



Revista Venezolana de Gerencia





Inteligencia artificial aplicada en la gestión de proyectos

Béjar Tinoco, Víctor *
Madrigal Moreno, Flor **
Madrigal Moreno, Salvador ***

Resumen

La inteligencia artificial (IA) transforma la gestión de proyectos al optimizar procesos y mejorar la toma de decisiones. Este estudio analiza modelos de IA aplicados a la administración de proyectos mediante una revisión sistemática de literatura en Scopus, Web of Science e IEEE Xplore (2013-2024). La investigación, cualitativa y exploratoria, clasificó modelos como aprendizaje automático, redes neuronales, lógica difusa y algoritmos genéticos según su utilidad en las fases del proyecto. Los resultados destacan el aprendizaje automático y las redes neuronales por su capacidad predictiva, y los sistemas híbridos (neuro-difusos, máquinas de soporte vectorial) por su eficacia en costos y riesgos. Se identifican limitaciones en la calidad de datos y la especialización técnica. Se concluye que los sistemas híbridos de IA son clave para abordar la complejidad organizacional.

Palabras clave: inteligencia artificial; gestión de proyectos; aprendizaje automático; técnicas híbridas; optimización.

Recibido: 19.05.25

Aceptado: 30.07.25

* Doctor en Administración. Universidad Michoacana de San Nicolás de Hidalgo. Morelia- México. E-mail: vbejar@umich.mx. ORCID. <http://orcid.org/0000-0002-9941-2317>

** Doctora en Administración. Universidad Michoacana de San Nicolás de Hidalgo. Morelia- México. E-mail. fmadrigal@umich.mx. ORCID. <https://orcid.org/0000-0002-9854-2400>

*** Doctor en Administración. Universidad Michoacana de San Nicolás de Hidalgo. Morelia- México. E-mail. smadrigal@umich.mx. ORCID. <https://orcid.org/0000-0003-1672-9966>

Artificial intelligence applied to project management

Abstract

Artificial intelligence (AI) transforms project management by optimizing processes and enhancing decision-making. This study analyzes AI models applied to project administration through a systematic literature review in Scopus, Web of Science, and IEEE Xplore (2013-2024). The qualitative, exploratory research classified models like machine learning, neural networks, fuzzy logic, and genetic algorithms based on their utility in project phases. Results highlight machine learning and neural networks for their predictive capacity, and hybrid systems (neuro-fuzzy, support vector machines) for cost and risk management. Limitations include data quality and technical specialization needs. Hybrid AI systems are key to addressing organizational complexity.

Keywords: artificial intelligence; project management; machine learning; hybrid techniques; optimization.

1. Introducción

La transformación digital y el avance tecnológico plantean retos crecientes en la gestión de proyectos, caracterizados por incertidumbre, complejidad y la necesidad de respuestas ágiles. Surge así la cuestión central de cómo aprovechar la inteligencia artificial para mejorar la toma de decisiones y la asignación de recursos en proyectos complejos. La IA ha integrado disciplinas como la informática, la lógica y la biología computacional, permitiendo avances en aprendizaje automático, lógica difusa, redes neuronales y algoritmos evolutivos. Estas herramientas han sido adoptadas progresivamente en la gestión de proyectos, facilitando el análisis predictivo, la optimización de recursos y la mitigación de riesgos mediante el uso de datos históricos y en tiempo real.

El objetivo de este artículo es analizar los modelos de IA aplicados a la gestión de proyectos, evaluando su efectividad, limitaciones y áreas de aplicación en todas las fases del ciclo de vida del proyecto.

2. Historia del desarrollo de la inteligencia artificial: Revisión de literatura

La inteligencia artificial (IA) ha evolucionado como un campo interdisciplinario que integra informática, lógica y biología, con aplicaciones en aprendizaje automático, sistemas expertos y robótica (Hon, 2019; Jackson, 2019). Hitos clave incluyen el modelo de neurona artificial (1943), la Conferencia de Dartmouth (1956), el auge de sistemas expertos en los 80, y el aprendizaje profundo desde 2006, potenciado por avances en hardware y

datos (Boden, 2018; Deng & Yu, 2014). El triunfo de AlphaGo en 2016 marcó el potencial de la IA en tareas complejas (Brunner, 2019). Este artículo analiza avances recientes y su aplicabilidad en la optimización de resultados.

2.1. Concepto de inteligencia artificial

La inteligencia artificial (IA) se concibe como la capacidad de emular funciones humanas en sistemas computacionales o desarrollar máquinas inteligentes sin replicar mecanismos biológicos. Su estudio se centra en dos dimensiones fundamentales: los procesos cognitivos (pensar) y el comportamiento (actuar), abordados desde enfoques humanistas y racionalistas basados en lógica matemática e ingeniería (Amer & Golparvar-Fard 2019). Entre sus aplicaciones más destacadas se encuentran los sectores de salud (Angelis & Stamelos, 2000), seguridad internacional, finanzas (Anguita et al., 2010; Arslan & Yetik, 2011) y ciberseguridad (Auria et al., 2008a). Las técnicas más representativas incluyen el aprendizaje automático, que permite clasificación y predicción sin programación explícita mediante algoritmos como Random Forest y árboles de decisión (Aziz et al., 2014); el aprendizaje profundo, que utiliza redes multicapa para el reconocimiento de patrones (Bhattacharyya et al., 2011b); las redes neuronales, basadas en la estructura del cerebro para resolver problemas complejos (Bhoskar et al., 2015); el procesamiento del lenguaje natural, orientado al análisis de textos (Boejko et al., 2012); y la lógica difusa, que facilita el razonamiento bajo incertidumbre mediante funciones de pertenencia y reglas inferenciales.

2.2. Gestión de proyectos basada en aprendizaje automático

En el ámbito de la gestión de proyectos, el aprendizaje automático facilita el análisis predictivo y correctivo, brindando herramientas para la toma de decisiones, la planificación de recursos y la mitigación de riesgos, basándose en datos históricos de proyectos (Prieto, 2019). La IA permite proponer cronogramas adaptativos, alertar sobre riesgos y oportunidades, e incluso automatizar decisiones, lo que transforma la gestión de proyectos y reduce la incertidumbre (Castillo et al., 2009).

