MPC permanece activo durante toda la simulación, reproduciendo condiciones realistas de operación industrial en las que la regulación del proceso se encuentra permanentemente en funcionamiento.

2.3 Supervisión estadística multivariada (MSPC)

La supervisión estadística del proceso se implementa mediante Control Estadístico de Procesos Multivariado (MSPC), utilizando técnicas de Análisis de Componentes Principales (PCA). El modelo MSPC se calibra exclusivamente bajo condiciones nominales estacionarias, empleando como variables de entrada los residuos del modelo predictivo lineal del MPC, lo que permite desacoplar el desempeño de control de la detección estadística.

A partir de esta calibración se obtienen los estadísticos multivariantes Hotelling T^2 y Squared Prediction Error (SPE), junto con sus respectivos límites de control definidos para un nivel de confianza estadística fijo. Una vez concluida la calibración, el esquema MSPC se mantiene estrictamente invariante y se aplica sin recalibración en todos los escenarios no nominales, permitiendo evaluar de manera objetiva su capacidad intrínseca de detección frente a perturbaciones externas y cambios estructurales internos, sin introducir sesgos adaptativos.

2.4 Modelo neuronal artificial como referencia no lineal

Las redes neuronales artificiales (ANN) se emplean como modelos de referencia no lineales, con fines exclusivos de supervisión estructural. La ANN se entrena previamente en modalidad fuera de línea, utilizando datos generados bajo condiciones nominales y perturbadas, y permanece fija durante la ejecución de todos los experimentos.

La ANN no interviene en el lazo de control, evitando problemas asociados a estabilidad, interpretabilidad y ajuste en línea. La supervisión basada en ANN se realiza mediante el análisis del error de predicción, el cual se somete a un esquema MSPC independiente, permitiendo detectar desviaciones estructurales persistentes no capturadas por el modelo lineal nominal del MPC.

2.5 Escenarios experimentales

En la Tabla 1 se definen múltiples escenarios experimentales reproducibles, diseñados para representar situaciones relevantes en entornos industriales. Cada escenario se caracteriza por un instante de ocurrencia claramente definido, permitiendo una evaluación objetiva del tiempo de detección y del comportamiento post-evento de los sistemas de supervisión.

Tabla 1: Escenarios de simulación considerados y su interpretación operativa.

Escenario	Perturbación / evento aplicado	Interpretación operativa	Naturaleza de la desviación
S0_NOMINAL	Sin cambios; operación nominal (in-control)	Régimen nominal de referencia para calibración y comparación	Variabilidad estadística mínima (sin cambio estructural)
S2_10	Sesgo aditivo en MV: +10 % en u_1 a partir de k_0	Perturbación manipulada / desviación en actuador o señal de mando	Desviación operativa inducida en u (sin cambio estructural)
S2_20	Sesgo aditivo en MV: +20 % en u_1 a partir de k_0	Perturbación manipulada de mayor severidad (condición más exigente)	Desviación operativa inducida en u (sin cambio estructural)

Escenario	Perturbación / evento aplicado	Interpretación operativa	Naturaleza de la desviación
S4	Referencia agresiva: +20 % en r para activar restricciones	Operación restringida por límites de actuadores (régimen saturado)	Desviación operativa con restricciones activas (sin cambio estructural)
S5	Deriva interna de ganancia en planta: +30 % post k_0	Cambio estructural interno (alteración persistente de la relación entrada–salida)	Cambio estructural interno (inconsistencia modelo–planta)

2.6 Métricas de evaluación

El desempeño de las arquitecturas evaluadas se cuantifica mediante métricas ampliamente aceptadas en la literatura y se muestran en la Tabla 2. Para la supervisión estadística se emplean indicadores como el Average Run Length (ARL), la tasa de falsas alarmas (FAR) y la ocupación de alarma post-evento. El desempeño de control se evalúa mediante métricas de error de seguimiento (RMSE y MAE) y mediante indicadores de esfuerzo de control basados en la energía de las variaciones de las acciones manipuladas.

