



<https://estelac.org>

ESTELAC

Año 2026, Vol. 2, No. 1 OCTUBRE 2025 | MARZO 2026

Consejo Editorial

Universidad Autónoma del Estado de México

Director Editorial: Javier Salas García

Editora Científica: Ruth Hernández Pérez (gestión de revisión por pares)

Editor Técnico: Miguel Moran Gonzalez (producción editorial)

Comité Científico

Álvarez Sánchez, Ervin Jesús – Universidad Veracruzana, Región Xalapa, (UV) México

Carbajal-Degante, Erik – Universidad Nacional Autónoma de México (UNAM), México

Flores Cautle, José de Jesús Agustín – Instituto Tecnológico de Orizaba (TecNM Campus Orizaba), México

Gómez Ramos, José Luis – Universidad Juárez Autónoma de Tabasco (UJAT), México

Hernández López, Francisco Miguel – Instituto Tecnológico José Mario Molina Pasquel y Henríquez (TECMM) Jalisco, México

Hernández Oliva, Noemi – Instituto Politécnico Nacional (IPN), México

Hernández Paxtián, Zulma J. – Universidad de la Cañada (UNCA), México

Hernández Villegas, Mario Antonio – Universidad Autónoma de Coahuila (UADEC), México

Lerma Sánchez, Ángel Mario – Universidad Autónoma de Tamaulipas (UAT), México

Rojas, Julio César – Instituto Tecnológico Superior de Acatlán de Osorio (ITSAO) Puebla, México

ESTELAC, año 2026, Volumen 2, Número 1, octubre 2025 – marzo 2026, es una revista de publicación semestral editada por Javier Salas García, Toluca, Estado de México, C.P. 50100, México. Tel. (722) 7595572, <https://estelac.org>, contacto@estelac.org. Editor Responsable: Javier Salas García. Reserva de Derechos al Uso Exclusivo número 04-2026-012113162500-102, ISSN: en trámite, ambos tramitados ante el Instituto Nacional del Derecho de Autor (INDAUTOR). Responsable de la última edición: Javier Salas García. Fecha de última modificación: 30 de marzo de 2026.

Las opiniones expresadas por los autores no necesariamente representan la postura de la Dirección Editorial de la revista. Se permite la reproducción total o parcial del contenido sin fines de lucro, siempre y cuando no se realicen modificaciones y se cite la fuente completa. Esta publicación es realizada en México por Javier Salas García; todos los derechos están reservados en el año 2026. Esta obra cuenta con una Licencia de Creative Commons Atribución-NoComercial-SinDerivar 4.0 Internacional.



Tabla de Contenido	2
Carta Editorial <i>Salas García, Javier</i>	3
Diseño de cimentaciones para aerogeneradores implementados en Ecatzingo, Estado de México	4
Design of foundations for wind turbines implemented in Ecatzingo, State of Mexico	
<i>Sotres Díaz, Jacqueline; Bañuelos García, Francisco Héctor; Dávila Vilchis, Juana Mariel</i>	
Evaluación de los procedimientos aproximados para determinar el diseño de amortiguadores de fluido viscoso no-lineales	16
Evaluation of approximate procedures to determine the design of non-linear viscous fluid dampers	
<i>Sotres Díaz, Jacqueline; Bañuelos García, Francisco Héctor</i>	
Compensación dinámica de par mediante identificación en tiempo finito para el control de un péndulo de un grado de libertad	24
Dynamic torque compensation via finite-time identification for the control of a one-degree-of-freedom pendulum	
<i>Alvarez Sánchez, Ervin Jesús; Aldana Franco, Fernando; Leyva Retureta, José Gustavo; Sánchez Moreno, Alejandro</i>	
Aplicación de la ley de Fourier en la fabricación de una mufla	29
Application of Fourier's law in the manufacture of a muffle	
<i>Flores Camo, Rafael; Galván Chávez, Jorge Moises; García Enríquez, Irma Josefina; Flores Cuautle, Jose de Jesus Agustin; Lara Hernández, Gemima</i>	
Enfoques bayesianos para la toma de decisiones bajo incertidumbre en sistemas inteligentes: una revisión multidisciplinaria	35
Bayesian approaches for decision-making under uncertainty in intelligent systems: a multidisciplinary review	
<i>Moran Gonzalez, Miguel; Salas García, Javier; Albarrán Trujillo, Silvia Edith</i>	

CARTA EDITORIAL

Vol. 2, Núm. 1 (2026)

ESTELAC

Estimados lectores y colegas de la comunidad científica,

Damos la bienvenida al Vol. 2, Núm. 1 de **ESTELAC**, una edición que marca la madurez de nuestra propuesta editorial en la intersección de la energía sostenible, la seguridad estructural y la toma de decisiones asistida por computación para la nueva era tecnológica.

Iniciamos con una sólida contribución al diseño de cimentaciones para aerogeneradores en el municipio de Ecatzingo, una zona de alto valor para el desarrollo eólico mesoamericano. Esta línea de innovación estructural se extiende hacia la evaluación de amortiguadores de fluido viscoso, aportando soluciones críticas para la resiliencia en entornos dinámicos y sísmicos bajo normativas internacionales.

En el ámbito del control avanzado, se presenta un esquema de compensación dinámica de par para péndulos de un grado de libertad, demostrando una precisión superior mediante técnicas de filtrado algebraico. El proceso de manufactura también es analizado a través de la ley de Fourier aplicada a la fabricación de muflas industriales, lo que subraya la importancia de la transferencia de calor en la ingeniería de procesos.

Cerramos este número con una revisión exhaustiva sobre enfoques bayesianos para la toma de decisiones bajo incertidumbre en sistemas inteligentes. Este trabajo, de corte multidisciplinario, sintetiza el estado del arte en inferencia estadística y aprendizaje automático, consolidando a nuestra revista como un referente de vanguardia en la resolución de problemas interdisciplinarios.

Nos sentimos honrados por la calidad de las propuestas recibidas y agradecemos a los revisores por su labor infatigable. Los invitamos a explorar este segundo volumen con la convicción de que la ingeniería moderna exige, hoy más que nunca, una visión integral y audaz.




Javier Salas García

Director Editorial. Revista ESTELAC

Facultad de Ingeniería. Universidad Autónoma del Estado de México

Diseño de cimentaciones para aerogeneradores implementados en Ecatzingo, Estado de México

Design of foundations for wind turbines implemented in Ecatzingo, State of Mexico

Sotres Díaz, Jacqueline¹ ; Bañuelos García, Francisco Héctor^{1*} ; Dávila Vilchis, Juana Mariel¹



Historial del artículo

Recibido: 15-oct-2025

Aceptado: 20-dic-2025

Disponible en línea: 30-mar-2026

Palabras clave

ES: aerogeneradores, cimentación de gravedad, diseño geotécnico, Ecatzingo, ASCE 7-22

EN: wind turbines, gravity foundation, geotechnical design, Ecatzingo, ASCE 7-22

RESUMEN

El presente trabajo desarrolla el diseño estructural y geotécnico de una cimentación de gravedad octagonal para aerogeneradores propuestos en el municipio de Ecatzingo, Estado de México. Se parte del análisis de cargas actuantes, principalmente por viento y sismo, empleando los lineamientos del ASCE 7-22 y el Manual de Diseño de Obras Civiles de la Comisión Federal de Electricidad (CFE). Posteriormente, se realiza el diseño geotécnico considerando los criterios establecidos en la normativa DNV-OS-J101. Para un correcto análisis, se plantean cinco modelos de torres con alturas de 20, 40, 60, 80 y 100 m, evaluando para cada caso las condiciones de volteo, deslizamiento y asentamientos. Los resultados muestran que todas las configuraciones propuestas cumplen con los factores de seguridad mínimos requeridos y con los límites permisibles de asentamiento, demostrando la viabilidad técnica del uso de cimentaciones de gravedad en la zona de estudio. El análisis confirma que estructural y geotécnicamente los modelos son factibles para su implementación.

ABSTRACT

This study develops the structural and geotechnical design of an octagonal gravity foundation for wind turbines proposed in the municipality of Ecatzingo, State of Mexico. The analysis begins with the evaluation of acting loads, primarily wind and seismic forces, following the guidelines established in ASCE 7-22 and the Manual of Civil Works Design of the Federal Electricity Commission (CFE). Subsequently, the geotechnical design is carried out considering the criteria established in the DNV-OS-J101 standard. For a comprehensive analysis, five tower models with heights of 20, 40, 60, 80, and 100 m are proposed, evaluating overturning, sliding, and settlement conditions for each case. The results show that all proposed configurations meet the minimum required safety factors and allowable settlement limits, demonstrating the technical feasibility of using gravity foundations in the study area. The analysis confirms that the models are structurally and geotechnically feasible for implementation.

1. Introducción

En los últimos años, la búsqueda de alternativas a los combustibles fósiles ha tomado mayor relevancia a nivel global debido a la necesidad de mitigar el cambio climático y garantizar una economía sustentable a largo plazo. En este contexto, las energías renovables se presentan como una de las mejores alternativas para lograrlo, por lo que continúan las investigaciones para conseguir avances en su tecnología que les permita ser más eficientes y económicas. En consecuencia, la energía generada por el viento ha ido destacando como una de estas alternativas, aumentando en años recientes su producción a nivel global.

Según datos del Global Wind Energy Council [1], el año 2024 destacó por ser uno de los mejores para la industria eólica. Según el informe para ese año, la energía total producida entre instalaciones existentes y nuevas fue de 1,136 GW, de los cuales, 117 GW corresponden a lo producido únicamente

¹ Facultad de Ingeniería. Universidad Autónoma del Estado de México

* Autor de correspondencia: hbanuelosg589@profesor.uaemex.mx

por las nuevas instalaciones.

En México, según datos de la Asociación Mexicana de Energía Eólica [2], en el año 2024 se mantuvieron en operación 74 parques eólicos que representan 7,782 MW con 3042 aerogeneradores instalados en el país. La energía producida fue equivalente al 5.68 % de la generación total de electricidad en el país.

Este aumento en las nuevas instalaciones durante los últimos años ha sido posible gracias a la capacidad de adaptar los aerogeneradores a diferentes condiciones geológicas y geotécnicas, especialmente en zonas donde el viento puede aprovecharse de manera óptima. Sin embargo, no solo las turbinas deben responder a estas condiciones: las estructuras en las que se sostienen y, sobre todo, sus cimentaciones, deben diseñarse de la mejor manera para garantizar su estabilidad y un funcionamiento adecuado.

La cimentación es un elemento clave en la instalación de un aerogenerador, pues deberá ser capaz de transmitir las cargas de la turbina al suelo. Aunado a esto, tiene un gran impacto tanto en la parte técnica como en la parte económica, pudiendo representar hasta el 36 % del costo total del aerogenerador [3].

En el mercado actual, los tipos de cimentación varían según el lugar donde se instalen este tipo de sistemas. Cuando los aerogeneradores se ubican en tierra firme (estructuras costa-adentro), el diseño depende principalmente de las características del suelo. Entre las más utilizadas se encuentran los pilotes y las cimentaciones de gravedad.

En este artículo solo se consideran las cimentaciones para las turbinas costa-adentro, para el sitio de Ecatzingo en el estado de México.

2. Antecedentes

Los criterios para elegir el tipo de cimentación dependen mayormente del tipo de suelo y las condiciones que prevalecen en la zona donde estará desplantada. En el caso de cimentaciones superficiales, se consideran parámetros geotécnicos como [4]:

- **Estabilidad global:** El análisis en este caso debe realizarse con las condiciones de carga establecidas por el fabricante de la turbina.
- **Rigidez mínima:** Una de las especificaciones establecidas por el fabricante es la rigidez mínima (traslacional y rotacional) que debe tener la cimentación ya que es la base para estimar la respuesta de la turbina.
- **Capacidad de carga:** Se determina normalmente utilizando la ecuación de Terzaghi-Meyerhof utilizando los factores geotécnicos determinados previamente mediante estudios de suelo. El factor de seguridad recomendable es de 3.0, a menos que esté sujeto a cargas extremas, donde se reduce a 2.26.

En el caso de los aerogeneradores, la cimentación se encuentra sometida a grandes momentos de volteo, por lo que siempre debe considerarse una carga excéntrica en su evaluación.

La cimentación de gravedad destaca porque puede ser usado tanto en estructuras costa-adentro como estructuras costa-afuera. Se les atribuye entre el 20 – 25 % del costo total del aerogenerador [5].

Este tipo de cimentación consiste en una base de concreto reforzado, ya sea circular u ortogonal, donde se monta un pedestal cilíndrico [4]. Su elección debe basarse en los resultados obtenidos al realizar un estudio exhaustivo de los estratos inmediatos de suelo. Además, el diseño deberá estar enfocado en la revisión de los asentamientos. Este tipo de cimentación se basa principalmente en su estabilidad, por lo que factores como el área de la cimentación y el peso necesario deberán tomarse en cuenta.




Figura 1: Representación esquemática de una cimentación de gravedad tipo octagonal para aerogeneradores terrestres, compuesta por una losa de base y un pedestal central cilíndrico.

El correcto aprovechamiento de la turbina depende en gran medida de la velocidad de viento en la zona donde será desplantada. De este modo, la cimentación a elegir está fuertemente ligada a las condiciones geotécnicas a las que se encontrará expuesta.

Además, al jugar también un papel importante para el correcto aprovechamiento y desempeño de un aerogenerador, el sitio debe cumplir con las siguientes características [6]:

- Fácil acceso por carretera al sitio.
- Baja densidad de población.
- Riesgo mínimo para actividades agroforestales.
- Terrenos de propiedad privada y libre dominio.
- Uso de suelo dedicado principalmente a la agricultura y pastoreo.

3. Metodología

Para realizar un diseño adecuado de cimentación, debe llevarse a cabo tanto el análisis estructural para determinar las cargas actuantes (principalmente por viento), así como el análisis de las características del suelo y condiciones geotécnicas de la zona. Una vez que se conocen estos datos, puede revisarse una propuesta para el diseño de la cimentación.

Dentro del análisis estructural, los rubros a considerar son: análisis de viento, y análisis sísmico.

El análisis sísmico puede llevarse a cabo con ayuda del Manual de Diseño de Obras Civiles de la Comisión Federal de Electricidad (CFE) [7], siguiendo el siguiente procedimiento.

1. **Determinar la clasificación de la estructura.** Depende de los efectos que pudiesen ocurrir si la estructura falla, tomando en cuenta su relevancia y la magnitud de los daños que pueden generarse en circunstancias desfavorables.
2. **Identificar la región sísmica.** El Manual de Diseño de Obras Civiles propone cuatro regiones, dos de alta y dos de baja sismicidad, como se muestra en la figura.




Figura 2: Mapa de regionalización sísmica de la República Mexicana según el manual de la CFE, utilizado para identificar la intensidad sísmica en la zona de estudio y definir parámetros de diseño [7].

3. **Crear el espectro de diseño.** El espectro de diseño sísmico se puede construir manualmente a partir de las siguientes ecuaciones:

$$S_a(T_e, \beta) = \begin{cases} a_0 + [c\beta T_e - a_0] \frac{T_e}{T_a} & \text{si } T_e < T_a \\ c\beta(T_e, \xi_e) & \text{si } T_a \leq T_e < T_b \\ c\beta(T_e, \xi_e) \left(\frac{T_b}{T_e}\right)^r & \text{si } T_b \leq T_e < T_c \\ c\beta(T_e, \xi_e) \left(\frac{T_b}{T_c}\right)^r \left(\frac{T_c}{T_e}\right)^2 & \text{si } T_e \geq T_c \end{cases} \quad (1)$$

También es posible utilizar el programa PRODISIS, el cual corresponde con lo establecido en el Manual de Diseño de Obras Civiles.

Como ya se ha explicado, la estructura estará expuesta mayormente a cargas de viento y su desempeño está directamente relacionado con la exposición a este tipo de carga. Al ser éste el factor más importante en cuanto a su funcionamiento, el análisis por viento es el más importante a la hora de realizar el diseño de la cimentación, ya que deberá ser capaz de oponerse a volteos y deslizamientos.

El análisis para esta parte puede realizarse según lo establecido en el documento técnico del ASCE 7-22.

Se revisa la velocidad de viento para el municipio donde se tendrá la instalación de aerogeneradores, la cual puede obtenerse con los datos proporcionados por el Centro Nacional de Prevención de Desastres (CENAPRED) [8].

Entre otros datos, debe tomarse en cuenta la topografía natural de la zona, construcciones existentes y la vegetación para determinar la rugosidad del suelo.

Considerando la topografía del lugar y la geometría de la estructura, se puede realizar el cálculo de las fuerzas de viento que actúan sobre ella utilizando la siguiente fórmula.

$$q_z = 0,613K_zV^2K_{zt}K_dK_e \quad (2)$$

donde: V es la velocidad básica de viento en m/s, y K_z es el coeficiente de exposición a la presión de velocidad.

Una vez teniendo el conocimiento de la presión dinámica de base, pueden calcularse las fuerzas de viento actuando en diferentes alturas sobre la torre.

$$F = q_zGC_fA_f \quad (3)$$

donde: G es un factor de efecto de ráfaga, el cual puede ser considerado como 0.85 si se trata de una estructura rígida; C_f es un coeficiente de fuerza. Puede ser obtenido con la tabla que se muestra a continuación; A_f es el área proyectada al viento.

Según el ASCE 7-22 [9], se denomina rígida a una estructura cuya frecuencia natural sea mayor o igual que 1 Hz.