Estudios recientes han demostrado la aplicabilidad de técnicas como las redes neuronales (Cheng et al., 2009), las máquinas de soporte vectorial (Anguita et al., 2010) y los algoritmos evolutivos e híbridos (García et al., 2016). Estas herramientas mejoran la capacidad del responsable del proyecto para enfrentar situaciones adversas y disminuyen los errores derivados de una planificación o administración deficiente (Cheng & Yan, 2009; Abdelaziz et al., 2008).

3. Metodología

El presente artículo realiza una revisión bibliográfica sistemática para analizar los modelos de inteligencia artificial (IA) aplicados a la gestión de proyectos. Se siguieron las directrices del modelo PRISMA, garantizando un proceso estructurado y transparente. La búsqueda se llevó a cabo en bases de datos científicas reconocidas (Scopus, Web of Science, IEEE Xplore, SpringerLink y Google Scholar), utilizando las palabras clave: "Artificial Intelligence AND Project Management",

“Machine Learning in Project Management” y “Predictive Analytics AND Project Management”.

La revisión se limitó a artículos revisados por pares, publicados entre 2013 y 2024, en inglés o español, con acceso a texto completo y enfoque en aplicaciones prácticas de IA en administración de proyectos. Se excluyeron resúmenes, documentos sin revisión por pares y estudios no centrados en la temática principal. El proceso de selección incluyó revisión de títulos, resúmenes y textos completos para asegurar la relevancia académica.

4. Impacto y Resultados de la Inteligencia Artificial en la Gestión de Proyectos


Los resultados se derivan de una revisión sistemática de literatura científica sobre el uso de inteligencia artificial (IA) en la gestión de proyectos. Las técnicas identificadas se agrupan en: (1) modelos clásicos (redes neuronales artificiales, máquinas de soporte vectorial y lógica difusa); (2) algoritmos evolutivos y de optimización

(como genéticos y por enjambre de partículas); y (3) modelos híbridos que integran diversas metodologías. Esta clasificación facilita la comprensión de las fortalezas y limitaciones de cada enfoque para distintos contextos de gestión de proyectos.

Entre los modelos clásicos, destacan las redes neuronales artificiales (ANN), cuyo funcionamiento imita el cerebro humano y evidencia eficacia en predicción, análisis de datos y apoyo a la toma de decisiones. Su capacidad de aprendizaje y manejo de datos incompletos las vuelve útiles en la gestión de recursos, control de costos y programación de actividades (Yacim & Boshoff, 2018; Mijwil, 2021).

Las redes neuronales de alto orden (HONN) (ilustración 1), basadas en el modelo de Hopfield (ilustración 2), abordan problemas de clasificación no lineales mediante retroalimentación interna y procesamiento bidireccional (Gupta et al., 2012; Jeffries, 1995). Estas técnicas de inteligencia artificial mejoran el análisis predictivo, la optimización de procesos y la toma de decisiones estratégicas en la gestión de proyectos.

Ilustración 1
Red neuronal de alto orden




Fuente: Control Neuronal Recurrente de Alto Orden para Turbinas de Viento con generador Síncrono de Imán Permanente (Ricalde et al., 2010).

- **Red neuronal de Hopfield**

La *Hopfield Neural Network* o red neuronal de Hopfield (HNN) es una red neuronal artificial de orden superior con una sola capa de neuronas

completamente conectadas; es decir, todas las neuronas también están conectadas entre sí, como se muestra en la ilustración 2, y se utiliza para resolver problemas de optimización combinatoria (Sulehria & Zhang, 2007).

Ilustración 2 Topología de las redes Hopfield, con 3 neuronas



Fuente: Redes lineales de Hopfield y optimización restringida. IEEE Trans (Lendaris et al., 1999).


Por lo que una HNN permite que un problema pueda describirse como una función de energía con una solución óptima (Ganesan et al., 2014; Mutter et al., 2007).

complejos (Chapelle & Vapnik, 2000). Se compone de un fuzzificador, una base de reglas, un motor de inferencia y un desfuzzificador, además de mecanismos para configurar funciones de pertenencia, operadores de composición y adquisición de reglas específicas para cada aplicación (Ebrahimnejad et al., 2010; Tsakonas & Gabrys, 2013; Fazzolari et al., 2011), como se muestra en el diagrama 1.

- **Lógica difusa**

La lógica difusa (LD) es una herramienta que aborda la incertidumbre y la inexactitud, permitiendo a los sistemas automatizados describir sujetos

Diagrama 1 Arquitectura de sistemas de lógica difusa




Fuente: Artificial Intelligence - Fuzzy Logic Systems.” ([TutorialPoint.com](https://www.tutorialpoint.com), 2024).

- **Mapas cognitivos difusos**

Los mapas cognitivos constituyen una herramienta gráfica utilizada para representar el razonamiento causal en contextos donde los conceptos y relaciones presentan un alto grado de incertidumbre o ambigüedad, como la política, la historia y la planificación estratégica de proyectos (Kobbacy, 2012; Egbu, 2008). En estos diagramas,

cada nodo representa un conjunto difuso o un evento, permitiendo modelar acciones, valores, objetivos o procesos (Kobbacy, 2012). Esta técnica facilita la modelación visual, la simulación y la predicción, así como la identificación de alternativas para la toma de decisiones estratégicas (Nápoles & Bello, 2014). En la ilustración 3 la topología de un mapa cognitivo difuso.

Ilustración 3
Topología del mapa cognitivo difuso



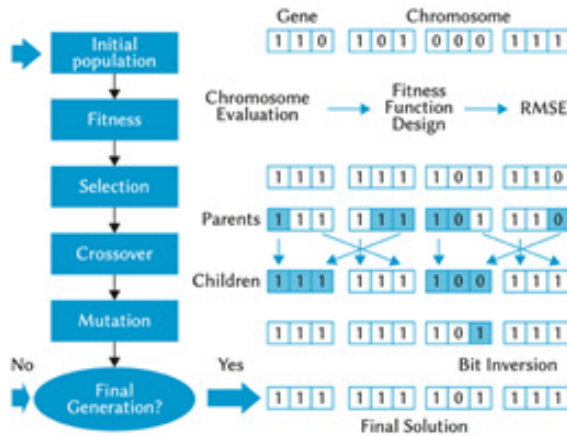
Fuente: Modeling Complex Systems Using Fuzzy Cognitive Maps. IEEE Transactions on Systems, Man, and Cybernetics Part A: Systems and Humans (Stylios & Groumpos, 2004).