Estas métricas permiten una evaluación objetiva, trazable y reproducible del compromiso entre desempeño de regulación y capacidad de supervisión estructural.

Tabla 2. Métricas empleadas para la evaluación del desempeño de control y supervisión estadística

Métrica	Dominio	Definición	Base de cálculo	Escenarios
ARL ₁	Supervisión	Longitud media de corrida desde la ocurrencia de un evento hasta su detección sostenida	Número esperado de muestras entre el instante del evento k_0 y el primer instante k_d en que el estadístico MSPC excede el límite de control durante L muestras consecutivas.	S2–S5
FAR _{pre}	Supervisión	Tasa de falsas alarmas bajo operación nominal previa al evento.	Fracción de muestras previas al evento en las que el estadístico MSPC excede el límite de control sin presencia de cambio estructural.	S0, S1
AOR _{post}	Supervisión	Ocupación temporal del estado de alarma posterior al evento.	Proporción de muestras posteriores al evento en las que el estadístico MSPC permanece por encima del límite de control.	S2–S5
RMSE	Control	Error cuadrático medio de seguimiento.	Raíz del promedio del error cuadrático entre la salida del proceso y la referencia.	Todos
MAE	Control	Error absoluto medio de seguimiento	Promedio del valor absoluto del error entre la salida del proceso y la referencia	Todos
$J_{\Delta u}$	Control	Índice de esfuerzo de control.	Suma de la energía de las variaciones sucesivas de las acciones manipuladas	Todos

3. RESULTADOS Y DISCUSIÓN

Los resultados obtenidos muestran que las arquitecturas evaluadas mantienen un desempeño de control comparable bajo todos los escenarios considerados. En particular, los indicadores globales de error de seguimiento (RMSE y MAE) y el esfuerzo de control asociado a la variación de las variables manipuladas $J_{\Delta u}$ presentan valores comparables dentro del margen operativo observado entre el esquema MPC convencional (no mostrado por brevedad), el esquema MPC con supervisión estadística (MPC+MSPC) y la arquitectura inte-

grada MPC+ANN+MSPC. Este comportamiento consistente se observa tanto en escenarios de perturbación escalonada como en condiciones de operación forzada con activación de restricciones, lo que evidencia que la incorporación de mecanismos adicionales de supervisión no degrada el desempeño de regulación ni introduce penalizaciones significativas en la acción de control.

Tabla 3. Comparación integrada del desempeño regulatorio y la capacidad de supervisión estructural bajo distintos escenarios operativos en un sistema MIMO

Escenario	Arquitectura	RMSE_all	MAE_all	$J\Delta u$	ARL1	FAR_pre	AOR_post
S2_10	MPC+MSPC_L	0,0309	0,0233	1,5484	2	0,0167	0,9890
S2_10	MPC+ANN+MSPC_ANN	0,0309	0,0233	1,5484	NDS	0,0333	0,0276
S2_20	MPC+MSPC_L	0,0562	0,0401	1,5773	1	0,0167	0,9945
S2_20	MPC+ANN+MSPC_ANN	0,0562	0,0401	1,5773	NDS	NDS	0,0608
S4	MPC+MSPC_L	0,0257	0,0157	5,1784	NDS	0,0167	0,0055
S4	MPC+ANN+MSPC_ANN	0,0257	0,0157	5,1784	NDS	0,0333	0,0331
S5	MPC+MSPC_L	0,0213	0,0165	1,9089	3	0,0167	0,9834
S5	MPC+ANN+MSPC_ANN	0,0213	0,0165	1,9089	NDS	0,0333	0,1492

Nota: Valores menores son deseables para RMSE, MAE, FAR_pre, AOR_post y $J\Delta u$. Un menor ARL₁ indica una detección sostenida más rápida cuando está definida. NDS (No Detection Sustained) indica ausencia de detección sostenida bajo el criterio L=3 consistente con escenarios sin cambio estructural interno.