3.1. Diseño Geotécnico

Para determinar un diámetro adecuado, se requieren los datos geotécnicos de la zona, mismos que permitirán realizar los cálculos pertinentes que permitan determinar la capacidad de carga que tenga el suelo donde será desplantada. No debe olvidarse que, al estar mayormente expuesto a cargas de viento, el valor de excentricidad no puede ser despreciado. A continuación se muestran los pasos de acuerdo con el DNV-OS-J101 [10].

Determinar el área efectiva de la cimentación:

$$A_{eff} = 2[R^2 \cos^{-1}(e/R) - e\sqrt{R^2 - e^2}] \quad (4)$$

donde: R es el radio de la cimentación; e es la excentricidad, que puede ser calculada con:

$$e = \frac{M_t}{V} \quad (5)$$

Considerando que M_t es el momento total, mientras que V es la carga axial de la estructura más el peso propio de la cimentación.

Determinar las dimensiones del rectángulo equivalente, dadas por:

$$L_{eff} = \sqrt{A_{eff} \frac{L}{B}} \quad (6)$$

$$B_{eff} = \frac{A_{eff}}{L_{eff}} \quad (7)$$

Momento máximo a compresión. El objetivo de realizar estos cálculos es obtener el esfuerzo máximo a compresión bajo la cimentación, el cual puede ser obtenido con:

$$\sigma_{max} = \frac{V}{A_{eff}} \quad (8)$$

El esfuerzo obtenido a partir de este método deberá compararse con la capacidad de carga admisible en el terreno donde será desplantado, la cual puede obtenerse a partir de los datos geotécnicos citados en la Tabla 1 y con la ecuación de Meyerhof [11].

Capacidad de carga.

$$q_u = cN_c s_c d_c + qN_q s_q d_q + 0,5\gamma B N_\gamma s_\gamma d_\gamma \quad (9)$$

Se debe considerar que la ecuación de Meyerhof dará como resultado una capacidad de carga máxima, por lo que, si se desea obtener la capacidad de carga admisible, se debe considerar un factor de seguridad en un rango de 2 a 3 [12]. Para este caso en particular, el factor considerado fue de 3.0.

Comparación. Una vez que se tienen estos valores, pueden compararse restando la capacidad de carga admisible con el esfuerzo máximo a compresión de la cimentación, y una vez que el resultado sea aproximadamente cero, se entenderá que el diámetro es el adecuado.

4. Ejemplo de Aplicación

El municipio de Ecatzingo destaca como una zona adecuada para desplantar un aerogenerador gracias a que, según el Plan de Desarrollo Municipal [13], en el municipio el uso de suelo está dividido en: 35 % actividades agrícolas, 30 % en actividades forestales, 10 % en pastizales para alimentar al ganado y solo el 25 % es de uso urbano, condiciones que se consideran adecuadas según lo especificado para la selección de sitio.

Se plantean cinco modelos de alturas variables desde los 20 hasta los 100 m, tal como se muestra en la Figura 3. Para cada uno de ellos, se llevó a cabo el análisis y diseño según lo descrito en la metodología.

Los resultados obtenidos se muestran a continuación.

4.1. Análisis por viento y sismo

4.2. Diseño geotécnico

Para la revisión de asentamientos que debe realizarse por el tipo de cimentación utilizada [14], se obtienen los siguientes resultados.

Tabla 1: *Parámetros geotécnicos representativos del suelo en el municipio de Ecatzingo, incluyendo valores de resistencia al corte y factores de capacidad de carga empleados en el diseño.*

Parámetro	Valor
Peso Volumétrico del suelo, γ	1,679 tf/m ²
Ángulo de fricción interna del suelo, ϕ	13,48°
Cohesión del suelo, c	6,33 tf/m ²
Factor de cohesión, N_c	9.12
Factor de sobrecarga, N_q	2.46
Factor de suelo, N_γ	0.42
Capacidad de carga admisible, q_a	16,39 tf/m ²
Capacidad de carga última, q_c	49,2 tf/m ²




Figura 3: *Comparativa visual a escala de los cinco modelos de torres de aerogenerador propuestos, con alturas incrementales de 20 a 100 metros para su evaluación técnica.*

Tabla 2: *Resumen de las acciones mecánicas extremas (carga axial, fuerza cortante y momento de volteo) obtenidas del análisis estructural bajo condiciones de viento y sismo para cada altura de torre.*

Torre	Carga axial (kN)	Cortante (kN)	Momento (kN-m)
20 m	259.28	10.01	146.95
40 m	359.83	27.57	625.98
60 m	392.60	66.02	2218.43
80 m	416.43	108.79	4831.03
100 m	530.72	147.05	7989.95




Figura 4: Distribución de las fuerzas de viento calculadas para cada uno de los modelos propuestos, reflejando el incremento de la carga dinámica conforme aumenta la altura de la torre.




Figura 5: Espectro de diseño sísmico obtenido con el programa PRODISIS, mostrando la aceleración máxima esperada en función del periodo natural de vibración de las estructuras.

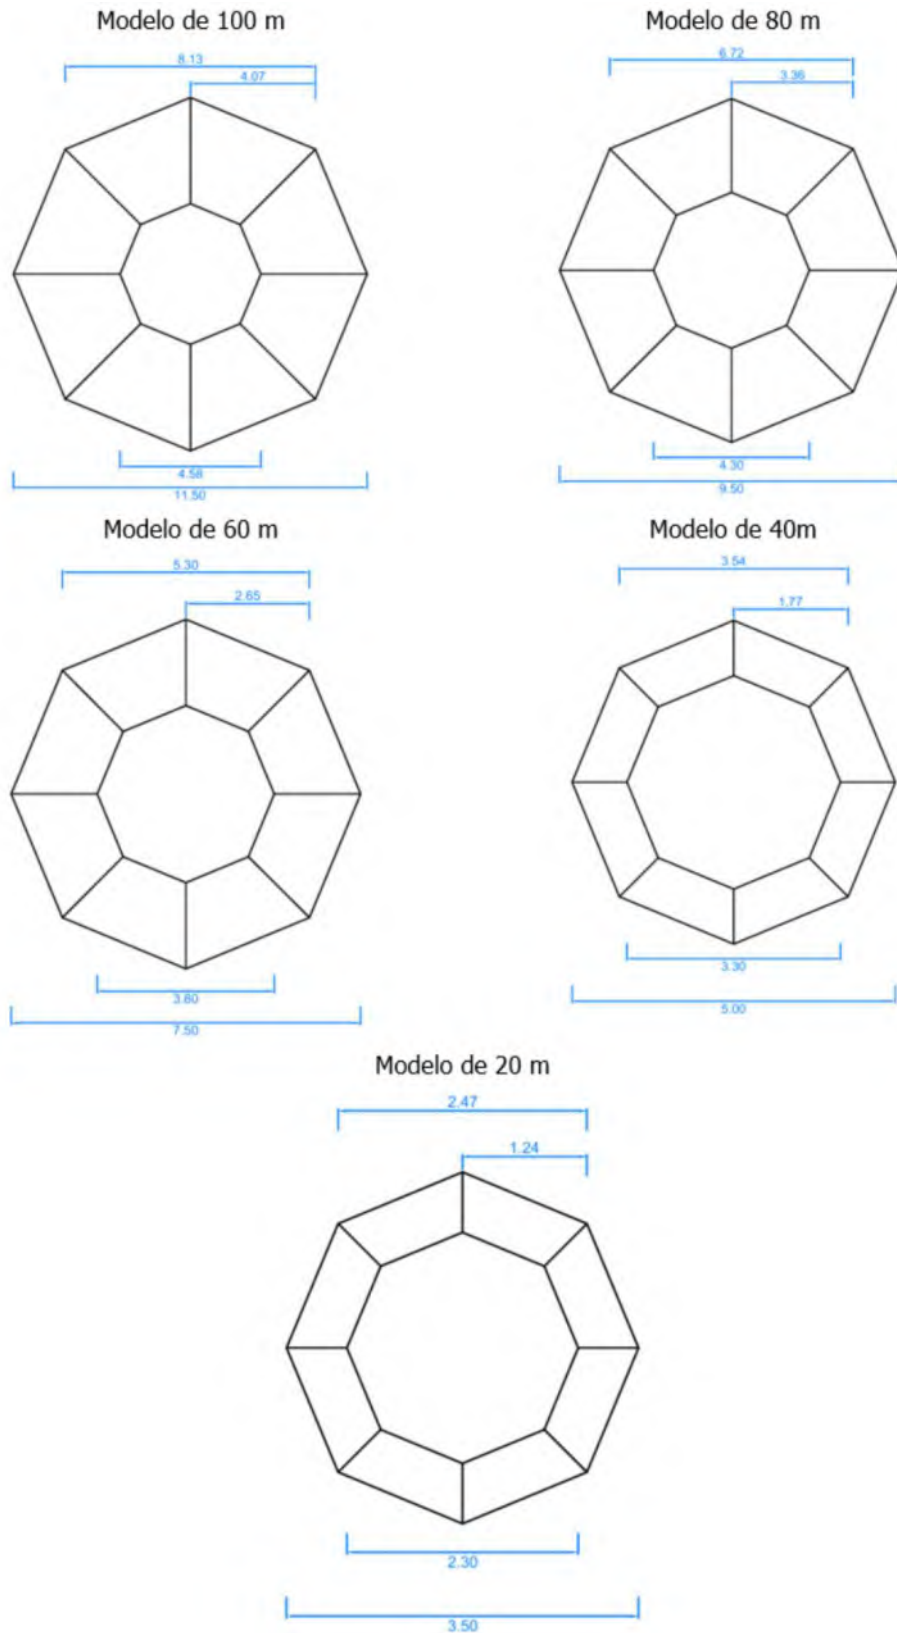


Figura 6: Detalles geométricos de las cimentaciones diseñadas para cada modelo, especificando dimensiones críticas como el lado del octágono y distancia entre caras para garantizar la estabilidad.

Tabla 3: Resultados de la validación de estabilidad mecánica, comparando el esfuerzo máximo aplicado contra la capacidad admisible del terreno y verificando los factores de seguridad.

Altura	σ_{max} (MPa)	q_a (MPa)	FS (volteo)	V_{res} (kN)
20 m	0.13	0.16	1.40	853.78
40 m	0.15	0.16	3.67	1421.91
60 m	0.15	0.16	10.83	2541.11
80 m	0.16	0.16	20.99	3662.48
100 m	0.15	0.16	36.79	5367.05

Tabla 4: Evaluación del estado límite de servicio por asentamientos, contrastando los valores calculados con los límites normativos establecidos (30 cm) para asegurar la funcionalidad.

Altura (m)	Asentamiento (cm)	Permisible (cm)
20	3.31	30
40	5.24	30
60	7.63	30
80	9.95	30
100	11.45	30




Figura 7: Relación entre la altura del modelo y el asentamiento total esperado, ilustrando que en todos los casos los valores cumplen con el límite de 30 cm propuesto por la normativa.

5. Conclusiones

De acuerdo con los resultados obtenidos, se pueden destacar las conclusiones enlistadas a continuación:

- Para la revisión por volteo, el factor de seguridad mínimo para que se considere que la cimentación cumple con las condiciones adecuadas para oponerse a este efecto debe ser de 1.5. Como se observa, todos los factores de seguridad obtenidos con el análisis son mayores que 1.5 (o muy cercanos en el caso de 20m), por lo que satisface la revisión.
- Así mismo, las fuerzas cortantes son menores a las fuerzas que se oponen a estas, propias de las características geotécnicas del suelo, demostrando que también todos los casos satisfacen la revisión.
- El asentamiento permisible indica un máximo de 30 cm [15]. Ninguno de los casos propuestos excede este límite, por lo que también cumplen con la revisión.
- El objetivo de hacer el análisis con cinco modelos es demostrar que cualquiera de los casos puede adaptarse en la zona. La selección final dependerá del aprovechamiento energético.

Créditos de los Autores

Sotres Díaz, Jacqueline: Investigación, Metodología, Redacción - borrador original.

Bañuelos García, Francisco Héctor: Conceptualización, Análisis formal, Supervisión.

Dávila Vilchis, Juana Mariel: Validación, Visualización.

Referencias

- [1] A. I. D. Henrique et al. “Global Wind Energy Council”. En: (2025).
- [2] Asociación Mexicana de Energía Eólica. “Informe Anual de la AMDEE”. En: (2025).
- [3] K.-Y. Oh et al. “A review of foundations of offshore wind energy convertors: Current status and future perspectives”. En: *Renewable and Sustainable Energy Reviews* 88 (2018), págs. 16-36. DOI: [10.1016/j.rser.2018.02.005](https://doi.org/10.1016/j.rser.2018.02.005).
- [4] E. Ntambakwa et al. “Geotechnical Design Considerations for Onshore Wind Turbine Shallow Foundations”. En: *Geotechnical and Structural Engineering Congress 2016*. Phoenix, Arizona: ASCE, 2016, págs. 1153-1165. DOI: [10.1061/9780784479742.096](https://doi.org/10.1061/9780784479742.096).
- [5] M. J. Vahdatirad et al. “Reliability analysis of a gravity-based foundation for wind turbines: a code-based design assessment”. En: *Géotechnique* 64.8 (2014), págs. 635-645. DOI: [10.1680/geot.13.P.152](https://doi.org/10.1680/geot.13.P.152).
- [6] G. C. B. y S. P. S. “Site Selection for Wind Farm Installation”. En: *International Journal of Innovative Research in Electrical, Electronics, Instrumentation and Control Engineering* 3.8 (2015), págs. 59-61. DOI: [10.17148/IJIREICE.2015.3814](https://doi.org/10.17148/IJIREICE.2015.3814).
- [7] U. Hernández y L. Rocha. *Manual de Diseño de Obras Civiles: Diseño por Sismo*. 1.^a ed. Comisión Federal de Electricidad, 2015.

-
- [8] O. A. L. Bótiz, V. M. Cruz y M. J. Espinosa. *SISTEMA NACIONAL DE PROTECCIÓN CIVIL CENTRO NACIONAL DE PREVENCIÓN DE DESASTRES*. Inf. téc. CENAPRED.
- [9] American Society of Civil Engineers. *Minimum Design Loads and Associated Criteria for Buildings and Other Structures*. Reston, VA: ASCE, 2021. DOI: [10.1061/9780784415788](https://doi.org/10.1061/9780784415788).
- [10] Det Norske Veritas. *DNV-OS-J101 Design of Offshore Wind Turbine Structures*. Inf. téc. 2014.
- [11] W. Mohamed y P.-E. Austrell. “A comparative study of three onshore wind turbine foundation solutions”. En: *Computers and Geotechnics* 94 (2018), págs. 46-57. DOI: [10.1016/j.compgeo.2017.08.022](https://doi.org/10.1016/j.compgeo.2017.08.022).
- [12] G. G. Meyerhof. “THE ULTIMATE IBARING CAPACITY OF FOUNDATIONS”. En: ().
- [13] D. Robalo y A. Martínez. *Plan de Desarrollo Municipal de Ecatzingo 2025-2027*. Inf. téc. Gobierno Municipal de Ecatzingo, 2025. URL: https://ecatzingo.gob.mx/documentos/PDM%202025_2027%20ECATZINGO%20PDF.pdf.
- [14] Det Norske Veritas y Forskningscenter Risø. *Guidelines for design of wind turbines*. 2.^a ed. Copenhagen: Det Norske Veritas, 2009.
- [15] Instituto para la Seguridad de las Construcciones en la Ciudad de México. *Norma Técnica Complementaria para el Diseño y Construcción de Cimentaciones*. Inf. téc. 2023.

Evaluación de los procedimientos aproximados para determinar el diseño de amortiguadores de fluido viscoso no-lineales

Evaluation of approximate procedures to determine the design of non-linear viscous fluid dampers

Sotres Díaz, Jacqueline¹ ; Bañuelos García, Francisco Héctor^{1*} 

Historial del artículo

Recibido: 05-nov-2025

Revisado: –

Aceptado: 10-ene-2026

Publicado: 30-mar-2026

Palabras clave

ES: amortiguadores de fluido viscoso, diseño sísmico, no-linealidad, edificios de acero

EN: viscous fluid dampers, seismic design, non-linearity, steel buildings

RESUMEN

El propósito principal de esta investigación es comparar la efectividad de los procedimientos más utilizados para el diseño y distribución de amortiguadores de fluido viscoso no-lineal en marcos de acero. Estos procedimientos consisten en idealizar el comportamiento de estos dispositivos como un sistema simplificado, con la finalidad de utilizar el análisis modal espectral tal y como se indica en los códigos de diseño. Para ilustrar la aplicación de estos procedimientos se propone diseñar cuatro modelos de acero con diferente número de entresijos e irregularidades en planta. Para comparar la efectividad de estos procedimientos se propone determinar la respuesta de los marcos diseñados utilizando análisis no-lineales historia-tiempo. A partir de los resultados se puede evaluar en términos de las distorsiones, aceleraciones, fuerzas cortantes y de amortiguamiento máximas de entrepiso. Como demanda sísmica se considera un conjunto de registros sísmicos del Valle de México. De los resultados obtenidos se pueden analizar las ventajas y desventajas de cada uno de los procedimientos analizados para determinar cuál proporciona los mejores resultados.

ABSTRACT

The main purpose of this research is to compare the effectiveness of the most used procedures for the design and distribution of nonlinear viscous fluid dampers in steel frames. These procedures consist of idealizing the behavior of these devices as a simplified system to apply modal response spectrum analysis, as indicated in design codes. To illustrate the application of these procedures, four steel frame models with different numbers of stories and plan irregularities are proposed. To compare the effectiveness of these procedures, the structural response of the designed frames will be determined using nonlinear time-history analyses. Based on the results, performance will be evaluated in terms of maximum interstory drifts, accelerations, shear forces, and damping forces. As seismic demand, a set of ground motion records representative of those affecting the Valley of Mexico is proposed. From the obtained results, the advantages and disadvantages of each analyzed procedure can be examined, thereby determining which procedure provides the best overall performance.