- **Algoritmos genéticos en la gestión de proyectos**

Los algoritmos genéticos (AGs) son métodos adaptativos de optimización inspirados en la selección natural, que parten de una población inicial aleatoria y evolucionan hacia soluciones óptimas a través de generaciones (Fogel,

2006; Rodríguez -Cevallos et al., 2020) (diagrama 2). Estos algoritmos destacan por su flexibilidad y capacidad de combinarse con otras metodologías, mejorando la búsqueda de soluciones en problemas complejos sin técnicas especializadas, como en ingeniería, planificación y gestión de proyectos (Bhoskar et al., 2015; Kumar et al., 2010).

Diagrama 2 Diagrama de algoritmos genéticos

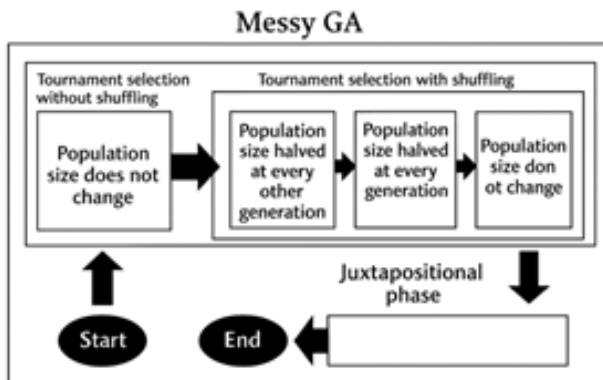


Fuente: Introducción a los Algoritmos Genéticos. (Heiss-Czedik, 1997).

Los AGs identifican soluciones parciales mediante la modificación de bloques de construcción, facilitando la convergencia hacia soluciones globales eficientes (Goldberg et al., 1989; Kargupta, 1995; Whitley et al.,

1997) (diagrama 3). En la gestión de proyectos, son especialmente útiles para la administración de recursos y la optimización en ingeniería civil (Day et al., 2002).

Diagrama 3 Muestra la arquitectura de funcionamiento de Messy GA



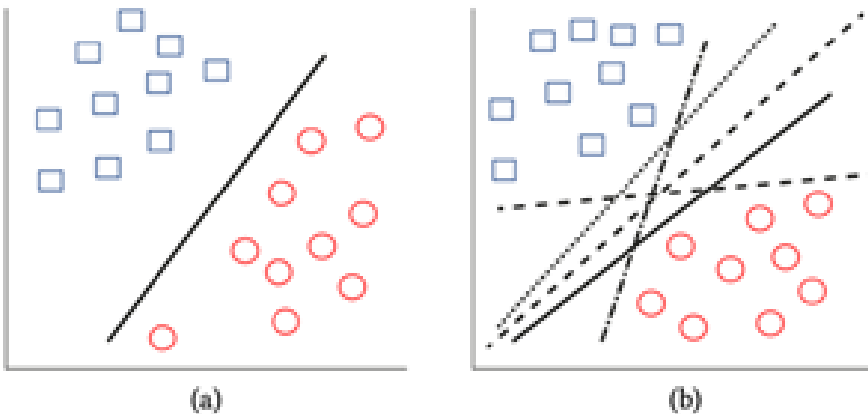
Fuente: Arquitectura GA desordenada (Kwasnicka & Przewozniczek, 2011).

- **Máquina de vectores de soporte**

La máquina de vectores de soporte es una técnica utilizada para resolver problemas de regresión y clasificación de datos, destacándose por su capacidad para manejar datos desconocidos y su ventaja sobre las redes neuronales en

ciertas aplicaciones, como la gestión de costos y proyectos (Auria et al., 2008b) y proyectos (Wauters & Vanhoucke, 2014). Pertenece a los clasificadores lineales, ya que genera separadores lineales o hiperplanos en el espacio de entrada o en uno transformado, incluso en presencia de ruido (Chapelle & Vapnik, 2000) como se muestra en la ilustración 4.

Ilustración 4 Hiperplanos de separación en un espacio bidimensional



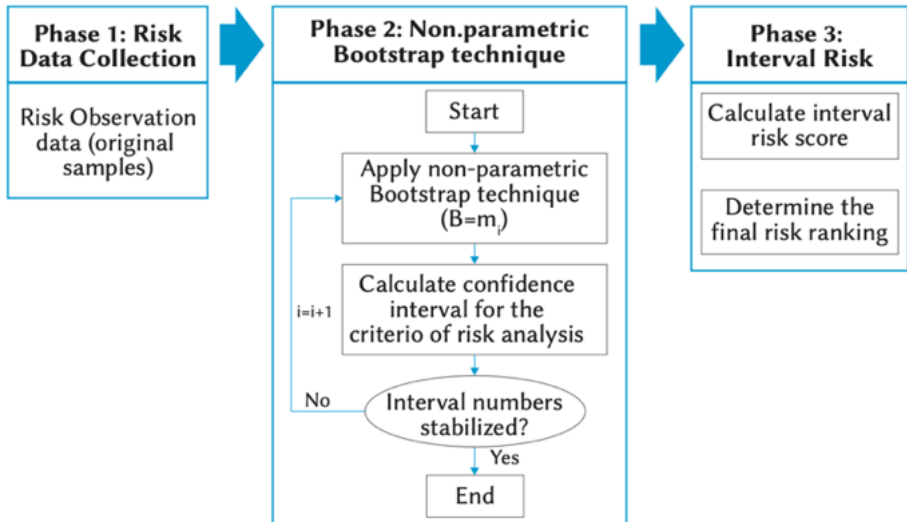
Fuente: Tutorial sobre Máquinas de Vectores Soporte, (a) ejemplo de hiperplano de separación, (b) otros ejemplos de hiperplanos de separación entre los infinitos posibles (Carmona Suárez, 2016).