En consecuencia, los resultados confirman que la arquitectura propuesta preserva las propiedades fundamentales del MPC como regulador multivariable, condición indispensable para su viabilidad en aplicaciones industriales reales. Las siguientes tablas resumen simultáneamente el desempeño de control y la capacidad de supervisión estructural, permitiendo distinguir entre variabilidad operativa esperada y cambios estructurales internos del proceso.

Aunque el desempeño de control se mantiene comparable entre arquitecturas, las diferencias emergen con claridad en los indicadores de supervisión estadística, como se resume en la Tabla 3. En los escenarios de perturbación escalonada aplicadas a las variables manipuladas (S2_10 y S2_20), el esquema basado en MSPC sobre el residual lineal del modelo nominal (MSPC_L) exhibe una detección sostenida rápida (ARL₁ bajo), pero acompañada de una ocupación de alarma post-evento cercana a la unidad (AOR_post $\approx$ 1), lo que evidencia una alta sensibilidad con baja selectividad. En contraste, la supervisión basada en el error de predicción neuronal (MSPC_ANN) reduce de manera sustancial la ocupación de alarma post-evento (AOR_post bajo a moderado) y limita la longitud de rachas consecutivas de alarma, sugiriendo un comportamiento más selectivo y menos propenso a generar fatiga de alarmas. Este contraste es coherente con la naturaleza de las señales supervisadas: mientras el residual lineal e_L cuantifica desviaciones respecto al modelo lineal nominal y puede amplificar transitorios compensables por el controlador, el error neuronal e_{ANN} actúa como un indicador de consistencia estructural no lineal, permitiendo discriminar de forma más efectiva entre perturbaciones operativas y desviaciones persistentes del comportamiento aprendido del proceso.

Un resultado particularmente relevante se observa en el escenario S4, diseñado para representar una condición operativa exigente pero esperada, en la cual el proceso es forzado mediante un cambio agresivo de referencia que activa restricciones en las variables manipuladas, como se resume en la Tabla 1. En este escenario, ambas arquitecturas —MPC+MSPC_L y MPC+ANN+MSPC_ANN— mantienen un desempeño de control estable, con errores de seguimiento y esfuerzo de control comparables, confirmando la capacidad del MPC para gestionar restricciones explícitas sin pérdida significativa de regulación. Desde la perspectiva de supervisión, ninguno de los esquemas presenta detección sostenida de cambios estructurales (ARL₁ no definido), y las tasas de ocupación de alarma post-evento permanecen bajas, lo que indica una adecuada discriminación entre una condición operativa exigente y una falla estructural interna. Este resultado es particularmente relevante desde el punto de vista industrial, ya que demuestra que la arquitectura integrada no confunde la activación de restricciones—un comportamiento inherente al diseño del MPC— con degradaciones estructurales del proceso, evitando así la generación de falsas alarmas en situaciones de operación normal, pero extrema. En consecuencia, el escenario S4 valida la robustez semántica del esquema de supervisión propuesto, al preservar la coherencia entre la lógica de control y la interpretación estadística de las señales de monitoreo.

Tabla 4. Respuesta de los esquemas de supervisión ante un escenario operativo exigente sin modificación estructural interna

Arquitectura	ARL ₁	FAR _{pre}	AOR _{post}	Rachas (máx.)	Interpretación
MPC + MSPC_L	NDS	0,0167	0,0055	1	Operación exigente

Arquitectura	ARL ₁	FAR _{pre}	AOR _{post}	Rachas (máx.)	Interpretación
MPC + ANN + MSPC _{ANN}	NDS	0,0333	0,0331	6	Operación exigente

Nota: ARL₁ no definido (NDS) indica ausencia de detección sostenida bajo el criterio L=3, coherente con un escenario de operación exigente sin pérdida de causalidad entrada-salida. FAR_{pre} corresponde a la tasa de falsas alarmas previa al evento. AOR_{post} representa la ocupación de alarma posterior al evento. *Rachas (máx.)* Indica máxima longitud de secuencias consecutivas de alarma tras la activación de restricciones