1. Introducción

Las tendencias actuales en la rehabilitación y en el diseño de nuevos edificios consisten en garantizar niveles de resiliencia cuando están sujetos a las demandas sísmicas de diseño durante su ciclo de vida. Muchos edificios existentes no satisfacen las condiciones de los códigos de diseño actuales debido a las restricciones arquitectónicas y al incremento de las demandas sísmicas. En el caso del diseño de nuevas estructuras, existen situaciones donde es económicamente inviable satisfacer las condiciones de los códigos de diseño, en particular para edificios críticos como hospitales, que requieren seguir en funcionamiento después de un sismo. Por ello, es necesario considerar alternativas como los disipadores pasivos de energía, que permiten reducir la respuesta estructural y restringir el daño en los elementos principales. Entre estos dispositivos, los amortiguadores de fluido viscoso (FVDs) han cobrado gran

¹ Facultad de Ingeniería. [Universidad Autónoma del Estado de México](https://www.uaemex.mx)

* Autor de correspondencia: hbanuelosg589@profesor.uaemex.mx

relevancia debido a que el amortiguamiento viscoso suplementario es su única variable de diseño, su comportamiento es independiente de la frecuencia de la estructura y su capacidad de disipación de energía es muy alta en comparación con otros sistemas [1].

Estos dispositivos dependen de la velocidad relativo; su funcionamiento consiste en el flujo de un fluido viscoso a través de pequeños orificios de una cámara a otra. Este proceso convierte la energía cinética en calor, disipando la energía inducida por la excitación lateral. La fuerza de un FVD puede considerarse proporcional a la velocidad relativa entre sus extremos [2]:

$$f_d = c_d |\dot{u}|^\alpha \operatorname{sgn}(\dot{u}) \quad (1)$$

donde c_d es el coeficiente de amortiguamiento, \dot{u} es la velocidad relativa y α es el exponente del dispositivo. Aunque a menudo se idealizan como lineales ($\alpha = 1$), una relación no-lineal ($\alpha < 1$) es más precisa de acuerdo con estudios experimentales [2]. Los NLFVDs ofrecen la ventaja de presentar fuerzas de amortiguamiento mayores a velocidades pequeñas en comparación con los lineales (Figura 1), reduciendo además las fuerzas axiales en columnas y cimentaciones.




Figura 1: Relación de fuerza-velocidad de los amortiguadores viscosos y comparación entre modelos lineales y no-lineales.

Los procedimientos de diseño y distribución de FVDs se clasifican en dos categorías: distribución “óptima” y procedimientos simplificados. La primera utiliza algoritmos iterativos o genéticos [3, 4, 5, 6]. Aunque eficientes, estos métodos no son sencillos ni prácticos para el diseño cotidiano. Por otro lado, los procedimientos simplificados idealizan los disipadores como amortiguamiento clásico suplementario para utilizar el análisis modal espectral convencional [7]. Se han desarrollado variantes basadas en diversos parámetros como fuerza cortante [8], energía de deformación [9] o distorsiones [1].

Muchos métodos simplificados se formularon originalmente para disipadores lineales, pero se pueden extender a los no-lineales [2, 10]. Sin embargo, al usar la ecuación del movimiento para sistemas dinámicos [5, 11], surge la dificultad de parametrizar la no-linealidad. Por ello, se introdujo el concepto de “energía equivalente” [12], donde un modelo lineal disipa la misma cantidad de energía que el no-lineal.

$$[M]\{\ddot{u}\} + [C]\{\dot{u}\} + [C]\{\dot{u}\}^\alpha + [K]\{u\} = -[M]\{\iota\}\ddot{u}_g(t) \quad (2)$$

Adicionalmente, Diotallevi et al. [13] propusieron un procedimiento directo basado en un índice de amortiguamiento adimensional, mientras que Landi et al. [14] desarrollaron un método de dos pasos

basado en el espectro de capacidad. También existen enfoques estocásticos para la optimización de estos dispositivos [15].

2. Antecedentes

2.1. Diseño de amortiguadores de fluido viscoso lineal

El procedimiento más común para el diseño de LFVDs es el de Constantinou y Symans [7], que aproxima el comportamiento no clásico como amortiguamiento suplementario clásico para análisis espectral:

$$\xi_{dpi} = \frac{T_i \sum_{j=1}^{nd} c_{dj} f_j \phi_{rj,i}^2}{4\pi \sum_{j=1}^n m_j \phi_{j,i}^2} \quad (3)$$

Este enfoque ha sido adoptado por documentos técnicos como FEMA 273 [16], FEMA 356 [17] y ASCE 7 [18].

3. Procedimientos para calcular amortiguadores no-lineales

En esta sección se resumen los principales métodos simplificados para determinar las propiedades de los NLFVDs.

3.1. Procedimiento de Symans, Constantinou y Ramirez et al. [7, 10]

Es una evolución del método lineal donde el amortiguamiento suplementario se calcula considerando el exponente α y la amplitud de desplazamiento de la azotea:

$$\xi_{dpi} = \frac{\sum_{j=1}^{nd} (2\pi)^{2\alpha_j} T_i^{2-\alpha_j} \lambda_j c_{dj} f_j^{1+\alpha_j} D_{az}^{\alpha_j-1} \phi_{rj,i}^{1+\alpha_j}}{(8\pi)^3 \sum_{j=1}^n m_j \phi_{j,i}^2} \quad (4)$$

Donde D_{az} es el desplazamiento máximo de la azotea.

3.2. Procedimiento de Lin y Chopra [12]

Basado en la “energía equivalente” bajo movimiento armónico, iguala la energía disipada por un sistema lineal y uno no-lineal para determinar coeficientes equivalentes:

$$c_d^{NL} = c_d^L \left[\frac{(\dot{w}_{\text{máx}})^{1-\alpha}}{\beta_\alpha} \right], \quad \beta_\alpha = \frac{2^{2+\alpha} \Gamma^2(1 + \frac{\alpha}{2})}{\pi \Gamma(2 + \alpha)} \quad (5)$$

3.3. Otros procedimientos

Se incluyeron también los métodos de Diotallevi et al. [13] (índice de amortiguamiento), Landi et al. [19] (espectro de capacidad) y el procedimiento estocástico de Di Paola y Navarra [15].

4. Proceso de comparación

Se evaluaron los procedimientos mediante el diseño de cuatro modelos de acero.

4.1. Diseño preliminar

Se diseñaron marcos planos de acero con diferentes configuraciones de entrepiso e irregularidades (Figura 2).




Figura 2: Geometría de los marcos de acero utilizados como ejemplos de aplicación (dimensiones en metros).

4.2. Definición de la demanda de diseño

Se utilizaron registros sísmicos del Valle de México escalados al espectro de las NTCDS-23 [20]. Se calculó el amortiguamiento suplementario necesario para cumplir con los estados límite de distorsión (Figura 3).

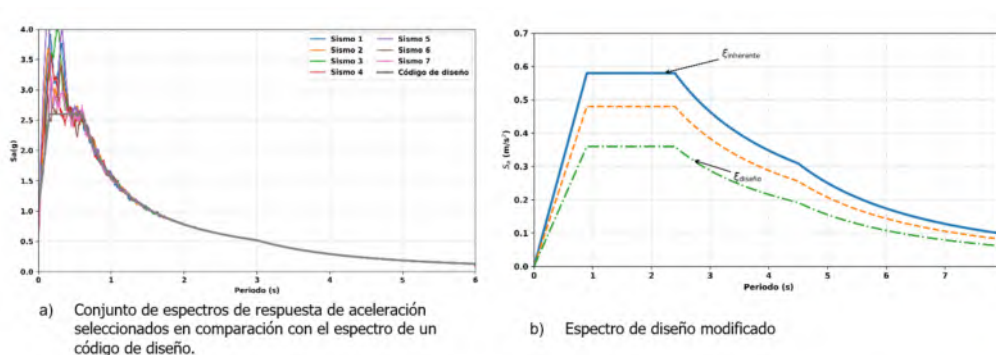


Figura 3: Demandas sísmicas de diseño y registros escalados para el análisis dinámico.

4.3. Análisis historia-tiempo

Se realizaron análisis dinámicos no-lineales en Perform 3D [21] y OpenSees [22], empleando el modelo de histéresis de Ramberg y Osgood [23] para el acero y modelos no-lineales para los amortiguadores.

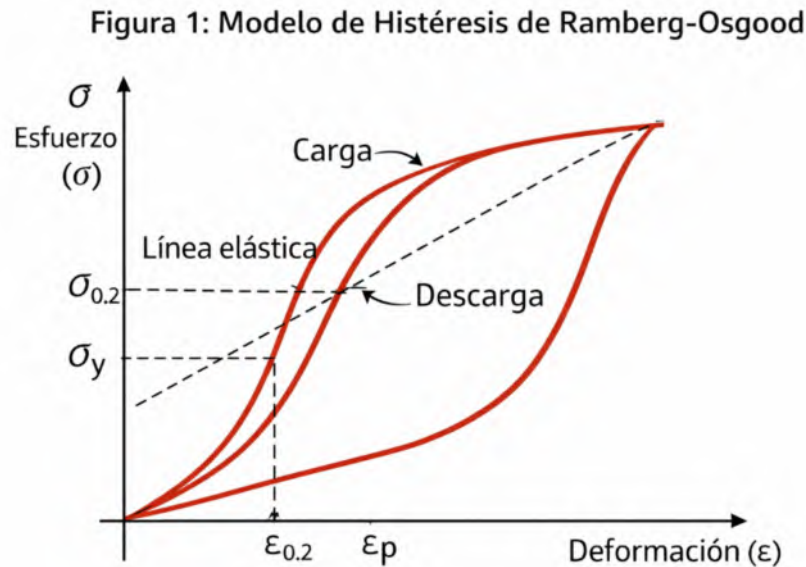


Figura 1: Modelo de Histéresis de Ramberg-Osgood

Figura 4: Modelo de Ramberg y Osgood utilizado para representar el comportamiento inelástico de los elementos de acero.

5. Resultados y comparación

Los resultados comparan distorsiones, aceleraciones y fuerzas (Figuras 5-6).

Además, se realizó una evaluación de desempeño mediante la metodología FEMA P-58 [24] para estimar los costos de reparación esperados (Figura 7).

6. Conclusiones

Se espera que este estudio permita identificar el procedimiento de diseño más efectivo para NLFVDs, logrando un balance entre precisión técnica y simplicidad práctica, reduciendo costos de reparación y optimizando los recursos estructurales para edificaciones en zonas de alta sismicidad como el Valle de México.

Créditos de los Autores

Bañuelos García, Francisco Héctor: Conceptualización, Metodología, Investigación, Supervisión.

Sotres Díaz, Jacqueline: Conceptualización, Software, Redacción - revisión y edición.

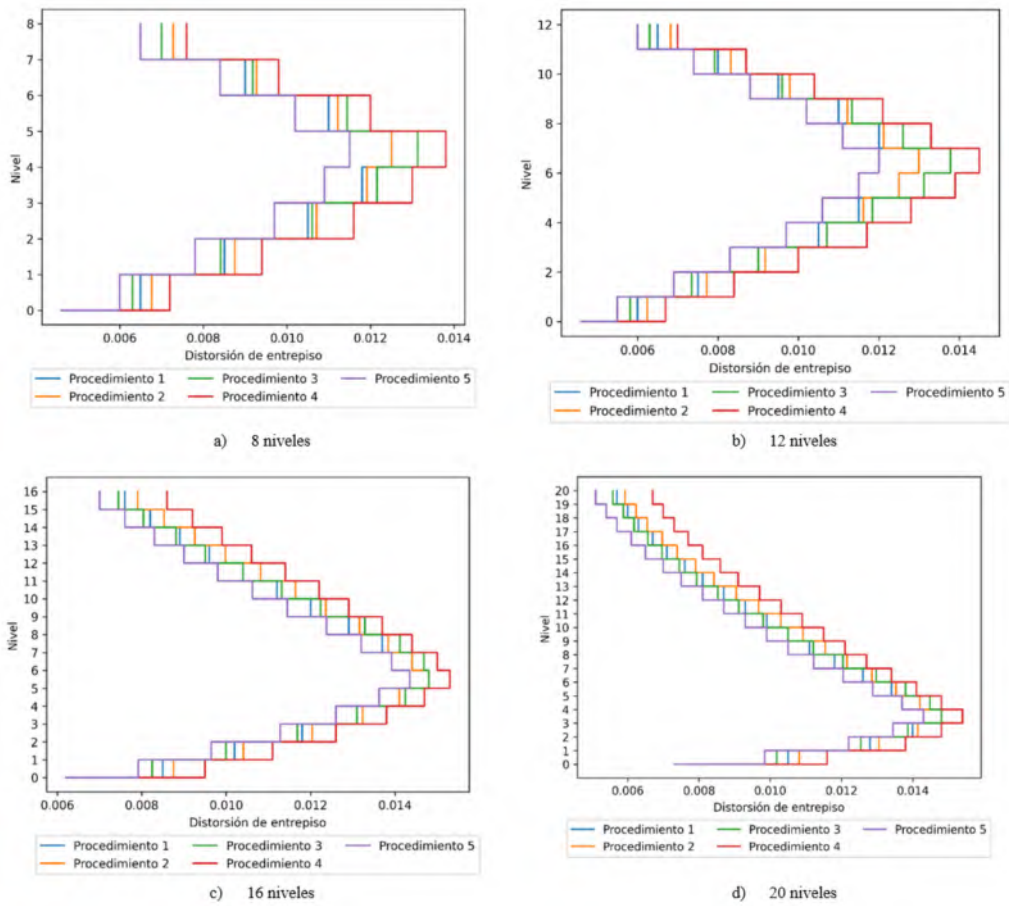


Figura 5: Comparación de distorsiones máximas de entrepiso para cada uno de los procedimientos simplificados evaluados.

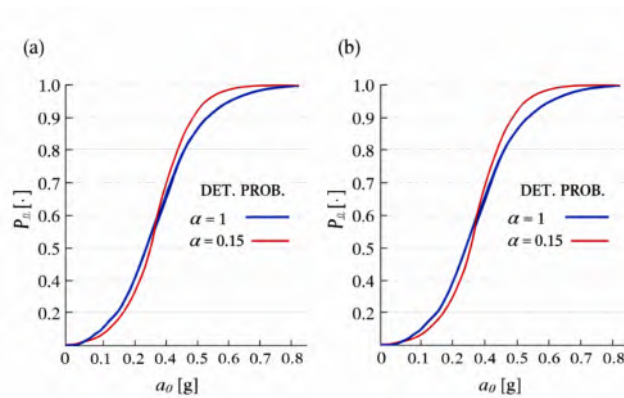


Figura 6: Curvas de probabilidad para la evaluación del estado límite de prevención de colapso.

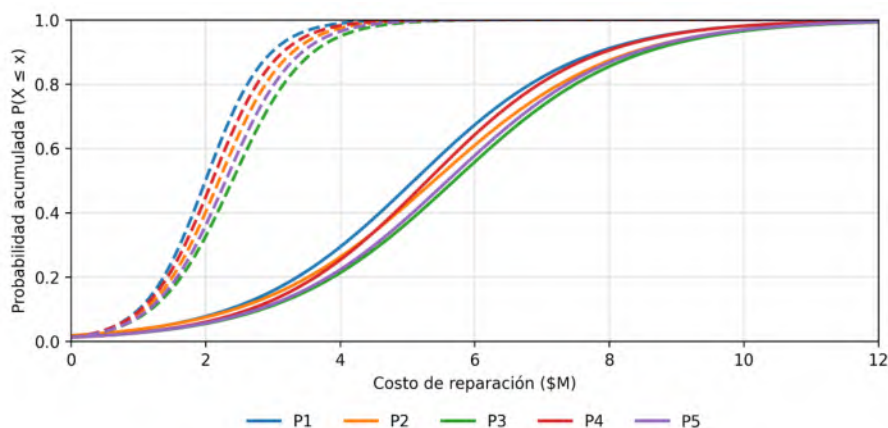


Figura 7: Funciones de distribución acumulativa de los costos totales de reparación estimados mediante FEMA P-58.