- **Técnica bootstrap**

El método bootstrap (BT) es una técnica estadística utilizada para estimar parámetros poblacionales mediante réplicas generadas por muestreo con reemplazo de una muestra original. Este procedimiento permite que una misma observación se repita varias veces en una réplica, y el promedio de las estimaciones se emplea como

aproximación del valor poblacional. Es especialmente útil cuando se trabaja con muestras pequeñas o sin supuestos fuertes sobre la distribución de los datos. Sus aplicaciones abarcan campos como la medicina, las finanzas y la gestión de proyectos (Davison & Hinkley, 2014; Hashemi et al., 2013; MacKinnon, 2006; Umit, 2000; Sonmez, 2008; Wehrens et al., 2000) (diagrama 4).

Diagrama 4 Enfoque propuesto para el análisis de riesgos



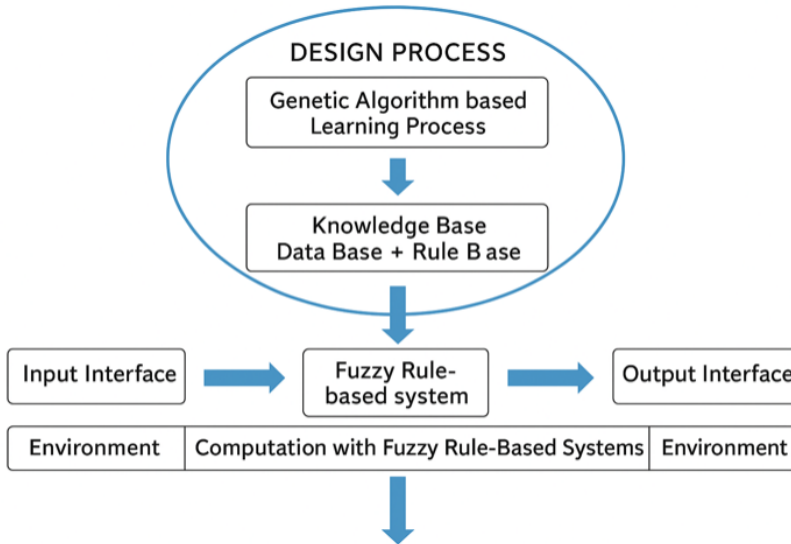
Fuente: Bootstrap Technique for Risk Analysis with Interval Numbers in Bridge Construction Projects. (Hashemi et al., 2011).

• Técnicas híbridas

Los sistemas neurodifusos, que integran redes neuronales y lógica difusa, representan un avance significativo en la gestión de proyectos, combinando el aprendizaje automático con la interpretación lingüística para mejorar la adaptación y la tolerancia a fallos (Abraham, 2005; Esogbue & Murrell, 1993). Estas técnicas han demostrado eficacia en predicción y prevención de riesgos en ingeniería,

procesamiento de imágenes y gestión de proyectos (Rutkowski & Cpałka, 2012; Kar et al., 2014; Vu et al., 2018; Ioannou et al., 2005; Tiwari & Chatterjee, 2010; Efendigil et al., 2009). Además, los enfoques *bootstrap* en redes neuronales y los modelos de refuerzo adaptativo optimizan predicciones y decisiones en entornos dinámicos, fortaleciendo la robustez y el aprendizaje (Sutton & Barto, 1998; Tiwari & Chatterjee, 2010) (diagrama 5).

Diagrama 5
Estructura FRBS



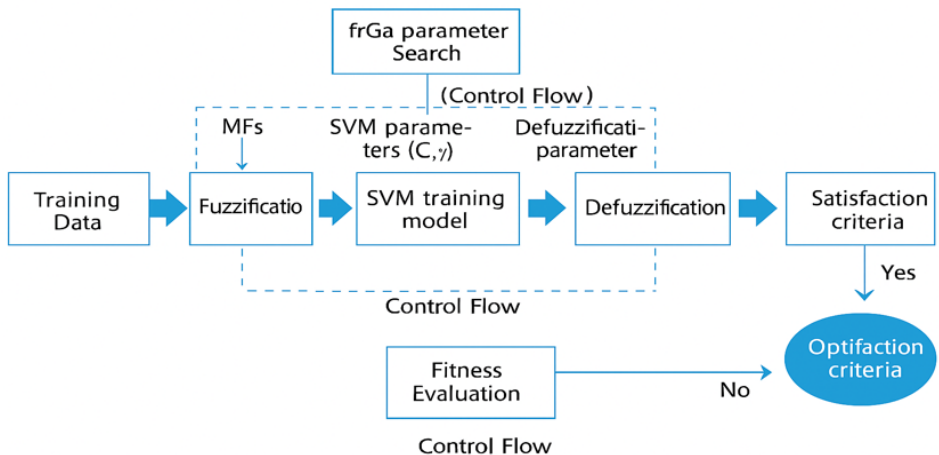
Fuente: Genetic fuzzy systems: Taxonomy, current research trends and prospects. Evolutionary Intelligence, (Herrera, 2008).

El aspecto central del uso de un AG (Cordón, 2011) para el aprendizaje automático de un FRBS es que el proceso puede analizarse como un problema de optimización. Esta técnica se utiliza con frecuencia en pronósticos meteorológicos (De la Rosa et al., 2011), el pronóstico de recursos de energía renovable (Suganthi et al., 2015) (solar (Kisi, 2014), eólica, proyectos militares (Egbu & Suresh, 2008) y en la gestión de proyectos (Bhattacharyya et al., 2011a).

- **Modelo de inferencia de máquinas de vectores de soporte difusos evolutivos (EFSIM)**

El modelo de inferencia de máquinas de vectores de soporte difusos evolutivos (EFSIM) presenta una técnica híbrida (Chou et al., 2014) que incorpora tres técnicas de IA diferentes: LD, SVM y fmGA, como se muestra en el diagrama 6.

Diagrama 6 Estructura de EFSIM



Fuente: Predicting productivity loss caused by change orders using the evolutionary fuzzy support vector machine inference model. *Journal of Civil Engineering and Management*. (Cheng et al., 2015)

En este sistema híbrido, la LD se ocupa de cualquier imprecisión y razonamiento aproximado, el SVM actúa como una herramienta de aprendizaje supervisor para manejar el mapeo de entrada-salida difuso, y el fmGA funciona para optimizar los parámetros LD y SVM. Se han llevado a cabo investigaciones interesantes sobre esta técnica en relación con la gestión de proyectos (Chou et al., 2013).