Con el fin de evaluar la sanidad estadística del esquema de supervisión propuesto, se analizaron métricas pre-evento y post-evento orientadas a verificar la ausencia de alarmas espurias y la correcta interpretación de las condiciones operativas normales. Los resultados, resumidos en la Tabla 5, muestran que tanto el esquema MPC+MSPC como la arquitectura integrada MPC+ANN+MSPC_{ANN} presentan tasas de falsas alarmas pre-evento reducidas (FAR_{pre} < 0,05) y ausencia de alarmas anticipadas (preAlarm = 0) en todos los escenarios evaluados. Asimismo, los valores acotados de rachas máximas consecutivas post-evento confirman que la activación de alarmas no responde a saturaciones estadísticas ni a ruido persistente, sino a condiciones dinámicas coherentes con los eventos introducidos en cada escenario.

Tabla 5. Evaluación de la sanidad estadística y persistencia de alarmas del esquema de supervisión bajo escenarios operativos y cambios estructurales.

Arquitectura	Escenario	FAR _{pre}	PreAlarm	maxRun _{post}
MPC + MSPC _L	S4	0,0167	0	1
MPC + ANN + MSPC _{ANN}	S4	0,0333	0	2
MPC + MSPC _L	S5	0,0167	0	178
MPC + ANN + MSPC _{ANN}	S5	0,0333	0	2

Nota: FAR_{pre} corresponde a la tasa de falsas alarmas previa al evento. PreAlarm indica la presencia de alarmas anticipadas antes del instante de ocurrencia del evento. maxRun_{post} representa la máxima longitud de rachas consecutivas de alarma tras el evento, utilizada como indicador de persistencia y potencial fatiga de alarmas.

En conjunto, estos resultados evidencian que la arquitectura propuesta mantiene una supervisión estadísticamente sana, evitando la confusión entre variabilidad operacional esperada y cambios estructurales reales del proceso.

Los resultados obtenidos concuerdan con estudios recientes que documentan las limitaciones de los enfoques convencionales de MSPC frente a dinámicas no lineales y a condiciones operativas no estacionarias en procesos industriales complejos (Melo et al., 2024). En particular, la reducción observada en la ocupación de alarmas tras eventos y la mayor capacidad para discriminar entre perturbaciones operativas transitorias y cambios estructurales persistentes son compatibles con comportamientos reportados en arquitecturas híbridas basadas en aprendizaje supervisado. De forma análoga, los hallazgos muestran afinidad conceptual con los enfoques LSTM-MPC descritos por Huang et al. (2023), donde la incorporación de modelos no lineales mejora la representación dinámica del proceso; no obstante, en el presente trabajo la red neuronal se emplea exclusivamente como referencia estructural en modo fuera de línea, evitando su inserción directa en el lazo de control. Complementariamente, los resultados respaldan las recomendaciones metodológicas de Ren et al. (2022), que abogan por la integración de modelos neuronales en arquitecturas de supervisión y control preservando criterios de estabilidad, interpretabilidad y viabilidad operativa industrial.

4. CONCLUSIONES

La presente investigación confirma que la integración no intrusiva de control predictivo multivariable, control estadístico de procesos y redes neuronales artificiales constituye una arquitectura eficaz y metodológicamente consistente para la detección y gestión de cambios estructurales en procesos industriales MIMO. La arquitectura propuesta permite discriminar de forma confiable entre perturbaciones externas operativas y modificaciones internas persistentes del proceso, sin comprometer el desempeño de regulación en lazo cerrado.