Referencias

- [1] L. Landi, F. Conti y P. P. Diotallevi. “Effectiveness of different distributions of viscous damping coefficients for the seismic retrofit of regular and irregular RC frames”. En: *Engineering Structures* 100 (2015), págs. 79-93. DOI: [10.1016/j.engstruct.2015.05.031](https://doi.org/10.1016/j.engstruct.2015.05.031).
- [2] A. A. Seleemah y M. C. Constantinou. *Investigation of Seismic Response of Buildings with Linear and Nonlinear Fluid Viscous Dampers*. Inf. téc. NCEER-97-0004. NCEER, 1997.
- [3] M. P. Singh y L. M. Moreschi. “Optimal placement of dampers for passive response control”. En: *Earthquake Engineering and Structural Dynamics* 31.4 (2002), págs. 955-976. DOI: [10.1002/eqe.132](https://doi.org/10.1002/eqe.132).
- [4] N. Wongprasert y M. D. Symans. “Application of a genetic algorithm for optimal damper distribution within the nonlinear seismic benchmark building”. En: *Journal of Engineering Mechanics* 130.4 (2004), págs. 401-406. DOI: [10.1061/\(ASCE\)0733-9399\(2004\)130:4\(401\)](https://doi.org/10.1061/(ASCE)0733-9399(2004)130:4(401)).
- [5] I. Takewaki. *Building Control with Passive Dampers: Optimal Performance-based Design for Earthquakes*. 2009. DOI: [10.1002/9780470824931](https://doi.org/10.1002/9780470824931).
- [6] D. Lopez-Garcia y T. T. Soong. “Efficiency of a simple approach to damper allocation in MDOF structures”. En: *Journal of Structural Control* 9.1 (2002), págs. 19-30. DOI: [10.1002/stc.3](https://doi.org/10.1002/stc.3).
- [7] M. C. Constantinou y M. D. Symans. *Experimental and Analytical Investigation of Seismic Response of Structures with Supplemental Fluid Viscous Dampers*. Inf. téc. NCEER-92-0032. NCEER, 1993.
- [8] G. Pekcan, J. B. Manders y S. S. Chen. “Non-Linear Viscous Dampers”. En: *Earthquake Engineering* 1425 (1999), págs. 1405-1425.
- [9] J. S. Hwang, W. C. Lin y N. J. Wu. “Comparison of distribution methods for viscous damping coefficients to buildings”. En: *Structure and Infrastructure Engineering* 9.1 (2013), págs. 28-41. DOI: [10.1080/15732479.2010.513713](https://doi.org/10.1080/15732479.2010.513713).

-
- [10] O. M. Ramirez. *Development and evaluation of simplified procedures for the analysis and design of buildings with passive energy dissipation systems*. Inf. téc. 2000.
- [11] F. H. Bañuelos-García, G. Ayala y S. López. “A displacement-based seismic design procedure for buildings with fluid viscous dampers”. En: 5 (2020), págs. 609-623.
- [12] W. H. Lin y A. K. Chopra. “Earthquake response of elastic single-degree-of-freedom systems with nonlinear viscoelastic dampers”. En: *Journal of Engineering Mechanics* 129.6 (2003), págs. 597-606. DOI: [10.1061/\(ASCE\)0733-9399\(2003\)129:6\(597\)](https://doi.org/10.1061/(ASCE)0733-9399(2003)129:6(597)).
- [13] P. P. Diotallevi, L. Landi y A. Dellavalle. “A methodology for the direct assessment of the damping ratio of structures equipped with nonlinear viscous dampers”. En: *Journal of Earthquake Engineering* 16.3 (2012), págs. 350-373. DOI: [10.1080/13632469.2011.618521](https://doi.org/10.1080/13632469.2011.618521).
- [14] L. Landi, F. Conti y P. P. Diotallevi. “Influence of vertical distribution of damper properties for seismic upgrading of regular and irregular rc frames”. En: 2013.
- [15] M. Di Paola y G. Navarra. “Stochastic seismic analysis of MDOF structures with nonlinear viscous dampers”. En: *Structural Control and Health Monitoring* (2009). DOI: [10.1002/stc](https://doi.org/10.1002/stc).
- [16] FEMA 273. *NEHRP Guidelines for the Seismic Rehabilitation of Buildings*. Inf. téc. 1997.
- [17] FEMA 356. *NEHRP Guidelines for the Seismic Rehabilitation of Buildings*. Inf. téc. Federal Emergency Management Agency, 2000.
- [18] ASCE 7-10. *Minimum Design Loads for Buildings and Other Structures*. 2016.
- [19] L. Landi, S. Lucchi y P. P. Diotallevi. “A procedure for the direct determination of the required supplemental damping for the seismic retrofit with viscous dampers”. En: *Engineering Structures* 71 (2014), págs. 137-149. DOI: [10.1016/j.engstruct.2014.04.025](https://doi.org/10.1016/j.engstruct.2014.04.025).
- [20] NTCDS-23. *Normas Técnicas Complementarias para Diseño por Sismo*. Inf. téc. 2023.
- [21] PERFORM 3D Computers and Structures Inc. (CSI). *Nonlinear Analysis and Performance Assessment for 3D Structures: User Guide*. 2006.
- [22] S. Mazzoni et al. *OpenSees: Open System for Earthquake Engineering Simulation*. Pacific Earthquake Engineering Research Center. 2018.
- [23] W. Ramberg y W. R. Osgood. *Description of Stress-Strain Curves by Three Parameters*. Inf. téc. Technical Note 902. 1943.
- [24] G. M. Del Gobbo, M. S. Williams y A. Blakeborough. “Comparing fluid viscous damper placement methods considering total-building seismic performance”. En: *Earthquake Engineering and Structural Dynamics* 47.14 (2018), págs. 2864-2886. DOI: [10.1002/eqe.3117](https://doi.org/10.1002/eqe.3117).

Compensación dinámica de par mediante identificación en tiempo finito para el control de un péndulo de un grado de libertad

Dynamic torque compensation via finite-time identification for the control of a one-degree-of-freedom pendulum

Alvarez Sánchez, Ervin Jesús^{1*} ; Aldana Franco, Fernando¹ ; Leyva Retureta, José Gustavo¹ ; Sánchez Moreno, Alejandro¹ 

Historial del artículo

Recibido: 25-nov-2025

Aceptado: 30-ene-2026

Publicado: 30-mar-2026

Palabras clave

ES: técnica de Fliess, incertidumbre dinámica, métricas de desempeño, principio de certeza equivalente, aniquilación algebraica

EN: Fliess technique, dynamic uncertainty, performance metrics, certainty equivalence principle, algebraic annihilation

RESUMEN

Este trabajo aborda el problema de la incertidumbre paramétrica en la inercia de sistemas mecánicos no lineales, centrandolo en un péndulo de un solo eslabón sometido a variaciones dinámicas de carga. El objetivo principal es garantizar la robustez del seguimiento de trayectoria mediante la integración de una técnica de identificación algebraica propuesta por Fliess y un esquema de control por par calculado. La metodología se fundamenta en la manipulación de las ecuaciones diferenciales en el dominio complejo de Laplace, aplicando operadores de aniquilación para eliminar la dependencia de las condiciones iniciales desconocidas. Mediante el uso de integrales iteradas, el estimador logra aislar el valor de la inercia en tiempo finito, proporcionando una señal filtrada y robusta ante el ruido sensorial que caracteriza a los sensores reales. Para validar la propuesta, se realizaron simulaciones numéricas en MATLAB con un tiempo de muestreo de un milisegundo, evaluando métricas críticas como el error cuadrático medio (RMSE) y la integral del error absoluto ponderado por el tiempo (ITAE). Los resultados demuestran que el controlador adaptable logra una mejora superior al 68% en la precisión del seguimiento y una reducción del 90% en el error acumulado en comparación con un control nominal de parámetros fijos. El sistema demostró una transición eficiente de perturbaciones internas oscilatorias continuas a respuestas transitorias mínimas de forma triangular, confirmando que la actualización paramétrica en línea permite mantener la estabilidad y el desempeño invariante del lazo cerrado frente a cambios estructurales imprevistos en el hardware operativo.

ABSTRACT

This work addresses the problem of parametric uncertainty in the inertia of nonlinear mechanical systems, focusing the study on a single-link pendulum subjected to dynamic load variations. The main objective is to guarantee trajectory tracking robustness by integrating an algebraic identification technique proposed by Fliess and a computed torque control scheme. The methodology is based on the manipulation of differential equations in the complex Laplace domain, applying annihilation operators to eliminate dependency on unknown initial conditions. Through the use of iterated integrals, the estimator manages to isolate the inertia value in finite time, providing a filtered and robust signal against the sensory noise that characterizes real sensors. To validate the proposal, numerical simulations were performed in MATLAB with a sampling time of one millisecond, evaluating critical metrics such as the root mean square error (RMSE) and the integral of time-weighted absolute error (ITAE). The results demonstrate that the adaptive controller achieves an improvement of over 68% in tracking precision and a 90% reduction in cumulative error compared to a fixed-parameter nominal control. The system demonstrated an efficient transition from continuous oscillatory internal disturbances to minimal triangular-shaped transient responses, confirming that online parametric updating allows for maintaining stability and invariant closed-loop performance in the face of unforeseen structural changes in the operating hardware.

¹ Facultad de Ingeniería Mecánica y Eléctrica. [Universidad Veracruzana](#)

* Autor de correspondencia: ervin.alvarezs@gmail.com



1. Introducción

En la era de la automatización industrial y la robótica de alta precisión, la capacidad de los sistemas mecánicos para ejecutar tareas con errores mínimos es un requisito fundamental. Los sistemas de un grado de libertad (1-GDL) pueden ser ejemplificados por un péndulo simple debido a la facilidad con la que se pueden mostrar conceptos claves [1, 2], por lo que representan la unidad básica de análisis para una vasta gama de mecanismos, desde articulaciones de brazos robóticos y sistemas de apertura de compuertas, hasta estabilizadores de carga en grúas automatizadas. Sin embargo, la transición de los modelos teóricos a la implementación en entornos reales revela una brecha crítica: la presencia de incertidumbres paramétricas y su impacto en el control robusto [3].

La mayoría de las estrategias de control tradicionales, como el PID o el LQR, se sintonizan basándose en parámetros nominales, que son valores constantes obtenidos mediante mediciones estáticas o especificaciones de catálogo del fabricante, tales como la masa del eslabón, la longitud de la barra o el coeficiente de fricción del rodamiento. No obstante, un sistema mecánico real es una entidad dinámica y cambiante [4].

Cuando un controlador se sintoniza para una inercia nominal (J_0), su desempeño está optimizado estrictamente para ese valor, por lo que si el parámetro experimenta una desviación, el comportamiento del sistema en lazo cerrado deja de ser óptimo. Matemáticamente, esto se traduce en un movimiento de los polos del sistema hacia regiones de menor estabilidad, lo que físicamente se manifiesta como aumento del sobrepaso, oscilaciones sostenidas o error en estado estacionario [5].

En aplicaciones de manipulación, un brazo robótico puede llegar a transportar objetos de distintas masas y geometrías, lo que implica que cada nuevo objeto altera instantáneamente la inercia del sistema [6].

2. Metodología

Esta sección se divide en tres pilares fundamentales: primero, la derivación matemática de la dinámica del sistema mediante el formalismo de Euler-Lagrange, identificando la inercia como el parámetro crítico de incertidumbre; segundo, el desarrollo de la técnica de identificación algebraica de Fliess; y finalmente, el diseño del controlador por par calculado.

2.1. Dinámica del Sistema

Se considera un péndulo de 1-GDL. Es usual que se considere un péndulo compuesto por una varilla rígida de longitud L_B , masa m_B e inercia J_B , la cual se mueve bajo un par rotacional τ aplicado a su extremo articulado. Por facilidad se supondrá que es un péndulo simple, es decir, la varilla es de masa e inercia despreciables, conservándose solo como un sólido de longitud L .

La ecuación de movimiento no lineal que describe la dinámica del péndulo es:

$$J\ddot{\theta}(t) + b\dot{\theta}(t) + mgL \sin(\theta(t)) = \tau(t) \quad (1)$$




Figura 1: Representación esquemática del sistema mecánico, comparando (a) el péndulo real con masa y geometría compleja frente al (b) modelo de péndulo simple utilizado para la derivación del modelo dinámico de control.

2.2. Estimación Algebraica de la Inercia

Se emplea la técnica de identificación algebraica propuesta por Fließ [7]. El objetivo central es aislar el parámetro J mediante el uso de operadores de aniquilación. Se define una variable auxiliar de excitación $v(t)$:

$$v(t) = \tau(t) - b\dot{\theta}(t) - mgL \sin(\theta(t)) \quad (2)$$

La ley de estimación algebraica \hat{J} obtenida es:

$$\hat{J}(t) = \frac{\int^{(3)} t^2 v(t) d\tau^3}{2 \int^{(3)} \theta(t) d\tau^3 - 4 \int^{(2)} t\theta(t) d\tau^2 + \int t^2 \theta(t) d\tau} \quad (3)$$


3. Resultados

El desarrollo se llevó a cabo en MATLAB R2022b, empleando una frecuencia de muestreo de 1 kHz ($T_s = 0,001$ s).


Tabla 1: Parámetros físicos del péndulo

Parámetro	Símbolo	Magnitud	Unidades
Masa puntual	m	1	kg
Longitud del brazo	L	0.5	m
Coefficiente de fricción	b	0.1	N·m·s/rad
Inercia (calculada)	J	0.25	kg·m ²
Gravedad	g	9.81	m/s ²

La Fig. 3 muestra la convergencia de la estimación $\hat{J}(t)$ frente a la inercia real del sistema.



(a) Decaimiento libre



(b) Respuesta al escalón

Figura 2: Validación del comportamiento dinámico del péndulo en lazo abierto mediante pruebas de (a) respuesta transitoria ante condiciones iniciales y (b) seguimiento de referencia tipo escalón.




Figura 3: Evolución temporal del parámetro de inercia estimado mediante la técnica de identificación algebraica de Fliess, demostrando la convergencia rápida y robusta hacia el valor real del sistema en tiempo finito.

4. Conclusiones

Se demostró que la técnica de identificación algebraica de Fliess supera las limitaciones de los estimadores asintóticos tradicionales. Los resultados confirman que el control adaptable indirecto logra una invariancia de desempeño”.

Referencias

- [1] D.V. Resende, M.V.G. de Morais y S.M. Avila. “Experimental Analysis of One-Degree-of-Freedom (1DoF) Dynamic System Controlled by Optimized Inverted Pendulum”. En: *Journal of Vibration Engineering and Technologies* 8 (2020), págs. 471-481. DOI: [10.1007/s42417-020-00198-2](https://doi.org/10.1007/s42417-020-00198-2).
- [2] D. G. Tolasa. “Theoretical Analysis of a Simple Pendulum Experiment”. En: *International Journal of Current Research in Science, Engineering and Technology* 8.1 (2025), págs. 214-218. DOI: [10.30967/IJCRSET/Diriba-Gonfa-Tolasa/168](https://doi.org/10.30967/IJCRSET/Diriba-Gonfa-Tolasa/168).
- [3] S. P. Bhattacharyya. “Robust control under parametric uncertainty: An overview and recent results”. En: *Annual Reviews in Control* 44 (2017), págs. 45-77. DOI: [10.1016/j.arcontrol.2017.05.001](https://doi.org/10.1016/j.arcontrol.2017.05.001).
- [4] V. Karlova-Sergieva. “Robust Performance Assessment of Control Systems with Root Contours Analysis”. En: *Cybernetics and Information Technologies* 25.2 (2025), págs. 83-99. DOI: [10.2478/cait-2025-0013](https://doi.org/10.2478/cait-2025-0013).
- [5] Y. Xia et al. “A Cooperative Adaptive VSG Control Strategy Based on Virtual Inertia and Damping for Photovoltaic Storage System”. En: *Energies* 18.6 (2025), pág. 1505. DOI: [10.3390/en18061505](https://doi.org/10.3390/en18061505).
- [6] T. Sands. “Autonomous Real-Time Mass Center Location and Inertia Identification for Grappling Space Robotics”. En: *Technologies* 13.4 (2025), pág. 148. DOI: [10.3390/technologies13040148](https://doi.org/10.3390/technologies13040148).
- [7] M. Fliess y H. Sira-Ramirez. “An algebraic framework for linear identification”. En: *ESAIM: Control, Optimisation and Calculus of Variations* 9 (2003), págs. 151-168. DOI: [10.1016/j.actaastro.2016.11.019](https://doi.org/10.1016/j.actaastro.2016.11.019).

Créditos de los Autores

Alvarez Sánchez, Ervin Jesús: Conceptualización, Metodología, Redacción - borrador original.

Aldana Franco, Fernando: Conceptualización, Validación, Redacción - revisión y edición.

Leyva Retureta, José Gustavo: Metodología, Software, Redacción - revisión y edición.

Sánchez Moreno, Alejandro: Validación, Redacción - revisión y edición.

Aplicación de la ley de Fourier en la fabricación de una mufla

Application of Fourier's law in the manufacture of a muffle

Flores Camo, Rafael¹  ; Galván Chávez, Jorge Moises¹  ; García Enríquez, Irma Josefina¹  ;
Flores Cuautle, Jose de Jesus Agustin²  ; Lara Hernández, Gemima^{1*} 

Historial del artículo

Recibido: 15-dic-2025

Aceptado: 20-feb-2026

Publicado: 30-mar-2026

Palabras clave

ES: conducción térmica, ley de Fourier, materiales refractarios, eficiencia energética

EN: thermal conduction, Fourier law, refractory materials, energy efficiency

RESUMEN

Los hornos de alta temperatura son una herramienta esencial en física y en particular en el área de materiales. El diseño de este tipo de hornos requiere de un adecuado balance entre la temperatura interior, la temperatura exterior, la seguridad y la eficiencia energética. Este trabajo reporta el diseño de un horno compacto, capaz de alcanzar 1100 °C usando energía eléctrica. En los cálculos para el diseño de este horno se empleó la ley de conducción de calor de Fourier, la cual describe la transferencia de calor a través de las paredes del horno. Para el diseño se consideraron ladrillos refractarios, así como resistencias de Kanthal. El diseño obtenido es un horno de tamaño reducido que es capaz de alcanzar altas temperaturas y que resulta ideal como caso de estudio para ilustrar la aplicación de la transferencia de calor en el ambiente académico.

ABSTRACT

High-temperature furnaces are essential tools in physics, particularly in materials science. The design of these furnaces requires a careful balance among internal and external temperatures, safety, and energy efficiency. This paper reports the design of a compact furnace capable of reaching 1100 °C using electricity. The design calculations employed Fourier's law of heat conduction, which describes heat transfer through the furnace walls. Refractory bricks and Kanthal heating elements were considered in the design. The resulting design is a compact furnace capable of reaching high temperatures, making it an ideal case study for illustrating heat transfer in academia.