- **Modelo de inferencia neuronal difusa evolutiva (EFNIM)**

La técnica EFNIM combina

algoritmos genéticos (AG), lógica difusa (LD) y redes neuronales (NN) para optimizar sistemas híbridos, maximizando sus fortalezas y compensando sus debilidades (Cheng et al., 2009).

Los AG abordan la optimización global, la LD gestiona incertidumbres y la NN mapea entradas-salidas, siendo particularmente eficaz en ingeniería civil y gestión de proyectos (Ko et al., 2007).. Esta integración, ilustrada en el diagrama 7, facilita estrategias eficientes y decisiones efectivas para el éxito a largo plazo de los proyectos.

Diagrama 7
Estructura EFNIM



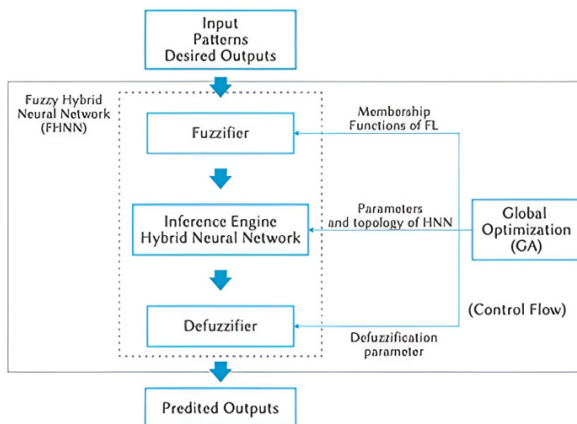
Fuente: Artificial intelligence approaches to dynamic project success assessment taxonomic. (Cheng et al., 2012).

• **Red neuronal híbrida difusa evolutiva**

El modelo híbrido EFHNN integra redes neuronales (NN), redes neuronales de alto orden (HONN), lógica difusa (LD) y algoritmos genéticos (AG) para optimizar la gestión de proyectos (Cheng & Yan, 2009). A diferencia del EFNIM, EFHNN maneja problemas

más complejos gracias a su mayor integración de HONN. En este sistema, las NN y HONN forman el motor de inferencia, la LD gestiona la fuzzificación y defuzzificación, y los AG optimizan los componentes (Diagrama 8). Aunque es ampliamente aplicado en ingeniería civil, su uso en gestión de proyectos es aún limitado.

Diagrama 8
Estructura EFHNN



Fuente: Evaluating subcontractor performance using evolutionary fuzzy hybrid neural network. (Cheng et al., 2011)

5. Conclusiones

La inteligencia artificial (IA) se consolida como una herramienta estratégica en la gestión de proyectos, al analizar grandes volúmenes de datos, detectar patrones y generar predicciones precisas. Esto permite decisiones informadas y reduce errores en fases clave como la planificación de recursos, la evaluación de riesgos y la estimación de costos, abordando eficazmente la complejidad de los entornos organizacionales.

El análisis sistemático destaca que los modelos híbridos de inteligencia artificial, como EFNIM y EFHNN, integran redes neuronales, lógica difusa, máquinas de soporte vectorial y algoritmos genéticos, abordando eficazmente la alta dimensionalidad, incertidumbre y dinámica de proyectos contemporáneos. Estos modelos muestran alto rendimiento en ingeniería civil y administración de tecnologías de la información.

La lógica difusa y los algoritmos genéticos destacan por gestionar incertidumbre y optimizar procesos en proyectos, mejorando decisiones estratégicas y operativas. Técnicas adaptativas, como redes neuronales de refuerzo y sistemas neuro-difusos, permiten respuestas dinámicas en entornos volátiles. Sin embargo, la falta de estandarización para integrar inteligencia artificial con metodologías tradicionales (e.g., PMBOK, PRINCE2) limita su aplicabilidad, sugiriendo la necesidad de marcos metodológicos híbridos.

Este estudio aporta una taxonomía clara de técnicas de inteligencia artificial aplicadas a la gestión de proyectos, detallando sus aplicaciones, ventajas y limitaciones. Los hallazgos ofrecen

una base para que investigadores y profesionales implementen soluciones de IA estratégicamente, optimizando el desempeño y éxito de los proyectos.

Referencias

- Abbasianjahromi, H., & Rajaie, H. (2012). Developing a project portfolio selection model for contractor firms considering the risk factor. *Journal of Civil Engineering and Management*, 18(6), 879–889. <https://doi.org/10.3846/13923730.2012.734856>
- Abdelaziz, A. Y., Kamh, M. Z., Mekhamer, S. F., & Badr, M. A. L. (2008). A hybrid HNN-QP approach for dynamic economic dispatch problem. *Electric Power Systems Research*, 78(10), 1784–1788. <https://doi.org/10.1016/j.epr.2008.03.011>
- Abraham, A. (2005). *Adaptation of Fuzzy Inference System Using Neural Learning*. <http://ajith.softcomputing.net>
- Amer, F., & Golparvar-Fard, M. (2019). Formalizing Construction Sequencing Knowledge and Mining Company-Specific Best Practices from Past Project Schedules. *Computing in Civil Engineering 2019: Visualization, Information Modeling, and Simulation - Selected Papers from the ASCE International Conference on Computing in Civil Engineering 2019*, 215–223. <https://doi.org/10.1061/9780784482421.028>
- Anguita, D., Ghio, A., Greco, N., Oneto, L., & Ridella, S. (2010). *Model Selection for Support Vector Machines: Advantages and Disadvantages of the Machine Learning Theory*. IEEE.
- Arsilan, O., & Yetik, O. (2011). ANN based optimization of supercritical ORC-Binary geothermal power plant: Simav case study. *Applied Thermal Engineering*, 31(17–18),