Los resultados obtenidos mediante simulaciones controladas y reproducibles demuestran que el control predictivo multivariable mantiene un comportamiento regulatorio adecuado incluso bajo escenarios exigentes con activación de restricciones. Asimismo, la incorporación de redes neuronales artificiales como modelos de referencia no lineales aporta evidencia complementaria de inconsistencias estructurales no capturadas por el modelo nominal, reduciendo la ocupación y persistencia de alarmas y evitando la confusión entre saturaciones operativas esperadas y fallas estructurales reales, sin introducir complejidad adicional en el lazo de control.

La evaluación cuantitativa mediante métricas de desempeño de control y supervisión valida que la arquitectura integrada mejora la detección temprana de cambios estructurales severos y refuerza la robustez global del esquema de supervisión. Además, mantiene niveles comparables de error de seguimiento y esfuerzo de control respecto a enfoques convencionales, cerrando así la brecha existente entre regulación multivariable eficiente y supervisión estructural confiable identificada en la literatura.

La arquitectura propuesta presenta potencial aplicación en procesos industriales peruanos de alta complejidad dinámica, particularmente en circuitos de molienda y flotación minera, así como en sistemas termoenergéticos y plantas de tratamiento de agua. En minería, la integración MPC+MSPC+ANN podría contribuir a detectar tempranamente degradaciones operativas, desajustes planta–modelo y variaciones persistentes en variables críticas de recuperación y molienda, reduciendo falsas alarmas y pérdidas de eficiencia. En sistemas de agua y energía, permitiría mejorar la supervisión de procesos multivariables sujetos a perturbaciones y restricciones operativas.

Los principales costos de implementación se asocian a instrumentación industrial, integración computacional y calibración de modelos, mientras que los beneficios potenciales incluyen mayor confiabilidad operativa, reducción de alarmas espurias, mejor capacidad diagnóstica y soporte a estrategias de mantenimiento predictivo. Entre los riesgos principales destacan la dependencia de datos representativos, la complejidad de integración industrial y la necesidad de validación experimental bajo condiciones reales de operación.

La arquitectura propuesta presenta como fortalezas principales la integración no intrusiva entre MPC, MSPC y ANN, la preservación del desempeño regulatorio y la mejora en la discriminación entre perturbaciones operativas y cambios estructurales persistentes. Asimismo, el enfoque mantiene interpretabilidad operacional y compatibilidad con esquemas industriales convencionales de supervisión y control. No obstante, el trabajo presenta limitaciones asociadas a la dependencia de datos representativos para el entrenamiento neuronal, la ausencia de validación experimental en planta real y la evaluación restringida a un benchmark industrial simulado. Adicionalmente, el desempeño del esquema puede verse afectado ante dinámicas altamente no estacionarias, cambios abruptos de régimen o condiciones operativas no incluidas durante el entrenamiento del modelo neuronal.

Como proyección futura, se recomienda extender el enfoque propuesto hacia escenarios con dinámicas no estacionarias de mayor complejidad e incertidumbre, así como validar experimentalmente la arquitectura en plantas piloto o procesos industriales reales. Asimismo, futuras investigaciones podrían incorporar estrategias de aprendizaje profundo adaptativo, reentrenamiento en línea, transferencia de aprendizaje, métodos híbridos de diagnóstico y mecanismos de interpretabilidad para fortalecer la capacidad de supervisión estructural bajo condiciones industriales variables y de gran escala.