1. Introducción

En el ámbito de la investigación existen diversos escenarios en los cuales es necesario manejar altas temperaturas (mayores 600 °C), para ello se emplean hornos especialmente diseñados. Los hornos de laboratorio, comúnmente llamados muflas pueden alcanzar temperaturas entre 900 y 1700 °C y son utilizados en tratamiento térmico de materiales, determinación de cenizas, fabricación de cerámicos, entre otras muchas aplicaciones [1].

Una mufla consiste en un espacio destinado para calentar las muestras, dicho espacio está delimitado por material que aísla térmicamente, de esta forma el espacio de calentamiento permanece a una temperatura estable minimizando pérdidas de calor. Las muflas pueden generar calor mediante resistencias eléctricas o mediante combustión, siendo las de combustión las más populares debido a la mayor facilidad para controlar la temperatura de calentamiento.

Las principales partes de las que se componen una mufla incluyen la cámara de calentamiento, puerta de seguridad, resistencias de calentamiento, y control de temperatura. Cada uno de los componentes se elige de acuerdo con la aplicación deseada, así como la temperatura máxima de operación. Una mufla para aplicaciones científicas puede tener costos que van de los 500 hasta los 15,000 USD [2, 3]. En el presente trabajo se describe el diseño y la fabricación de una mufla, con énfasis en los parámetros

¹ División de Estudios de Posgrado e Investigación. [Universidad Tecnológica del Centro de Veracruz](#)

² SECIHTI, Investigadores e investigadoras por México. [Instituto Tecnológico de Orizaba](#)

* Autor de correspondencia: larag_139@hotmail.com



térmicos considerados para el diseño.

1.1. Ley de Fourier

El calor puede ser definido como la energía transferida entre dos objetos entre los cuales exista una diferencia de temperatura. Es importante resaltar que el flujo de energía térmica se da desde el objeto con mayor temperatura hacia el de menor temperatura, este flujo de energía térmica se da en forma continua hasta que ambos cuerpos alcanzan la misma temperatura.

La manera en la que se da el intercambio de calor puede darse mediante tres mecanismos diferentes: conducción, convección, radiación. La conducción se da entre dos cuerpos en contacto directo, la convección requiere que exista un medio que transmita el calor, en tanto que transferencia de calor se da mediante radiación térmica sin que exista un medio físico para el transporte de energía térmica. La transferencia de calor por conducción (Q_{cond}) puede expresarse mediante la Ec. (1) [4].

$$Q_{cond} = -\kappa \cdot \nabla T \quad (1)$$

en donde κ es la conductividad térmica, T la temperatura y ∇ significa la variación espacial de la temperatura. En el caso de un horno se deben de considerar los tres mecanismos de conducción de calor antes descritos. La conducción se da como consecuencia del flujo de calor desde la cámara de calentamiento hacia el recubrimiento exterior. El intercambio de calor por radiación, así como la convección se dan como consecuencia de la interacción de la cubierta exterior con el medio ambiente. La expresión que modela la transferencia de calor por convección (Q_{conv}) es:

$$Q_{conv} = A_{sup} \cdot h(T_{sup} - T_{amb}) \quad (2)$$

en donde A_{sup} el área de la sección transversal del exterior del horno, T_{sup} la temperatura en la superficie del horno, T_{amb} la temperatura ambiente, h el coeficiente de transferencia de calor. En tanto que la Ec. (3) representa la transferencia de calor mediante radiación (Q_{rad})

$$Q_{rad} = A_{sup} \cdot \epsilon \sigma (T_{sup}^4 - T_{amb}^4) \quad (3)$$

en donde ϵ es la emisividad, y σ la constante de Stefan Boltzmann.

2. Metodología

Para poder calcular el espesor de las paredes del horno, debemos de hacer los cálculos a dicha temperatura. Cuando el horno alcanza su máxima temperatura es necesario que se alcance un equilibrio térmico. Dicho equilibrio se da entre el calor que fluye a través de los ladrillos por conducción (Q_{cond}) y el calor que escapa por la cubierta exterior mediante radiación y convección ($Q_{conv} + Q_{rad}$). Finalmente, el calor de radiación y convección debe ser disipado por el aire circundante al horno. Debido a la simetría del horno propuesto, podemos hacer un análisis bidimensional con lo cual la Ec. (1) puede aproximarse a la forma:

$$Q_{cond} = -\kappa \cdot \nabla T \approx k \cdot A_{eff} \frac{T_{in} - T_{sup}}{L} \quad (4)$$

En donde A_{eff} es el área de la sección transversal de la cámara interior y T_{in} la temperatura interior del horno (cámara de calentamiento). En la Figura 1 se puede apreciar el área efectiva (A_{eff}), área superficial (A_{sup}), así como el grosor del aislamiento térmico (L) que se desea calcular. La Tabla 1 muestra los valores de las constantes, así como de los materiales empleados.




Figura 1: Diagrama esquemático de las áreas y longitud del aislamiento que intervienen en el cálculo de la transferencia de calor.

Tabla 1: Constantes termodinámicas empleadas

Constante	Material empleado	Valor	Unidades
κ conductividad térmica	Ladrillo refractario	0.20 @ 1100 °C	$\frac{W}{m \cdot K}$
ϵ emisividad	Acero inoxidable	0.4	adimensional
σ constante de Stefan Boltzmann	-	5.67×10^{-8}	$\frac{W}{m^2 \cdot K^4}$

Debido a que en las ecuaciones de transferencia de calor aparece la temperatura en la superficie del horno, así como la temperatura ambiente, es necesario establecer dichas temperaturas como parámetros en el diseño del horno. La temperatura en la superficie del horno (T_{sup}) se estableció en 50 °C, en tanto que la temperatura ambiente (T_{amb}) se fijó en 25 °C.

Con la finalidad de poder programar un control, es necesario conocer la respuesta del horno, por lo cual se obtuvo la respuesta de la temperatura a una función escalón ($u(t)$) [5]. La temperatura del horno al aplicar la función escalón puede observarse en la Figura 2.

3. Implementación

Para controlar la temperatura del horno, se programó un control PID. Las constantes del control se obtuvieron a partir de la respuesta al escalón del horno $u(t)$. El control se implementó en un Arduino y se empleó una salida PWM para controlar un relevador de estado sólido. El relevador controla la resistencia calefactora [6]. El Listado 1 muestra las constantes del control PID.




Figura 2: Respuesta de la temperatura del horno al aplicarse una función escalón $u(t)$.

Listado 1: Entradas del control PID

```
1 // PID entradas y constantes
2 double Kp = 55; // ganancia proporcional
3 double Ki = 0.012; // ganancia integral
4 double Kd = 60; // ganancia derivativa
```

4. Resultados

La propuesta del diseño del horno puede verse en la Figura 3A, una vez que se ha calculado el espesor del aislamiento se trabajó con las medidas específicas y el diseño fue llevado a un software de diseño CAD (Solid Works) antes de su construcción. También es posible apreciar una imagen real del horno ya fabricado en la Figura 3B donde es posible apreciar la resistencia calefactora en rojo, así como los ladrillos refractarios que constituyen el aislamiento térmico. El espesor de los ladrillos refractarios se obtuvo a partir de las Ecs. (2), (3) y (4). El horno desarrollado tiene 33 cm de altura, 32 cm de fondo y 20 cm de ancho; estas dimensiones permiten que sea fácilmente adaptable a cualquier laboratorio o inclusive que pueda ser empleado en el aula para llevar a cabo demostraciones.

Para comprobar el funcionamiento del horno, se programaron rampas de calentamiento de 10 °C y 20 °C por minuto, hasta alcanzar una temperatura de 800 °C. La Figura 4 muestra la temperatura al interior del horno al programar dichas rampas.

5. Discusión

Entre las características a destacar en el horno desarrollado se puede mencionar que una vez alcanzada la máxima temperatura, el horno necesita aproximadamente 95 W de potencia para mantener dicha temperatura. Adicionalmente, a la máxima temperatura, la temperatura en la superficie del horno es de 50 °C, lo cual no representa mayor peligro siempre y cuando se tengan las medidas de precaución




Figura 3: Temperatura del horno al programarse una tasa de calentamiento de 10 °C/ min. A) diseño concebido, B) imagen del horno en funcionamiento.




Figura 4: Temperatura del horno al programarse una tasa de calentamiento de 10 y 20 °C/ min. Inset detalle de la temperatura en el horno durante los primeros 200 °C.

adecuadas. A partir de la Figura 4 es posible apreciar que a bajas temperaturas el horno presenta mayores diferencias entre la temperatura esperada y la temperatura medida, esto es consecuencia directa del aislamiento en conjunto con la inercia térmica. A pesar de lo anterior, para aplicaciones por encima de los 200 °C el comportamiento de la temperatura es más estable.

Para poder obtener un horno de dimensiones reducidas, fue necesario limitar el volumen de la cámara de calentamiento lo cual limita las aplicaciones de este horno. A pesar de las reducidas dimensiones en la cámara de calentamiento, este horno cumple con el objetivo de proporcionar altas temperaturas tanto para demostraciones escolares como para experimentos con cantidades de muestra reducidas.

6. Conclusiones

El empleo de las ecuaciones de transferencia de calor permite acercar a los estudiantes a la termodinámica. Adicionalmente, ayuda a que el conocimiento vaya más allá de lo teórico y se implemente en la práctica. La aplicación de las ecuaciones en un objeto físico muestra la utilidad de la teoría, así mismo, permite llevar a la práctica los conocimientos vertidos en el aula.

El horno desarrollado permite llevar a cabo prácticas en otras áreas del conocimiento, en las cuales es necesario someter a materiales a altas temperaturas.

Créditos de los Autores

Flores Cuautle, Jose de Jesus Agustin: Conceptualización, Redacción - revisión y edición, Visualización.

Lara Hernández, Gemima: Análisis formal, Metodología, Redacción - borrador original, Visualización.

Flores Camo, Rafael: Investigación, Metodología, Software.

Galván Chávez, Jorge Moises: Investigación, Software, Supervisión.




García Enríquez, Irma Josefina: Validación, Curación de datos.

Referencias

- [1] Jose Jesus Agustin Flores Cuautle. “Caracterización térmica de cerámicas ferroeléctricas y aplicaciones biomédicas de cerámicas con implantes metálicos”. Tesis doctoral. CINVESTAV, 2012.
- [2] Cis-Lab Team. *Mufla de 1200 C*. Accedido: 25 de marzo de 2026. 2026. URL: <https://www.cislab.com.mx/shop/category/equipos-muflas-mufla-de-1200c-91>.
- [3] Carbolite Team. *Hornos de Laboratorio*. Accedido: 25 de marzo de 2026. 2026. URL: <https://www.carbolite.com/es/productos/hornos-de-camara/hornos-de-laboratorio/>.
- [4] Y.A. Çengel y A.J. Ghajar. *Heat and Mass Transfer: Fundamentals & Applications*. McGraw-Hill, 2011. ISBN: 9780073398129.
- [5] K. Ogata. *Modern Control Engineering Plus MATLAB and Simulink Student Version 2010*. Pearson Education, Limited, 2010. ISBN: 9781408264164.
- [6] Massimo Banzi y Michael Shiloh. *Getting started with Arduino: the open source electronics prototyping platform*. Maker Media, Inc., 2022. ISBN: 168045689X.

Enfoques bayesianos para la toma de decisiones bajo incertidumbre en sistemas inteligentes: una revisión multidisciplinaria

Bayesian approaches for decision-making under uncertainty in intelligent systems: a multidisciplinary review

Moran Gonzalez, Miguel¹ ; Salas García, Javier^{1*} ; Albarrán Trujillo, Silvia Edith¹ 

Historial del artículo

Recibido: 20-ene-2026

Aceptado: 15-mar-2026

Disponible en línea: 30-mar-2026

Palabras clave

ES: Inferencia bayesiana, toma de decisiones, redes neuronales bayesianas, ingeniería de procesos, incertidumbre epistémica, sistemas inteligentes

EN: Bayesian inference, decision-making, Bayesian neural networks, process engineering, epistemic uncertainty, intelligent systems

RESUMEN

Este artículo de revisión aborda la evolución del razonamiento en sistemas inteligentes, desde los enfoques deterministas clásicos hacia los paradigmas bayesianos probabilísticos. Se analizan los fundamentos de la toma de decisiones bajo incertidumbre, haciendo énfasis en la distinción entre incertidumbre aleatoria y epistémica, así como en la integración del teorema de Bayes con la teoría de la utilidad. Se exploran modelos avanzados como las redes bayesianas, procesos gaussianos y redes neuronales bayesianas (BNN), destacando técnicas de aproximación práctica como el Monte Carlo Dropout. La revisión culmina con un análisis de aplicaciones críticas en ingeniería química y visión por computadora, consolidando el enfoque bayesiano como un marco robusto para la cuantificación de la incertidumbre en entornos de alto riesgo.

ABSTRACT

This review article explores the evolution of reasoning in intelligent systems, transitioning from classical deterministic approaches to probabilistic Bayesian paradigms. It analyzes the foundations of decision-making under uncertainty, emphasizing the distinction between aleatoric and epistemic uncertainty, as well as the integration of Bayes' theorem with utility theory. Advanced models such as Bayesian networks, Gaussian processes, and Bayesian neural networks (BNNs) are explored, highlighting practical approximation techniques like Monte Carlo Dropout. The review concludes with an analysis of critical applications in chemical engineering and computer vision, establishing the Bayesian approach as a robust framework for uncertainty quantification in high-risk environments.

1. Introducción y contexto

La inteligencia artificial (IA) ha experimentado una transformación profunda en las últimas décadas, transitando desde sistemas basados en reglas deterministas hacia enfoques que incorporan de manera explícita la incertidumbre como componente central del razonamiento. Este cambio paradigmático tiene raíces tanto en las limitaciones computacionales de los modelos clásicos como en la complejidad inherente de los entornos reales en que operan los sistemas inteligentes.

1.1. El problema de la incertidumbre en los sistemas inteligentes

Los primeros sistemas expertos de la década de 1980, como MYCIN y PROSPECTOR, ya evidenciaban la necesidad de representar el conocimiento incierto mediante mecanismos como los factores de certeza y las razones de probabilidad bayesiana. Sin embargo, dichos mecanismos producían resultados anómalos e impredecibles en situaciones complejas [1]. Este fracaso motivó una reorientación de la investigación hacia el razonamiento probabilístico formal, en particular hacia la inferencia bayesiana como fundamento teórico para la representación y propagación de la incertidumbre.

¹ Facultad de Ingeniería. Universidad Autónoma del Estado de México

* Autor de correspondencia: proyectos@javiersalasg.com



Dietterich [2] ofrece una caracterización histórica de esta evolución en tres periodos: el periodo de los sistemas basados en conocimiento simbólico (pre-1980), el periodo de los *known unknowns* (1980 hasta la actualidad) dominado por modelos gráficos probabilísticos, y el periodo emergente de los *unknown unknowns*, en el que la robustez ante fenómenos no modelados se convierte en el problema central. En este último periodo, la obra seminal de Judea Pearl sobre redes bayesianas resultó determinante para establecer las bases computacionales del razonamiento probabilístico en IA [3].

La distinción fundamental entre incertidumbre *aleatoria* (variabilidad irreducible inherente al fenómeno) e incertidumbre *epistémica* (debida a la ignorancia o información incompleta del modelo) constituye el punto de partida para todo enfoque bayesiano moderno [4]. Esta distinción no es meramente filosófica: tiene implicaciones directas sobre la estrategia de inferencia, la selección del modelo y el diseño de sistemas de apoyo a la toma de decisiones.

1.2. De los enfoques deterministas a los probabilísticos

En los sistemas de control, diagnóstico de fallas y aprendizaje automático, la transición desde modelos deterministas hacia representaciones probabilísticas ha permitido cuantificar el grado de confianza en las predicciones y detectar regiones del espacio de entrada donde el modelo opera fuera de su dominio de entrenamiento [5]. Greenberg et al. [6] documentan cómo los modelos de red bayesiana superan a los modelos de probabilidad condicional exhaustivos en sistemas de infraestructura de gran escala, al factorizar distribuciones conjuntas de dimensión elevada aprovechando las independencias condicionales entre variables.

En el ámbito de la ingeniería de sistemas complejos, Glavind et al. [7] desarrollan un marco bayesiano probabilístico para la representación de sistemas industriales, combinando promedios de modelos bayesianos (*Bayesian model averaging*) con selección de modelos específica al contexto de decisión. Su aplicación al modelado de cargas ambientales en plataformas marinas demuestra que los procesos gaussianos para modelar discrepancias entre modelos permiten capturar incertidumbres de múltiples fuentes de forma coherente.

La integración de redes bayesianas dinámicas (DBN) con el paradigma de gemelo digital (*digital twin*) representa una dirección de frontera en la que la actualización continua de parámetros y la cuantificación de incertidumbre se combinan para el pronóstico de daños en sistemas físicos [8]. Esta convergencia ilustra la manera en que los fundamentos probabilísticos del enfoque bayesiano trascienden dominios específicos para convertirse en infraestructura metodológica transversal.