- 3922–3928. <https://doi.org/10.1016/j.applthermaleng.2011.07.041>
- Auria, L., Berlin, R. A. M., & Moro, R. A. (2008a). *Support Vector Machines (SVM) as a Technique for Solvency Analysis*.
- Auria, L., Berlin, R. A. M., & Moro, R. A. (2008b). *Support Vector Machines (SVM) as a Technique for Solvency Analysis*.
- Aziz, R. F., Hafez, S. M., & Abuel-Magd, Y. R. (2014). Smart optimization for mega construction projects using artificial intelligence. *Alexandria Engineering Journal*, 53(3), 591–606. <https://doi.org/10.1016/j.aej.2014.05.003>
- Bhattacharyya, R., Kumar, P., & Kar, S. (2011a). Fuzzy R&D portfolio selection of interdependent projects. *Computers and Mathematics with Applications*, 62(10), 3850–3870. <https://doi.org/10.1016/j.camwa.2011.09.036>
- Bhattacharyya, R., Kumar, P., & Kar, S. (2011b). Fuzzy R&D portfolio selection of interdependent projects. *Computers and Mathematics with Applications*, 62(10), 3857–3870. <https://doi.org/10.1016/j.camwa.2011.09.036>
- Bhoskar, T., Kulkarni, O. K., Kulkarni, N. K., Patekar, S. L., Kakandikar, G. M., & Nandedkar, V. M. (2015). Genetic Algorithm and its Applications to Mechanical Engineering: A Review. *Materials Today: Proceedings*, 2(4–5), 2624–2630. <https://doi.org/10.1016/j.matpr.2015.07.219>
- Boejko, W., Hejducki, Z., & Wodecki, M. (2012). Applying metaheuristic strategies in construction projects management. *Journal of Civil Engineering and Management*, 18(5), 621–630. <https://doi.org/10.3846/13923730.2012.719837>
- Bottani, E., Montanari, R., Rinaldi, M., & Vignali, G. (2015). Intelligent algorithms for warehouse management. *Intelligent Systems Reference Library*, 87, 645–667. https://doi.org/10.1007/978-3-319-17906-3_25
- Braswell, G. (2013). Artificial Intelligence Comes of Age in Oil and Gas. *Journal of Petroleum Technology*, 65(01), 50–57.
- Brunner, F. (2019). *Artificial Intelligence for Games Seminar Report Mastering the game of Go with deep neural networks and tree search (Silver et al., 2016)*.
- Carmona Suárez, E. J. (2016). Tutorial sobre Máquinas de Vectores Soporte (SVM). https://www.researchgate.net/publication/263817587_Tutorial_sobre_Maquinas_de_Vectores_Soporte_SVM
- Castillo, J. M., Cortes, C., González, J., & Benito, A. (2009). Prospecting The Future with AI. *International Journal of Artificial Intelligence and Interactive Multimedia*, 1(2), 1–53.
- Chakravarthy, V. S. (2019). *Networks that Learn. In Demystifying the Brain*. Springer.
- Chapelle, O., & Vapnik, V. (n.d.). *Model Selection for Support Vector Machines*.
- Chapelle, O., & Vapnik, V. (2000). Model Selection for Support Vector Machines. In *INFOR~ATIO~ AND CONTROL* (Vol. 8).
- Cheng, M., Lien, C., Tsai, H., & Chen, H. (2012). Artificial intelligence approaches to dynamic project success assessment taxonomic. *Life Science Journal*, 9, 5156–5163.
- Cheng, M., Tsai, H., & Sudjono, E. (2011). Evaluating subcontractor performance using evolutionary fuzzy

- hybrid neural network. *International Journal of Project Management*, 29(3), 349–356. <https://doi.org/10.1016/j.ijproman.2010.03.005>
- Cheng, M., Tsai, H.-C., & Sudjono, E. (2009). *Evolutionary fuzzy hybrid neural network for conceptual cost estimates in construction projects*.
- Cheng, M., Wibowo, D., Prayogo, D., & Roy, A. F. (2015). Predicting productivity loss caused by change orders using the evolutionary fuzzy support vector machine inference model. *Journal of Civil Engineering and Management*, 21(7), 881–892. <https://doi.org/10.3846/13923730.2014.893922>
- Cheng, M. Y., Tsai, H. C., & Hsieh, W. S. (2009). Web-based conceptual cost estimates for construction projects using Evolutionary Fuzzy Neural Inference Model. *Automation in Construction*, 18(2), 164–172. <https://doi.org/10.1016/j.autcon.2008.07.001>
- Cheng, T., & Yan, R. Z. (2009). Integrating messy genetic algorithms and simulation to optimize resource utilization. *Computer-Aided Civil and Infrastructure Engineering*, 24(6), 401–415. <https://doi.org/10.1111/j.1467-8667.2008.00588.x>
- Chou, J., Cheng, M., & Wu, Yu. (2013). Improving classification accuracy of project dispute resolution using hybrid artificial intelligence and support vector machine models. *Expert Systems with Applications*, 40(6), 2263–2274. <https://doi.org/10.1016/j.eswa.2012.10.036>
- Chou, J. S., Cheng, M. Y., Wu, Y. W., & Pham, A. D. (2014). Optimizing parameters of support vector machine using fast messy genetic algorithm for dispute classification. *Expert Systems with Applications*, 41(8), 3955–3964. <https://doi.org/10.1016/j.eswa.2013.12.035>
- Cordón, O. (2011). A historical review of evolutionary learning methods for Mamdani-type fuzzy rule-based systems: Designing interpretable genetic fuzzy systems. In *International Journal of Approximate Reasoning* (Vol. 52, Issue 6, pp. 894–913). <https://doi.org/10.1016/j.ijar.2011.03.004>
- Davison, A. C., & Hinkley, D. V. (2014). *Bootstrap methods and their application*. Cambridge University Press.
- Day, R., Zydallis, J., & Lamont, G. (2002). *Analysis of Fine Granularity and Building Block Sizes in the Parallel Fast Messy GA*.
- De la Rosa, J. J. G., Pérez, A. A., Palomares Salas, J. C., Ramiro Leo, J. G., & Muñoz, A. M. (2011). A novel inference method for local wind conditions using genetic fuzzy systems. *Renewable Energy*, 36(6), 1747–1753. <https://doi.org/10.1016/j.renene.2010.12.017>
- Deng, L., & Yu, D. (2014). Deep learning: Methods and applications. In *Foundations and Trends in Signal Processing* (Vol. 7, Issues 3–4, pp. 197–387). Now Publishers Inc. <https://doi.org/10.1561/20000000039>
- Ebrahimnejad, S., Mousavi, S. M., & Seyrafiyanpour, H. (2010). Risk identification and assessment for build–operate–transfer projects: A fuzzy multi attribute decision making model. *Expert Systems with Applications*, 37(1), 575–586. <https://doi.org/10.1016/j.eswa.2009.05.037>
- Egbu, C. (2008). *Knowledge Mapping Techniques Within The Construction Industry: An Exploratory Study*. 48–58.
- Egbu, C., & Suresh, S. (2008). *Knowledge Mapping Techniques Within The Construction Industry: An Exploratory*