REFERENCIAS BIBLIOGRÁFICAS

- Castelletti, A., Ficchi, A., Cominola, A., Segovia, P., Giuliani, M., Wu, W., Lucia, S., Ocampo-Martinez, C., De Schutter, B., & Maestre, J. M. (2023). Model predictive control of water resources systems: A review and research agenda. *Annual Reviews in Control*, 55, 442–465. <https://doi.org/10.1016/j.arcontrol.2023.03.013>
- Cavalcanti, F., Kozonoe, C. E., Pacheco, K., & Alves, R. M. B. (2021). Application of artificial neural networks to chemical and process engineering. In *Deep learning applications*. IntechOpen. <https://doi.org/10.5772/intechopen.96641>
- Fiedler, F., Karg, B., Lüken, L., Brandner, D., Heinlein, M., Brabender, F., & Lucia, S. (2023). do-mpc: Towards FAIR nonlinear and robust model predictive control. *Control Engineering Practice*, 140, 105676. <https://doi.org/10.1016/j.conengprac.2023.105676>
- Hernandez, C., Matta, N., Almadhoun, W., Chelliguel, T., Palomino, C., Alhammo, A., Ayoubi, R., Arnaout, A., Penubarthi, S., Pandey, M., Abdullayev, A., Sabbagh, A. A., Asarpota, J., Mijares, G., & Damarla, P. (2024). Revolutionizing oil field operations: Implementing multivariable predictive control to drive autonomous well control operations. *ADIPEC*. <https://doi.org/10.2118/222967-MS>
- Herrera Vega, J. C., de Jesús Rahmer, B., & Herrera Vidal, G. (2022). Análisis de componentes principales (ACP) aplicados al control estadístico de procesos multivariados. *Investigación e Innovación en Ingenierías*, 10(1), 17–29. <https://doi.org/10.17081/invinno.10.1.4972>
- Huang, K., Wei, K., Li, F., Yang, C., & Gui, W. (2023). LSTM-MPC: A deep learning based predictive control method for multimode process control. *IEEE Transactions on Industrial Electronics*, 70(11), 11544–11554. <https://doi.org/10.1109/TIE.2022.3229323>

- Jung, M., Mendes, P. R. d. C., Önnheim, M., & Gustavsson, E. (2023). Model predictive control when utilizing LSTM as dynamic models. *Engineering Applications of Artificial Intelligence*, 123, 106226. <https://doi.org/10.1016/j.engappai.2023.106226>
- Li, J., Ding, D., & Tsung, F. (2021). Directional PCA for fast detection and accurate diagnosis: A unified framework. *IEEE Transactions on Cybernetics*. <https://doi.org/10.1109/TCYB.2021.3070590>
- Melo, A., Câmara, M., & Pinto, J. C. (2024). Data-driven process monitoring and fault diagnosis: A comprehensive survey. *Processes*, 12(2), 251. <https://doi.org/10.3390/pr12020251>
- 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>
- Rivero-Contreras, R. E., Zamarreño, J. M., & Tadeo, F. (2025). Avances en el control predictivo para controladores lógicos programables. *Revista Iberoamericana de Automática e Informática Industrial*, 23(1), 13–24. <https://doi.org/10.4995/riai.2025.22466>
- Schwenzer, M., Ay, M., Bergs, T., & Abel, D. (2021). Review on model predictive control: An engineering perspective. *The International Journal of Advanced Manufacturing Technology*, 117(5–6), 1327–1349. <https://doi.org/10.1007/s00170-021-07682-3>
- Ueda, R. M., & Souza, A. M. (2022). An effective approach to detect the source(s) of out-of-control signals in productive processes by vector error correction (VEC) residual and Hotelling's T^2 decomposition techniques. *Expert Systems with Applications*, 187, 115979. <https://doi.org/10.1016/j.eswa.2021.115979>
- Wang, K., Chen, J., Song, Z., Wang, Y., & Yang, C. (2022). Deep neural network-embedded stochastic nonlinear state-space models and their applications to process monitoring. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 7682–7694. <https://doi.org/10.1109/TNNLS.2021.3086323>
- Yu, Z., & Long, J. (2024). Review on advanced model predictive control technologies for high-power converters and industrial drives. *Electronics*, 13(24), 4969. <https://doi.org/10.3390/electronics13244969>
- Zheng, J., Ma, L., Wu, Y., Ye, L., & Shen, F. (2022). Nonlinear dynamic soft sensor development with a supervised hybrid CNN–LSTM network for industrial processes. *ACS Omega*, 7(19), 16653–16664. <https://doi.org/10.1021/acsomega.2c01108>