1.3. Relevancia contemporánea

El contexto actual de aplicaciones de IA en sistemas de alto riesgo —conducción autónoma, gestión de redes eléctricas, diagnóstico médico, control de procesos industriales— exige que los sistemas inteligentes sean capaces de comunicar su grado de confianza junto con sus predicciones [2]. Los enfoques bayesianos proveen el marco formal para satisfacer este requisito, al modelar explícitamente las distribuciones de probabilidad sobre los parámetros del modelo y las predicciones. En este sentido, la revisión que se presenta en las secciones siguientes examina críticamente el estado del arte en modelos bayesianos para la toma de decisiones bajo incertidumbre, desde sus fundamentos formales hasta sus aplicaciones en ingeniería química e inteligencia artificial, pasando por las limitaciones computacionales y las tendencias

emergentes.

2. Fundamentos de la toma de decisiones bajo incertidumbre

La teoría formal de la decisión bajo incertidumbre constituye el andamiaje matemático sobre el que se construyen los enfoques bayesianos en sistemas inteligentes. Su núcleo conceptual descansa sobre dos distinciones fundamentales: la separación entre incertidumbre aleatoria y epistémica, y la representación del valor de los resultados mediante funciones de utilidad.

2.1. Tipos de incertidumbre

La distinción entre incertidumbre *aleatoria* (*aleatoric*) e incertidumbre *epistémica* (*epistemic*) es operacionalmente determinante en cualquier sistema de decisión inteligente. La primera refleja la variabilidad irreducible del fenómeno; la segunda, la ignorancia del modelador, y es por tanto reducible mediante la adquisición de información adicional [9]. Sakalli [10] formaliza esta taxonomía en el contexto de la programación estocástica con restricciones probabilísticas, señalando que la incertidumbre epistémica puede modelarse tanto por teoría de probabilidad clásica como por teorías generalizadas de la información (teoría de posibilidades, lógica difusa, teoría de evidencia de Dempster–Shafer). Weiss y Tonella [11] extienden esta distinción al dominio del aprendizaje profundo, mostrando que los supervisores de redes neuronales basados en estimación de incertidumbre permiten diseñar sistemas más seguros cuando se identifican por separado las contribuciones aleatoria y epistémica al error de predicción.

Desde la perspectiva de la psicología computacional, Hedley et al. [9] demuestran que la descomposición de incertidumbre heredada de la teoría de decisión bayesiana puede trasladarse a marcos de cuantificación de la ansiedad, lo que ilustra la transversalidad del formalismo. La distinción ha sido también adoptada en sistemas de aprendizaje automático para mejorar la interpretabilidad de las predicciones y construir modelos más confiables en dominios de alto riesgo [12]. Ver Figura 1 para una representación visual de este concepto.

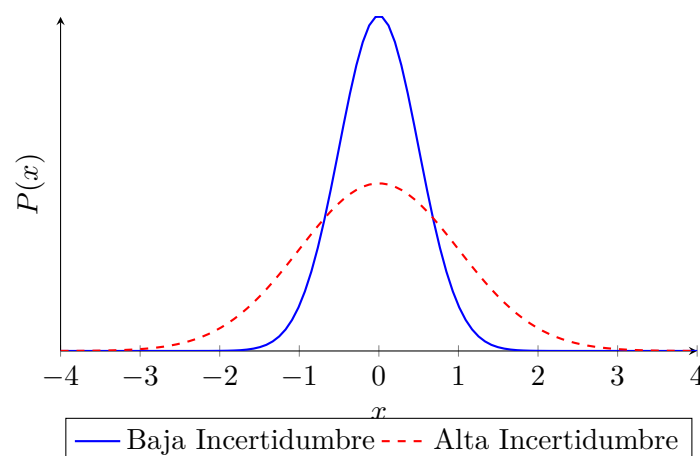


Figura 1: Representación de la incertidumbre epistémica: al adquirir más datos, la distribución posterior se concentra (curva azul), reduciendo la ignorancia sobre el parámetro.

2.2. Teoría de utilidad y valor esperado

La teoría de la utilidad esperada (EUT, por sus siglas en inglés) constituye el marco normativo canónico para la toma de decisiones racionales bajo incertidumbre. En ella, un agente selecciona la acción que maximiza la utilidad esperada de los resultados, ponderando cada resultado por su probabilidad de ocurrencia [13]. Las extensiones de la EUT incluyen la teoría de la perspectiva (*prospect theory*), que incorpora sesgos cognitivos como la aversión a las pérdidas; la teoría de decisión robusta, que optimiza bajo un conjunto de escenarios posibles; y los árboles de decisión, que permiten la descomposición secuencial de problemas complejos.

Yan et al. [14] proponen una extensión de la EUT que incorpora la incertidumbre epistémica sobre los valores de los atributos mediante la teoría de evidencia de Dempster–Shafer, definiendo índices cuantitativos de incertidumbre en la utilidad esperada de cada alternativa y construyendo criterios de decisión diferenciados para agentes adversos al riesgo, neutros al riesgo y propensos al riesgo. Este enfoque aborda directamente la limitación de la EUT clásica, que ignora el impacto de la incertidumbre epistémica en el proceso de elección.

En el contexto de la ingeniería de sistemas, Aspen et al. [15] aplican la teoría de utilidad multiatributo (MAUT) y los modelos de creencia bayesianos para estructurar decisiones de adquisición de tecnologías en sistemas marinos con múltiples criterios en conflicto. Su enfoque ilustra cómo los modelos probabilísticos—incluyendo redes de creencia bayesianas— pueden formalizarse como herramientas de soporte a la decisión cuando los criterios de utilidad son heterogéneos y la información disponible es parcial o incierta.

2.3. Marcos formales para sistemas inteligentes

Payandeh y Haldorai [13] ofrecen una revisión sistemática de los paradigmas de decisión bajo incertidumbre, destacando el análisis de decisión bayesiano como el enfoque que integra más coherentemente la teoría de la inferencia con la teoría de la utilidad. En dicho marco, las probabilidades previas (*prior*) se actualizan mediante el teorema de Bayes al recibir nueva evidencia, produciendo probabilidades posteriores (*posterior*) que alimentan la función de utilidad esperada para guiar la elección de acciones. Esta arquitectura de dos etapas—inferencia seguida de decisión—es la base de los Procesos de Decisión de Markov Parcialmente Observables (POMDP), uno de los marcos formales más completos para agentes autónomos que operan en entornos estocásticos con observaciones ruidosas [16].

Grandori [17] examina el caso límite de la incertidumbre “radical”—aquella que viola los supuestos de mensurabilidad bayesiana—y arguye que los modelos constructivistas de racionalidad epistémica son necesarios cuando no es posible asignar distribuciones de probabilidad a los estados desconocidos. Este debate delimita el alcance de los enfoques bayesianos y señala sus condiciones de aplicabilidad.

3. Fundamentos de inferencia bayesiana

La inferencia bayesiana proporciona un marco matemáticamente coherente para actualizar el conocimiento de un agente a medida que llega nueva evidencia. Su núcleo es el teorema de Bayes, que expresa la distribución posterior de un parámetro o hipótesis θ dado el conjunto de datos observados D

mediante la relación:

$$P(\theta | D) = \frac{P(D | \theta) P(\theta)}{P(D)}, \quad (1)$$

donde $P(\theta)$ es la distribución previa (*prior*), $P(D | \theta)$ es la función de verosimilitud y $P(D)$ es la evidencia marginal, que actúa como constante de normalización. Esta ecuación sintetiza la actualización de creencias y conecta el conocimiento anterior con la información empírica. El proceso se ilustra en la Figura 2.

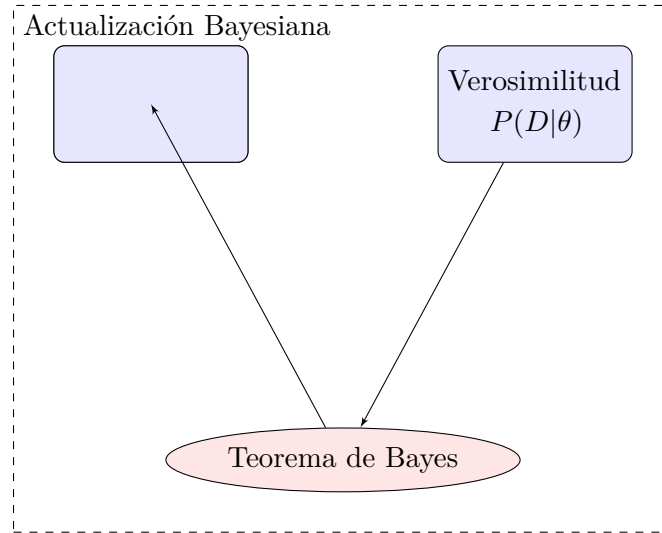


Figura 2: Esquema conceptual del proceso de actualización bayesiana: integración de conocimiento previo y evidencia empírica.

3.1. Modelos gráficos probabilísticos

Los modelos gráficos probabilísticos (PGM) constituyen la principal herramienta computacional para implementar la inferencia bayesiana en problemas de alta dimensión. En su variante dirigida, las redes bayesianas (BN) representan la distribución conjunta de un conjunto de variables aleatorias $\{Z_1, \dots, Z_n\}$ como el producto de distribuciones condicionales locales, aprovechando las independencias condicionales codificadas en un grafo acíclico dirigido (DAG) [18]:

$$P(Z_1, \dots, Z_n) = \prod_{i=1}^n P(Z_i | \text{padres}(Z_i)). \quad (2)$$

Esta factorización hace computacionalmente tratable la inferencia en dominios que de otro modo requerirían tablas de probabilidad de tamaño exponencial.

Kohler et al. [19] introducen un enfoque novedoso que traduce ecuaciones diferenciales parciales en redes bayesianas dinámicas discretas (DBN) para la estimación de parámetros. Su metodología permite aplicar el arsenal completo de algoritmos de inferencia en PGM—incluyendo el algoritmo de filtrado de Boyen–Koller—a problemas de inferencia en modelos de fenómenos físicos continuos, con aplicación directa a sistemas de ingeniería.

3.2. Actualización de creencias y razonamiento probabilístico

La actualización de creencias es el proceso mediante el cual un agente revisa sus probabilidades previas al recibir nueva evidencia. Gupta et al. [20] investigan experimentalmente las propiedades de la actualización bayesiana en sistemas de visualización de datos, concluyendo que las creencias posteriores obedecen de forma aproximada las predicciones del marco bayesiano, aunque exhiben fenómenos de *decay* (regresión hacia la distribución previa) cuando el intervalo temporal entre la observación y la evaluación posterior se prolonga. Este hallazgo tiene implicaciones directas para el diseño de sistemas de apoyo a la decisión que operan en tiempo real.

En el contexto de la ingeniería de procesos, Wang et al. [21] aplican redes bayesianas combinadas con análisis de componentes principales semiparamétrico (Semiparametric PCA) para el diagnóstico de fallas en sistemas de proceso. La red bayesiana actúa en una segunda etapa, utilizando el resultado del PCA como evidencia para actualizar las probabilidades de causa raíz mediante razonamiento deductivo y abductivo, demostrando que la inferencia bayesiana puede integrarse con herramientas de detección de anomalías propias de la ingeniería química de proceso.

3.3. Métodos computacionales para la inferencia posterior

El cálculo de la distribución posterior es en general intratable de forma analítica cuando el espacio de parámetros es continuo y de alta dimensión. Los métodos de Monte Carlo por Cadena de Markov (MCMC) resuelven este problema generando muestras de la distribución posterior sin necesidad de calcular explícitamente la evidencia marginal $P(D)$ [22]. Como alternativa determinista, la inferencia variacional (*variational inference*) aproxima la distribución posterior real $p(\theta | D)$ mediante una familia de distribuciones parametrizadas $q(\theta)$, minimizando la divergencia de Kullback–Leibler entre ambas [23]. Esta aproximación es significativamente más rápida que MCMC y ha sido adoptada masivamente en modelos de aprendizaje profundo bayesianos.

Simon et al. [24] demuestran la aplicabilidad del marco de inferencia bayesiana en el monitoreo de salud estructural (SHM), donde los parámetros de un modelo físico se estiman secuencialmente conforme llegan nuevas mediciones. El proceso de *Bayesian model updating* permite obtener distribuciones posteriores de los parámetros inciertos del sistema que son coherentes tanto con el conocimiento previo de ingeniería como con los datos de campo, produciendo intervalos de credibilidad que capturan la incertidumbre total de la predicción.

3.4. Selección de distribuciones previas

La elección de la distribución previa $P(\theta)$ es uno de los aspectos más debatidos del enfoque bayesiano, pues puede tener un impacto significativo en la distribución posterior cuando los datos son escasos. Fortuin [25] ofrece una revisión exhaustiva de las distribuciones previas propuestas para modelos de aprendizaje profundo bayesianos—incluyendo procesos gaussianos profundos, autoencoders variacionales y redes neuronales bayesianas—y documenta que la práctica común de utilizar distribuciones gaussianas estándar vagas puede conducir a comportamientos patológicos del modelo. Este trabajo establece criterios para la especificación de previas informativas y semidatos, sentando las bases para una práctica bayesiana más rigurosa en sistemas de IA.

De Pretis et al. [26] proponen el marco *E-Synthesis*, que combina principios filosóficos de la

epistemología bayesiana con técnicas de inteligencia artificial para la evaluación de evidencia sobre seguridad farmacológica. Los factores de Bayes aprendidos de datos históricos se utilizan para actualizar creencias sobre causalidad adversa, ilustrando cómo la inferencia bayesiana puede formalizarse computacionalmente para la integración de evidencia heterogénea en dominios regulados.

En el ámbito de la ingeniería geotécnica y de procesos, Li et al. [27] aplican el método de actualización bayesiana con simulación de subconjuntos (BUS) para el análisis probabilístico inverso de parámetros geomecánicos inciertos en un proyecto de tunelización, demostrando que la inferencia bayesiana secuencial—alimentada con datos de monitoreo en serie temporal—puede actualizar la confiabilidad estructural en tiempo real.

4. Modelos bayesianos en sistemas inteligentes

Los modelos bayesianos en sistemas inteligentes abarcan un conjunto diverso de arquitecturas probabilísticas diseñadas para representar, aprender e inferir sobre dominios inciertos. Entre los más empleados se encuentran las redes bayesianas (BN), los procesos gaussianos (GP), los modelos de mezcla bayesianos y la inferencia variacional. Cada uno ofrece un balance diferente entre expresividad, eficiencia computacional y capacidad para incorporar conocimiento previo. La Tabla 1 resume las características de los principales enfoques analizados.

Tabla 1: *Comparativa de modelos bayesianos en sistemas inteligentes.*

Modelo	Aplicación Principal	Ventajas	Limitaciones
Redes Bayesianas (BN)	Diagnóstico, causalidad	Manejo de datos faltantes, explicabilidad	Explosión combinatoria en grafos densos
Procesos Gaussianos (GP)	Optimización, regresión	Incertidumbre calibrada, no paramétrico	Escalabilidad cúbica $O(n^3)$
Redes Neuronales Bayesianas (BNN)	Visión, segmentación aérea	Robustez ante datos fuera de distribución	Inferencia aproximada requerida (Dropout/VI)
Procesos de Decisión de Markov (POMDP)	Robótica, agentes	Planificación bajo observabilidad parcial	Complejidad PSPACE-completa

4.1. Redes bayesianas: estructura y aprendizaje

Las redes bayesianas son modelos gráficos probabilísticos que codifican la distribución conjunta de un conjunto de variables mediante un grafo acíclico dirigido (DAG), en el que cada nodo almacena la distribución condicional de la variable dado su conjunto de padres [28]. Su principal ventaja radica en la capacidad de combinar datos con conocimiento experto tanto a nivel estructural (el DAG) como paramétrico (las distribuciones condicionales), lo que las convierte en una herramienta especialmente poderosa para dominios donde los datos son escasos pero el conocimiento del dominio es rico. El

aprendizaje de la estructura del DAG a partir de datos—conocido como aprendizaje estructural—constituye un problema NP-difícil en el caso general, por lo que en la práctica se recurre a algoritmos de propagación de creencias como la eliminación de variables o la propagación por árboles de unión (*junction trees*) [29]. Raza et al. [30] aplican BN entrenadas mediante algoritmos MCMC con muestreador Metropolis–Hastings mejorado para la inferencia de estructuras de dependencia en índices de sequía multivariados, demostrando que el marco bayesiano permite integrar fuentes de datos de diversas escalas temporales de forma estadísticamente coherente.

Las redes bayesianas híbridas—que permiten mezclar nodos discretos y continuos con distribución gaussiana multivariada—superan las limitaciones de las versiones puramente discretas al evitar la pérdida de información asociada a la discretización de variables continuas [31]. Sulaiman et al. [32] integran BN con el proceso analítico jerárquico difuso (FAHP) para determinar la condición de tuberías subsea, transformando las percepciones cualitativas de expertos en tablas de probabilidad condicional cuantitativas, un ejemplo paradigmático de elicitación de distribuciones previas en entornos industriales.

4.2. Procesos gaussianos

Los procesos gaussianos (GP) son modelos no paramétricos que definen una distribución de probabilidad sobre funciones, de modo que cualquier conjunto finito de evaluaciones sigue una distribución gaussiana multivariada. Su formulación bayesiana permite obtener distribuciones posteriores sobre la función objetivo—no solo predicciones puntuales— junto con intervalos de credibilidad calibrados [33]. Esta característica los hace especialmente atractivos cuando los datos son costosos de obtener, pues la función de adquisición del proceso gaussiano guía la exploración del espacio de parámetros balanceando exploración y explotación.