- Study. *CIB W102-Information and Knowledge Management in Buildings*, 48–57.
- Esogbue, A. O., & Murrell, J. A. (1993). *A Fuzzy Adaptive Controller Using Reinforcement Learning Neural Networks*.
- Fahim, A. M., Salem, A. M., Torkey, F. A., & Ramadan, M. A. (2006). Efficient enhanced k-means clustering algorithm. *Journal of Zhejiang University: Science*, 7(10), 1626–1633. <https://doi.org/10.1631/jzus.2006.A1626>
- Fogel A, Hsu HC, Shapiro AF, Nelson-Goens GC, Secrist C. Effects of normal and perturbed social play on the duration and amplitude of different types of infant smiles. *Dev Psychol*. 2006 May;42(3):459-473. doi: 10.1037/0012-1649.42.3.459. PMID: 16756438.
- Ganesan, T., Vasant, P., & Elamvazuthi, I. (2014). Hopfield neural networks approach for design optimization of hybrid power systems with multiple renewable energy sources in a fuzzy environment. *Journal of Intelligent & Fuzzy Systems*, 26, 2143–2154. <https://doi.org/10.3233/IFS-130889>
- García, V. R., Pupo, I. P., Villavicencio, N., Piñero, P. Y., & Beovides, S. (2016). Experiences by using genetic algorithms in project scheduling. *Revista Cubana de Ciencias Informáticas*, 10. [http://rcci.uci.cu/Pág.71-86Editorial"EdicionesFuturo"](http://rcci.uci.cu/Pág.71-86Editorial)
- Gupta, M. M., Bukovsky, I., Homma, N., Solo, A. M. G., & Hou, Z. G. (2012). Fundamentals of higher order neural networks for modeling and simulation. In *Artificial Higher Order Neural Networks for Modeling and Simulation* (pp. 103–133). IGI Global. <https://doi.org/10.4018/978-1-4666-2175-6.ch006>
- Hashemi, H., Mousavi, S. M., & Mojtahedi, S. M. H. (2011). Bootstrap Technique for Risk Analysis with Interval Numbers in Bridge Construction Projects. *Journal of Construction Engineering and Management*, 137(8), 600–608. [https://doi.org/10.1061/\(asce\)co.1943-7862.0000344](https://doi.org/10.1061/(asce)co.1943-7862.0000344)
- Hashemi, H., Mousavi, S. M., Tavakkoli-Moghaddam, R., & Gholipour, Y. (2013). Compromise Ranking Approach with Bootstrap Confidence Intervals for Risk Assessment in Port Management Projects. *Journal of Management in Engineering*, 29(4), 334–344. [https://doi.org/10.1061/\(asce\)me.1943-5479.0000167](https://doi.org/10.1061/(asce)me.1943-5479.0000167)
- Heiss-Czedik, D. (1997). *An Introduction to Genetic Algorithms.*, *Artificial Life* (Vol. 3).
- Herrera, F. (2008). Genetic fuzzy systems: Taxonomy, current research trends and prospects. *Evolutionary Intelligence*, 1(1), 27–46. <https://doi.org/10.1007/s12065-007-0001-5>
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *science*. *Science*, 313(5786), 502–504. <https://doi.org/10.1126/science.1129198>
- Hon, H. W. (2019). A Brief History of Intelligence. In ACM (Ed.), *International Conference on Multimodal Interaction* (pp. 1–1).
- Ioannou, S. V., Raouzaïou, A. T., Tzouvaras, V. A., Mailis, T. P., Karpouzis, K. C., & Kollias, S. D. (2005). Emotion recognition through facial expression analysis based on a neurofuzzy network. *Neural Networks*, 18(4), 423–435. <https://doi.org/10.1016/j.neunet.2005.03.004>
- Ishibuchi, H. (2004). Genetic fuzzy systems: evolutionary tuning and learning of fuzzy knowledge bases.

- Fuzzy Sets and Systems*, 141(1), 161–162. [https://doi.org/10.1016/s0165-0114\(03\)00262-8](https://doi.org/10.1016/s0165-0114(03)00262-8)
- Jackson, P. (2019). *Introduction to artificial intelligence* (Tercera Edición). Courier Dover Publications.
- Jeffries, C. (1995). *Tracking, code recognition, and memory management with high order neural networks*. 2492, 964–973. <http://proceedings.spiedigitallibrary.org/>
- Kandpal, A. P. K., & Mehta, B. A. (2019). *Comparative Study between Multiplicative Neuron and Spiking Neuron Model*. IEEE.
- Kanungo, T., Member, S., Mount, D. M., Netanyahu, N. S., Piatko, C. D., Silverman, R., & Wu, A. Y. (2002). *An Efficient k-Means Clustering Algorithm: Analysis and Implementation*.
- Kar, S., Das, S., & Ghosh, P. K. (2014). Applications of neuro fuzzy systems: A brief review and future outline. In *Applied Soft Computing Journal* (Vol. 15, pp. 243–259). <https://doi.org/10.1016/j.asoc.2013.10.014>
- Kargupta, H. (1995). *SEARCH, Polynomial Complexity, And The Fast Messy Genetic Algorithm*. www.manaraa.com
- Kisi, O. (2014). Modeling solar radiation of Mediterranean region in Turkey by using fuzzy genetic approach. *Energy*, 64, 429–436. <https://doi.org/10.1016/j.energy.2013.10.009>
- Ko, C. H., Cheng, M. Y., & Wu, T. K. (2007). Evaluating sub-contractors' performance using EFNIM. *Automation in Construction*, 16(4), 525–530. <https://doi.org/10.1016/j.autcon.2006.09.005>
- Kobbacy, K. A. H. (2012). Application of Artificial Intelligence in maintenance modelling and management. *IFAC Proceedings Volumes (IFAC-PapersOnline)*, 45(31), 54–59. <https://doi.org/10.3182/20121122-2-ES-4026.00046>
- Kumar, M., Husian, M., Upreti, N., & Gupta, D. (2010). *GENETIC ALGORITHM: REVIEW AND APPLICATION*. <https://ssrn.com/abstract=3529843>
- Lendaris, G., Mathia, K., & Sacks, R. (1999). Linear Hopfield networks and constrained optimization. *IEEE Trans. Knowl. Data Eng.*, 1, 114–118.
- Lewis, F. L., & Vrabie, D. (2009). Reinforcement learning and adaptive dynamic programming for feedback control. *IEEE Circuits and Systems Magazine*, 9(3), 32–50. <https://doi.org/10.1109/MCAS.2009.933854>
- Leyva - Vázquez, M. Y., Pérez Teruel, K., Febles Estrada, A., & Gulín González, J. (2013). Mapas cognitivos difusos para la selección de proyectos de tecnologías de la información. *Contaduría y Administración*, 58(4), 95–117. [https://doi.org/10.1016/s0186-1042\(13\)71235-x](https://doi.org/10.1016/s0186-1042(13)71235-x)
- Luo, J., Meng, Q., & Cai, Y. (2018). Analysis of the Impact of Artificial Intelligence Application on the Development of Accounting Industry. *Open Journal of Business and Management*, 06(04), 850–856. <https://doi.org/10.4236/ojbm.2018.64063>
- MacKinnon, J. G. (2006). Bootstrap methods in econometrics. *Economic Record*, 82(SPEC. ISS. 1). <https://doi.org/10.1111/j.1475-4932.2006.00328.x>
- Mijwil, M. (2021). Artificial Neural Networks Advantages and Disadvantages. *Mesopotamian Journal of Big Data*, 2021, 29–31. <https://doi.org/10.58496/mjbd/2021/006>