La revisión de Shireen [34] sobre optimización bayesiana en modelado de polímeros muestra que los GP como modelos sustitutos (*surrogate models*) permiten navegar espacios de parámetros de alta dimensión en simulaciones de dinámica molecular de grano grueso, integrando técnicas de aprendizaje activo para reducir el número de simulaciones necesarias. Lin y Kim [35] desarrollan una extensión de los GP al marco de regresión multikernels, donde la selección del conjunto de efectos relevantes se realiza mediante inferencia variacional bayesiana con previas de tipo Ising, demostrando que el enfoque es tratable computacionalmente en espacios de alta dimensión mediante un algoritmo de Bayes variacional eficiente.

4.3. Modelos de mezcla bayesianos e inferencia variacional no paramétrica

Los modelos de mezcla gaussiana bayesianos representan distribuciones complejas y multimodales como combinaciones ponderadas de gaussianas, donde el número de componentes puede inferirse directamente de los datos mediante procesos de Dirichlet [36]. Zhou y Wang [36] proponen un marco de mezcla gaussiana no paramétrico combinado con inferencia variacional en línea (*online variational inference*) capaz de escalar a conjuntos de datos de gran tamaño, aplicándolo a la agrupación de escenas (*scene clustering*) mediante la integración con redes convolucionales para la extracción de características. Este enfoque ilustra cómo la aproximación variacional resuelve el cuello de botella computacional del MCMC en aplicaciones de visión por computadora.

Alroobaea et al. [37] presentan un marco de inferencia bayesiana para modelos de mezcla gaussiana

generalizada acotada, aplicado a la clasificación de imágenes biomédicas (retinopatía diabética y cáncer de mama), documentando que la inferencia bayesiana supera a la estimación de máxima verosimilitud cuando los datos están acotados y el modelo debe cuantificar la incertidumbre de clasificación.

4.4. Modelos jerárquicos bayesianos

Los modelos jerárquicos bayesianos (HBM) organizan los parámetros en múltiples niveles, permitiendo que los datos de grupos distintos informen mutuamente las estimaciones a través de hiperparámetros compartidos. Li et al. [38] modelan el aprendizaje de funciones en humanos como inferencia bayesiana jerárquica sobre los hiperparámetros de un proceso gaussiano, logrando capturar tanto la forma de las funciones aprendidas individualmente como el proceso meta-aprendizaje que ajusta las expectativas sobre familias de funciones. En el campo de la inversión geofísica, Feng [39] introduce una estructura jerárquica en las redes neuronales bayesianas (BNN) donde la media y desviación estándar de las distribuciones previas sobre los parámetros de la red se muestrean de hiperprevias, eliminando la necesidad de ajustar manualmente estos valores y logrando estimaciones consistentes de incertidumbre aleatoria y epistémica independientemente de la hiperprevia elegida.

5. Integración con inteligencia artificial y aprendizaje automático

La integración entre la inferencia bayesiana y el aprendizaje automático moderno ha generado el campo conocido como *Bayesian Machine Learning* y, más específicamente, el *Bayesian Deep Learning* (BDL). La motivación central es suplir la carencia de los modelos de aprendizaje profundo deterministas: aunque pueden alcanzar precisión notable en condiciones conocidas, no producen estimaciones calibradas de incertidumbre y exhiben sobreconfianza ante datos fuera de la distribución de entrenamiento (*out-of-distribution*). Los enfoques bayesianos remedian esto al mantener distribuciones de probabilidad sobre los pesos de la red en lugar de valores puntuales.

5.1. Redes neuronales bayesianas

Las redes neuronales bayesianas (BNN) extienden las redes neuronales estándar al tratar cada peso w como una variable aleatoria con distribución previa $P(w)$. El entrenamiento consiste en inferir la distribución posterior $P(w | D)$ dado el conjunto de datos D , y la predicción se realiza mediante integración sobre todos los pesos posibles—lo que en la práctica requiere métodos aproximados [40]. Los tres enfoques dominantes son: (i) MCMC, exacto pero intratable para redes con millones de parámetros; (ii) inferencia variacional con reparametrización (*Bayes by Backprop*), que minimiza la divergencia KL entre la aproximación $q(w)$ y la posterior real; y (iii) Monte Carlo Dropout (MC Dropout), que interpreta la operación de dropout activa en tiempo de inferencia como inferencia variacional de Bernoulli, un resultado seminal de Gal y Ghahramani [41].

La arquitectura Bayesian U-Net ha demostrado especial utilidad en tareas de segmentación de imágenes médicas, produciendo mapas de incertidumbre geométrica que permiten el control de calidad automático de las segmentaciones [41]. Mojiri Forooshani et al. [40] desarrollan una red convolucional 3D bayesiana para segmentación de hiperintensidades de sustancia blanca, logrando un coeficiente Dice de $0,89 \pm 0,08$ y demostrando robustez frente a perturbaciones adversariales de la señal de resonancia magnética.

5.2. Monte Carlo Dropout como aproximación bayesiana práctica

El MC Dropout ha emergido como la técnica más adoptada en la práctica industrial y científica para añadir cuantificación de incertidumbre a redes profundas sin modificar sustancialmente la arquitectura. Jiang et al. [42] documentan, en un estudio empírico a gran escala con 11 métricas de incertidumbre en redes neuronales profundas, que las métricas basadas en entropía predictiva y métodos ensemble caracterizan mejor la validez de las entradas de prueba, estableciendo guías para el diseño de sistemas de prueba guiados por incertidumbre (*uncertainty-guided testing*). Scalco et al. [43] realizan una comparación sistemática entre MC Dropout, MC DropConnect y métodos ensemble para segmentación multiclase de imágenes de tomografía computarizada, concluyendo que la elección del método depende de la propensión al riesgo requerida por la aplicación—un resultado con implicaciones directas para el diseño de sistemas de IA en entornos clínicos.

Lee y Kim [44] aplican BNN con MC Dropout a la cuantificación de metabolitos en espectroscopía de resonancia magnética de protón ($^1\text{H-MRS}$), obteniendo correlaciones entre el error real del modelo y la incertidumbre predicha de $r = 0,83 \pm 0,06$ ($p < 0,001$), lo que valida la calibración del estimador bayesiano en una aplicación biomédica cuantitativa.

5.3. Métodos ensemble como alternativa no bayesiana calibrada

Los métodos ensemble—que entrenan múltiples redes con inicializaciones o datos diferentes y promedian sus predicciones—constituyen la principal alternativa no bayesiana para la estimación de incertidumbre. Wyatt et al. [45] demuestran que los ensembles son más estables en su calibración ante cambios de distribución en datos de clasificación de imágenes marinas, superando a MC Dropout en entornos no vistos durante el entrenamiento. Este resultado subraya que la elección entre métodos bayesianos y de ensemble debe considerar la naturaleza del desplazamiento distribucional esperado en el dominio de aplicación.

5.4. Modelos bayesianos en aprendizaje secuencial y emulación

La combinación de MC Dropout con arquitecturas LSTM variacional ha abierto nuevas posibilidades para la emulación bayesiana de modelos físicos costosos. Van Katwyk et al. [46] introducen un emulador LSTM variacional para la contribución de la capa de hielo antártica al nivel del mar, comparándolo con emuladores basados en procesos gaussianos y demostrando que el emulador neuronal produce estimaciones de incertidumbre más precisas y es significativamente más rápido de entrenar. Zhang et al. [47] aplican redes neuronales artificiales con MC Dropout (ANN_MCD) al modelado de propiedades de suelos blandos, generando intervalos de credibilidad al 95 % que son consistentes con los datos de monitoreo de campo, mostrando la viabilidad del enfoque en geomecánica aplicada.

5.5. Priors en aprendizaje profundo bayesiano

Fortuin [48] presenta una revisión exhaustiva de las distribuciones previas propuestas para tres familias de modelos de aprendizaje profundo bayesiano: procesos gaussianos profundos, autoencoders variacionales (VAE) y redes neuronales bayesianas. El autor documenta que la práctica habitual de usar previas gaussianas estándar vagas puede conducir a comportamientos patológicos—incluyendo posteriors que no convergen y predicciones mal calibradas—y propone un programa de investigación

para el desarrollo de previas informativas basadas en conocimiento del dominio o aprendidas de los datos mediante *meta-learning*.

6. Aplicaciones en sistemas inteligentes

Los enfoques bayesianos han encontrado aplicación en una amplia gama de dominios de los sistemas inteligentes. Esta sección se organiza en dos grandes bloques, priorizando las aplicaciones en ingeniería química —área de particular relevancia para el presente trabajo— seguidas de las aplicaciones en inteligencia artificial general.

6.1. Aplicaciones en ingeniería química

6.1.1. Optimización bayesiana de procesos y transiciones de producto

Flores-Tlacuahuac y Fuentes-Cortés [49] proponen un enfoque bayesiano basado en datos para la optimización de transiciones dinámicas de producto en la industria de procesos, resolviendo el problema sin necesidad de un modelo matemático de primeros principios. El algoritmo de optimización bayesiana (BO) utiliza un modelo sustituto probabilístico que gestiona las mediciones ruidosas y los espacios de decisión continuos, encontrando trayectorias de control suaves que satisfacen los requisitos de composición del producto. Los resultados son comparables en calidad con los obtenidos mediante optimización gradiente clásica, pero con la ventaja de no requerir derivadas ni un modelo mecánico del proceso. La arquitectura de este ciclo iterativo se presenta en la Figura 3.

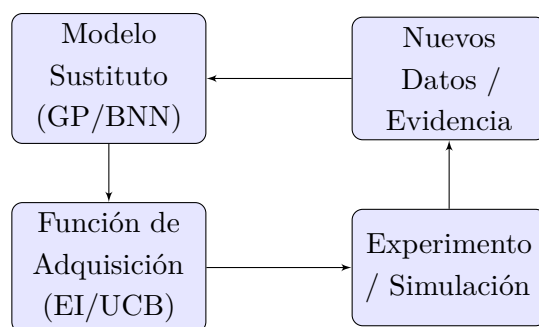


Figura 3: Diagrama de la arquitectura de Optimización Bayesiana (BO): ciclo iterativo para navegación eficiente en espacios de alta dimensión.

Morlet-Espinosa y Flores-Tlacuahuac [50] extienden la optimización bayesiana al dominio de los problemas de programación no lineal entera mixta con datos (*data-driven MINLP*), un tipo de problema frecuente en síntesis de procesos y programación de operaciones en la ingeniería química. Mediante un análisis comparativo de modelos sustitutos, funciones de adquisición y funciones kernel, los autores concluyen que los procesos gaussianos dispersos (*sparse GP*) en combinación con funciones de adquisición computacionalmente económicas ofrecen el mejor rendimiento para problemas con funciones ruidosas y comportamiento estocástico.

Liang et al. [51] presentan CAPBO (*Cost-Aware Parallelized Bayesian Optimization*), un método diseñado específicamente para la optimización de reacciones químicas en microreactores paralelos. El enfoque cambia el objetivo de minimizar el número de iteraciones al de minimizar el costo experimental

total, y la paralelización en el marco bayesiano permite explotar de forma simultánea múltiples evaluaciones experimentales. Los resultados en casos de estudio demuestran mejoras significativas en la eficiencia de optimización frente a BO secuencial tradicional.

6.1.2. Diseño experimental bayesiano y reacciones químicas

Schwaller et al. [52] revisan el estado del arte del uso de inteligencia de máquinas para la exploración del espacio de reacciones químicas, dedicando una sección específica a la optimización bayesiana como herramienta para el diseño de experimentos iterativo. Los autores documentan que BO ha superado a expertos humanos en la identificación de condiciones óptimas de reacción en sistemas de catálisis, y que su integración con plataformas robóticas autónomas permite reducir drásticamente el tiempo de desarrollo de nuevos catalizadores. Este trabajo establece el nexo entre la inferencia bayesiana y la química computacional experimental.

Gisberg et al. [53] ofrecen una revisión sistemática de la aplicación de BO en bioingeniería de procesos—incluyendo optimización de procesos de fermentación, diseño de experimentos de producción de mRNA in vitro y optimización de reacciones de deslignificación de madera—comparando BO con el diseño de experimentos clásico (DoE). Los autores concluyen que BO proporciona modelos más precisos cerca del óptimo cuando los datos son escasos, aunque su ventaja sobre DoE depende de la elección del diseño inicial y del nivel de ruido experimental.

6.1.3. Predicción de propiedades de materiales y polímeros

Kim [54] revisa el uso de métodos de aprendizaje automático basados en procesos gaussianos dispersos para la predicción acelerada de propiedades de materiales energéticos, incluyendo baterías, electrocatalizadores y celdas solares. Los GP con simetría equivariante permiten incorporar invariantes físicas en la función kernel, mejorando la extrapolación a espacios químicos no vistos durante el entrenamiento. La integración con estrategias de aprendizaje activo bayesiano reduce el número de cálculos de teoría del funcional de la densidad (DFT) necesarios para la optimización de materiales en varios órdenes de magnitud.

Shireen [55] revisa la aplicación de BO con sustitutos GP para la parametrización automatizada de modelos de grano grueso (CG) en simulaciones de polímeros, demostrando que el ciclo de optimización bayesiano permite navegar espacios de parámetros de alta dimensión con mínimo número de simulaciones de dinámica molecular. El autor presenta casos de estudio para electrolitos, copolímeros de bloque y resinas epoxi, y discute plataformas autónomas de diseño inverso como SPACIER and PAL 2.0.

6.1.4. Diagnóstico de fallas y seguridad de procesos

Wang et al. [56] aplican redes bayesianas combinadas con PCA semiparamétrico para el diagnóstico de fallas en sistemas de proceso, utilizando el razonamiento abductivo de la red bayesiana para identificar causas raíz a partir de mediciones de proceso en sistemas con correlaciones no gaussianas y no monótonas. La red bayesiana, alimentada con los resultados del PCA como evidencia, actualiza la

probabilidad de cada hipótesis de falla mediante el teorema de Bayes, constituyendo un sistema de diagnóstico inteligente para entornos industriales químicos complejos.

Sulaiman et al. [57] integran BN con el proceso analítico jerárquico difuso para determinar la condición de tuberías submarinas, transformando la incertidumbre subjetiva de los expertos en tablas de probabilidad condicional cuantitativas mediante el método de descomposición de FAHP. Esta metodología permite tomar decisiones de mantenimiento basadas en probabilidades coherentes aun cuando los datos históricos de falla son escasos, como ocurre frecuentemente en infraestructuras de proceso marinas.

6.2. Aplicaciones en inteligencia artificial general

6.2.1. Visión por computadora y segmentación de imágenes

Mojiri Forooshani et al. [58] aplican redes convolucionales bayesianas 3D con arquitectura U-Net para la segmentación automática de hiperintensidades de sustancia blanca en resonancia magnética multicentro, produciendo mapas de incertidumbre que sirven como indicadores de control de calidad automático. El modelo demuestra robustez ante casos adversariales clínicos que simulan baja relación señal-ruido, baja resolución y diferente contraste de imagen, aspectos críticos para la generalización de sistemas de visión médica.

Wang et al. [59] proponen UGCFNet, una red de fusión cruzada de capas guiada por incertidumbre para la segmentación de imágenes de tomografía de coherencia óptica (OCT) retiniana, en la que la incertidumbre bayesiana calculada en múltiples etapas del encoder-decoder dirige la atención de la red hacia las regiones de mayor complejidad. La función de pérdida bayesiana mejorada y la fusión cruzada de características permiten alcanzar coeficientes Dice de 79.47 % y 93.22 % en dos conjuntos de datos de referencia.

6.2.2. Sistemas de recomendación

Qazi et al. [60] diseñan sistemas de recomendación de seguros basados en redes bayesianas, aprovechando la capacidad de los modelos gráficos probabilísticos para manejar datos faltantes frecuentes en carteras de clientes. La inferencia bayesiana mediante propagación de creencias aproximada (*loopy belief propagation*) permite escalar el sistema a carteras reales, mientras que un enfoque de aprendizaje profundo complementario atiende a prospectos con datos externos de marketing, constituyendo un sistema híbrido bayesiano-neuronal de producción.

6.2.3. Agentes autónomos y robótica

La arquitectura de Procesos de Decisión de Markov Parcialmente Observables (POMDP), revisada en la sección de fundamentos, constituye el marco bayesiano dominante para el diseño de agentes autónomos que operan en entornos estocásticos con observabilidad parcial. Teipel et al. [61] discuten su aplicación a sistemas ICT para navigation asistida en demencia, describiendo cómo el POMDP permite planificar secuencias de acciones sobre horizontes temporales largos bajo incertidumbre, con costo computacional administrado mediante algoritmos de valor iterativo por puntos.

7. Conclusiones

La transición desde sistemas basados en reglas deterministas hacia paradigmas probabilísticos ha permitido a la inteligencia artificial abordar la incertidumbre de manera formal y estadísticamente rigurosa. A lo largo de esta revisión, se ha evidenciado que el enfoque bayesiano no solo proporciona una métrica de confianza para las predicciones, sino que ofrece un marco para la integración coherente del conocimiento previo del experto con la evidencia empírica.

La distinción entre incertidumbre aleatoria y epistémica se consolida como un pilar fundamental para el diseño de sistemas robustos, permitiendo identificar cuándo la falta de precisión se debe a la variabilidad intrínseca del sistema o a la insuficiencia de datos. La diversificación de modelos, desde las redes bayesianas gráficas hasta las redes neuronales bayesianas (BNN), demuestra la versatilidad del formalismo para adaptarse a diferentes niveles de dimensión y complejidad de datos.

En el ámbito de la ingeniería química, la optimización bayesiana y los modelos de procesos gaussianos están redefiniendo la eficiencia en la transición de productos y el descubrimiento de catalizadores, reduciendo significativamente la necesidad de experimentación física costosa. Por otro lado, la integración con el aprendizaje profundo ha mitigado el problema de la sobreconfianza en las redes neuronales, convirtiendo el *Bayesian Machine Learning* en una infraestructura crítica para aplicaciones donde el error tiene un costo elevado.

No obstante, persisten desafíos significativos, particularmente en la carga computacional de los métodos de muestreo exacto y en la sensibilidad de los resultados a la elección de las distribuciones previas en espacios de alta dimensión. La investigación futura apunta hacia la hibridación de métodos variacionales y arquitecturas dinámicas que permitan una cuantificación de la incertidumbre en tiempo real y con mayor estabilidad. En suma, los enfoques bayesianos se posicionan como la base metodológica para una inteligencia artificial más segura, estable y explicable.

Créditos de los Autores

Moran Gonzalez, Miguel: Conceptualización, Investigación, Metodología, Redacción - borrador original.

Salas García, Javier: Investigación, Supervisión, Redacción - revisión y edición.

Albarrán Trujillo, Silvia Edith: Validación, Redacción - revisión y edición.

Referencias

- [1] R. Fikes y T. Garvey. “Knowledge Representation and Reasoning — A History of DARPA Leadership”. En: *AI Magazine* 41.2 (2020), págs. 9-21. URL: <https://doi.org/10.1609/aimag.v41i2.5295>.
- [2] T. G. Dietterich. “Steps Toward Robust Artificial Intelligence”. En: *AI Magazine* 38.3 (2017), págs. 3-24. URL: <https://doi.org/10.1609/aimag.v38i3.2756>.
- [3] “AAAI News: Fall News from the Association for the Advancement of Artificial Intelligence [Judea Pearl Receives the 2010 Rumelhart Prize]”. En: *AI Magazine* 31.3 (2010), págs. 3-10. URL: <https://doi.org/10.1609/aimag.v31i3.2320>.

-
- [4] R. Flage et al. “Concerns, Challenges, and Directions of Development for the Issue of Representing Uncertainty in Risk Assessment”. En: *Risk Analysis* 34.7 (2014), págs. 1196-1207. URL: <https://doi.org/10.1111/risa.12247>.
- [5] M. Z. Naser. “A Guide to Machine Learning Epistemic Ignorance, Hidden Paradoxes, and Other Tensions”. En: *WIREs Data Mining and Knowledge Discovery* 15.3 (2025). URL: <https://doi.org/10.1002/widm.70038>.
- [6] M. Greenberg et al. “Risk Analysis: Celebrating the Accomplishments and Embracing Ongoing Challenges”. En: *Risk Analysis* 40 (2020), págs. 2113-2127. URL: <https://doi.org/10.1111/risa.13487>.
- [7] S. T. Glavind, E. D. Christensen H. Brüske y M. H. Faber. “Bayesian Probabilistic Representation of Complex Systems: With Application to Wave Load Modeling”. En: *Computer-Aided Civil and Infrastructure Engineering* 37.8 (2021), págs. 935-955. URL: <https://doi.org/10.1111/mice.12763>.
- [8] X. Xu, L. Xie y J. Chen. “Individual Multiple-Unit Train Damage Prognosis Method Based on Digital-Twin Concept”. En: *Fatigue & Fracture of Engineering Materials & Structures* 48.11 (2025), págs. 4552-4569. URL: <https://doi.org/10.1111/ffe.70053>.
- [9] F. E. Hedley et al. “Understanding Anxiety Through Uncertainty Quantification”. En: *British Journal of Psychology* 0.0 (2024). URL: <https://doi.org/10.1111/bjop.12693>.
- [10] Ü. S. Sakallı. “A Simulated Annealing Approach for Reliability-Based Chance-Constrained Programming”. En: *Applied Stochastic Models in Business and Industry* 30.4 (2013), págs. 497-508. URL: <https://doi.org/10.1002/asmb.2000>.
- [11] M. Weiss y P. Tonella. “Uncertainty Quantification for Deep Neural Networks: An Empirical Comparison and Usage Guidelines”. En: *Software Testing, Verification and Reliability* 33.6 (2023). URL: <https://doi.org/10.1002/stvr.1840>.
- [12] M. Z. Naser. “A Guide to Machine Learning Epistemic Ignorance, Hidden Paradoxes, and Other Tensions”. En: *WIREs Data Mining and Knowledge Discovery* 15.3 (2025). URL: <https://doi.org/10.1002/widm.70038>.
- [13] S. Payandeh y A. Haldorai. “Applications of Quantum Probability Amplitude in Decision Support Systems”. En: *Applied Computational Intelligence and Soft Computing* 2023.1 (2023). URL: <https://doi.org/10.1155/2023/5532174>.
- [14] Y. Yan, B. Suo y D. Božanić. “Decision-Making with Risk under Interval Uncertainty Based on Area Metrics”. En: *Mathematical Problems in Engineering* 2022.1 (2022). URL: <https://doi.org/10.1155/2022/2793538>.
- [15] D. M. Aspen, C. Haskins y A. M. Fet. “Application of Systems Engineering to Structuring Acquisition Decisions for Marine Emission Reduction Technologies”. En: *Systems Engineering* 21.4 (2018), págs. 388-397. URL: <https://doi.org/10.1002/sys.21445>.
- [16] S. Teipel et al. “Information and Communication Technology Solutions for Outdoor Navigation in Dementia”. En: *Alzheimer’s & Dementia* 12.6 (2016), págs. 695-707. URL: <https://doi.org/10.1016/j.jalz.2015.11.003>.

-
- [17] A. Grandori. “Judgment under Radical Uncertainty: Epistemic Rational Heuristics”. En: *European Management Review* 20.4 (2023), págs. 619-625. URL: <https://doi.org/10.1111/emre.12624>.
- [18] G. Briganti et al. “Network Analysis: An Overview for Mental Health Research”. En: *International Journal of Methods in Psychiatric Research* 33.4 (2024). URL: <https://doi.org/10.1002/mpr.2034>.
- [19] D. Kohler et al. “A New Network Approach to Bayesian Inference in Partial Differential Equations”. En: *International Journal for Numerical Methods in Engineering* 104.5 (2015), págs. 313-329. URL: <https://doi.org/10.1002/nme.4928>.
- [20] S. Gupta, A. Karduni y E. Wall. “Belief Decay or Persistence? A Mixed-Method Study on Belief Movement Over Time”. En: *Computer Graphics Forum* 42.3 (2023), págs. 111-122. URL: <https://doi.org/10.1111/cgf.14816>.
- [21] Y. Wang et al. “Semiparametric PCA and Bayesian Network Based Process Fault Diagnosis Technique”. En: *The Canadian Journal of Chemical Engineering* 95.9 (2017), págs. 1800-1816. URL: <https://doi.org/10.1002/cjce.22829>.
- [22] M. A. Raza et al. “A New Bayesian Network-Based Generalized Weighting Scheme for the Amalgamation of Multiple Drought Indices”. En: *Complexity* 2023.1 (2023). URL: <https://doi.org/10.1155/2023/8260317>.
- [23] X. Yu, J. Li y J. Xu. “Estimation Algorithm for System with Non-Gaussian Multiplicative/Additive Noises Based on Variational Bayesian Inference”. En: *International Journal of Adaptive Control and Signal Processing* 33.4 (2019), págs. 586-608. URL: <https://doi.org/10.1002/acs.2973>.
- [24] P. Simon et al. “A Bayesian Probabilistic Framework for Building Models for Structural Health Monitoring of Structures Subject to Environmental Variability”. En: *Structural Control and Health Monitoring* 2024.1 (2024). URL: <https://doi.org/10.1155/2024/4204316>.
- [25] V. Fortuin. “Priors in Bayesian Deep Learning: A Review”. En: *International Statistical Review* 90.3 (2022), págs. 563-591. URL: <https://doi.org/10.1111/insr.12502>.
- [26] F. De Pretis, J. Landes y W. Peden. “Artificial Intelligence Methods for a Bayesian Epistemology-Powered Evidence Evaluation”. En: *Journal of Evaluation in Clinical Practice* 27.3 (2021), págs. 504-512. URL: <https://doi.org/10.1111/jep.13542>.
- [27] C. Li et al. “Bayesian Approach for Sequential Probabilistic Back Analysis of Uncertain Geomechanical Parameters and Reliability Updating of Tunneling-Induced Ground Settlements”. En: *Advances in Civil Engineering* 2020.1 (2020). URL: <https://doi.org/10.1155/2020/8528304>.
- [28] S. T. Glavind, E. D. Christensen H. Brüske y M. H. Faber. “Bayesian Probabilistic Representation of Complex Systems: With Application to Wave Load Modeling”. En: *Computer-Aided Civil and Infrastructure Engineering* 37.8 (2021), págs. 935-955. URL: <https://doi.org/10.1111/mice.12763>.
- [29] G. Briganti et al. “Network Analysis: An Overview for Mental Health Research”. En: *International Journal of Methods in Psychiatric Research* 33.4 (2024). URL: <https://doi.org/10.1002/mpr.2034>.

-
- [30] M. A. Raza et al. “A New Bayesian Network-Based Generalized Weighting Scheme for the Amalgamation of Multiple Drought Indices”. En: *Complexity* 2023.1 (2023). URL: <https://doi.org/10.1155/2023/8260317>.
- [31] Y. Mao et al. “Determining the Shoreline Retreat Rate of Australia Using Discrete and Hybrid Bayesian Networks”. En: *Journal of Geophysical Research: Earth Surface* 126.6 (2021). URL: <https://doi.org/10.1029/2021JF006112>.
- [32] N. S. Sulaiman et al. “Integration of Bayesian Network with Fuzzy Analytical Hierarchy Process for Determining the Pipeline Conditions”. En: *Process Safety Progress* 41 (2022). URL: <https://doi.org/10.1002/prs.12353>.
- [33] F. Gisperg et al. “Bayesian Optimization in Bioprocess Engineering—Where Do We Stand Today?” En: *Biotechnology and Bioengineering* 122.6 (2025), págs. 1313-1325. URL: <https://doi.org/10.1002/bit.28960>.
- [34] Z. Shireen. “Bayesian Optimization in Polymer Modeling: From Coarse-Graining Foundations to Autonomous Inverse Design”. En: *Macromolecular Theory and Simulations* 35.1 (2025). URL: <https://doi.org/10.1002/mats.202500081>.
- [35] J. Lin e I. Kim. “Gaussian Process Selections in Semiparametric Multi-Kernel Machine Regression for Multi-Pathway Analysis”. En: *Statistical Analysis and Data Mining: The ASA Data Science Journal* 17.3 (2024). URL: <https://doi.org/10.1002/sam.11699>.
- [36] R. Zhou y W. Wang. “Online Nonparametric Bayesian Analysis of Parsimonious Gaussian Mixture Models and Scenes Clustering”. En: *ETRI Journal* 43.1 (2020), págs. 74-81. URL: <https://doi.org/10.4218/etrij.2019-0336>.
- [37] R. Alroobaea et al. “Bayesian Inference Framework for Bounded Generalized Gaussian-Based Mixture Model and Its Application to Biomedical Images Classification”. En: *International Journal of Imaging Systems and Technology* 30.1 (2019), págs. 18-30. URL: <https://doi.org/10.1002/ima.22391>.
- [38] M. Y. Li et al. “Learning to Learn Functions”. En: *Cognitive Science* 47.4 (2023). URL: <https://doi.org/10.1111/cogs.13262>.
- [39] R. Feng. “Geophysical Inversion via Hierarchical Bayesian Deep Learning with Statistical Sampling”. En: *Geophysical Prospecting* 73.9 (2025). URL: <https://doi.org/10.1111/1365-2478.70113>.
- [40] P. Mojiri Forooshani et al. “Deep Bayesian Networks for Uncertainty Estimation and Adversarial Resistance of White Matter Hyperintensity Segmentation”. En: *Human Brain Mapping* 43.7 (2022), págs. 2089-2108. URL: <https://doi.org/10.1002/hbm.25784>.
- [41] A. Largent et al. “Automatic Brain Segmentation in Preterm Infants with Post-Hemorrhagic Hydrocephalus Using 3D Bayesian U-Net”. En: *Human Brain Mapping* 43.6 (2022), págs. 1895-1916. URL: <https://doi.org/10.1002/hbm.25762>.
- [42] Z. Jiang et al. “Validity Matters: Uncertainty-Guided Testing of Deep Neural Networks”. En: *Software Testing, Verification and Reliability* 34.8 (2024). URL: <https://doi.org/10.1002/stvr.1894>.

- [43] E. Scalco et al. “Uncertainty Quantification in Multi-Class Segmentation: Comparison Between Bayesian and Non-Bayesian Approaches in a Clinical Perspective”. En: *Medical Physics* 51.9 (2024), págs. 6090-6102. URL: <https://doi.org/10.1002/mp.17189>.
- [44] H. H. Lee y H. Kim. “Bayesian Deep Learning-Based ^1H -MRS of the Brain: Metabolite Quantification with Uncertainty Estimation Using Monte Carlo Dropout”. En: *Magnetic Resonance in Medicine* 88.1 (2022), págs. 38-52. URL: <https://doi.org/10.1002/mrm.29214>.
- [45] M. Wyatt et al. “Using Ensemble Methods to Improve the Robustness of Deep Learning for Image Classification in Marine Environments”. En: *Methods in Ecology and Evolution* 13.6 (2022), págs. 1317-1328. URL: <https://doi.org/10.1111/2041-210X.13841>.
- [46] P. Van Katwyk et al. “A Variational LSTM Emulator of Sea Level Contribution From the Antarctic Ice Sheet”. En: *Journal of Advances in Modeling Earth Systems* 15.12 (2023). URL: <https://doi.org/10.1029/2023MS003899>.
- [47] P. Zhang, Y. Jin y Z. Yin. “Machine Learning-Based Uncertainty Modelling of Mechanical Properties of Soft Clays Relating to Time-Dependent Behavior and Its Application”. En: *International Journal for Numerical and Analytical Methods in Geomechanics* 45.11 (2021), págs. 1588-1602. URL: <https://doi.org/10.1002/nag.3215>.
- [48] V. Fortuin. “Priors in Bayesian Deep Learning: A Review”. En: *International Statistical Review* 90.3 (2022), págs. 563-591. URL: <https://doi.org/10.1111/insr.12502>.
- [49] A. Flores-Tlacuahuac y L. F. Fuentes-Cortés. “A Data-Driven Bayesian Approach for Optimal Dynamic Product Transitions”. En: *AIChE Journal* 70.6 (2024). URL: <https://doi.org/10.1002/aic.18428>.
- [50] J. Morlet-Espinosa y A. Flores-Tlacuahuac. “A Bayesian Optimization Approach for Data-Driven Mixed-Integer Nonlinear Programming Problems”. En: *AIChE Journal* 70.9 (2024). URL: <https://doi.org/10.1002/aic.18448>.
- [51] R. Liang et al. “CAPBO: A Cost-Aware Parallelized Bayesian Optimization Method for Chemical Reaction Optimization”. En: *AIChE Journal* 70.3 (2023). URL: <https://doi.org/10.1002/aic.18316>.
- [52] P. Schwaller et al. “Machine Intelligence for Chemical Reaction Space”. En: *WIREs Computational Molecular Science* 12.5 (2022). URL: <https://doi.org/10.1002/wcms.1604>.
- [53] F. Gisberg et al. “Bayesian Optimization in Bioprocess Engineering—Where Do We Stand Today?” En: *Biotechnology and Bioengineering* 122.6 (2025), págs. 1313-1325. URL: <https://doi.org/10.1002/bit.28960>.
- [54] K. S. Kim. “Machine Learning for Accelerating Energy Materials Discovery: Bridging Quantum Accuracy with Computational Efficiency”. En: *Advanced Energy Materials* 16.2 (2025). URL: <https://doi.org/10.1002/aenm.202503356>.
- [55] Z. Shireen. “Bayesian Optimization in Polymer Modeling: From Coarse-Graining Foundations to Autonomous Inverse Design”. En: *Macromolecular Theory and Simulations* 35.1 (2025). URL: <https://doi.org/10.1002/mats.202500081>.

-
- [56] Y. Wang et al. “Semiparametric PCA and Bayesian Network Based Process Fault Diagnosis Technique”. En: *The Canadian Journal of Chemical Engineering* 95.9 (2017), págs. 1800-1816. URL: <https://doi.org/10.1002/cjce.22829>.
- [57] N. S. Sulaiman et al. “Integration of Bayesian Network with Fuzzy Analytical Hierarchy Process for Determining the Pipeline Conditions”. En: *Process Safety Progress* 41 (2022). URL: <https://doi.org/10.1002/prs.12353>.
- [58] P. Mojiri Forooshani et al. “Deep Bayesian Networks for Uncertainty Estimation and Adversarial Resistance of White Matter Hyperintensity Segmentation”. En: *Human Brain Mapping* 43.7 (2022), págs. 2089-2108. URL: <https://doi.org/10.1002/hbm.25784>.
- [59] J. Wang et al. “Uncertainty-Guided Cross-Level Fusion Network for Retinal OCT Image Segmentation”. En: *Medical Physics* 52.9 (2025). URL: <https://doi.org/10.1002/mp.18102>.
- [60] M. Qazi et al. “Designing and Deploying Insurance Recommender Systems Using Machine Learning”. En: *WIREs Data Mining and Knowledge Discovery* 10.4 (2020). URL: <https://doi.org/10.1002/widm.1363>.
- [61] S. Teipel et al. “Information and Communication Technology Solutions for Outdoor Navigation in Dementia”. En: *Alzheimer’s & Dementia* 12.6 (2016), págs. 695-707. URL: <https://doi.org/10.1016/j.jalz.2015.11.003>.