- Nápoles, G., & Bello, R. (2014). *Algoritmo para mejorar la convergencia en Mapas Cognitivos Difusos Sigmoidales*. Universidad Central "Marta Abreu" de Las Villas .
- Obayashi, M., Nishida, T., Kuremoto, T., Kobayashi, K., & Feng, L. B. (2010). A reinforcement learning system embedded agent with neural networkbased multi-valued pattern memory structure. *ICCAS 2010 - International Conference on Control, Automation and Systems*, 176–181.
- Prieto, B. (2019). Impacts of Artificial Intelligence on Management of Large Complex Projects. In *PM World Journal Complexity in Large Engineering &: Vol. VIII*. www.peworldlibrary.net
- Ricalde, L. J., Cruz, B., Sanchez, E., Ricalde, L. J., Cruz, B. J., & Sánchez, E. N. (2010). *Neural Control for Wind Turbine with a Permanent Magnet Synchronous Generator Control Neuronal Recurrente de Alto Orden para Turbinas de Viento con Generador Síncrono de Imán Permanente*. 14(2), 133–143. <https://www.researchgate.net/publication/262613566>
- Rodriguez-Repiso, L., Setchi, R., & Salmeron, J. L. (2007). Modelling IT projects success with Fuzzy Cognitive Maps. *Expert Systems with Applications*, 32(2), 543–559. <https://doi.org/10.1016/j.eswa.2006.01.032>
- Rodríguez -Cevallos, M., José Andrade-Albán, M., Carlos Maldonado Palacios, R., & Alfonso Cobos-Cevallos, C. (2020). *Obtener el cromosoma mejor adaptado implementation of a genetic algorithm using a computer application based on neural and evolutionary computing to obtain the best adapted chromosome*. <https://orcid.org/0000-0001-8409-0530>
- Rutkowski Leszek and Cpałka, K. and N. R. and P. A. and S. R. (2012). Neuro-fuzzy Systems Neuro-fuzzy systems (NFS). In R. A. Meyers (Ed.), *Computational Complexity: Theory, Techniques, and Applications* (pp. 2069–2081). Springer New York. https://doi.org/10.1007/978-1-4614-1800-9_131
- Sonmez, R. (2008). Parametric Range Estimating of Building Costs Using Regression Models and Bootstrap. *Journal of Construction Engineering and Management*, 134(12), 1011–1016. <https://doi.org/10.1061/ASCE0733-93642008134:121011>
- Stylios, C. D., & Groumpos, P. P. (2004). Modeling Complex Systems Using Fuzzy Cognitive Maps. *IEEE Transactions on Systems, Man, and Cybernetics Part A: Systems and Humans*, 34(1), 155–162. <https://doi.org/10.1109/TSMCA.2003.818878>
- Sulehria, H. K., & Zhang, Y. (2007). Hopfield Neural Networks — A Survey. In *Engineering* (pp. 125–130).
- Sutton, R. S., & Barto, A. G. (1998). *Reinforcement Learning: An Introduction*, "IEEE Transactions on Neural Networks". 9(5), 1054–1054.
- Tiwari, M. K., & Chatterjee, C. (2010). Development of an accurate and reliable hourly flood forecasting model using wavelet-bootstrap-ANN (WBANN) hybrid approach. *Journal of Hydrology*, 394(3–4), 458–470. <https://doi.org/10.1016/j.jhydrol.2010.10.001>
- Tsakonas, A., & Gabrys, B. (2013). A fuzzy evolutionary framework for combining ensembles. *Applied Soft Computing Journal*, 13(4), 1800–1812. <https://doi.org/10.1016/j.asoc.2012.12.027>
- TutorialPoint.com. (2024). *Artificial Intelligence - Fuzzy Logic Systems."*

[Online]. <https://www.tutorialspoint.com/articles/index.php>.

- Umit, H. (2000). *Digital business strategies in blockchain ecosystems : transformational design and future of global business*. Contributions to Management Science.
- Wauters, M., & Vanhoucke, M. (2014). Support Vector Machine Regression for project control forecasting. *Automation in Construction*, 47, 92–106. <https://doi.org/10.1016/j.autcon.2014.07.014>
- Waziri, B. S., Bala, K., & Bustani, S. A. (2017). Artificial Neural Networks in Construction Engineering and Management. *International Journal of Architecture, Engineering and Construction*, 6(1). <https://doi.org/10.7492/ijaec.2017.006>
- Wehrens, R., Putter, H., & Buydens, M. C. (2000). The bootstrap: a tutorial. In *Chemometrics and Intelligent Laboratory Systems* (Vol. 54). www.elsevier.com/locate/chemometrics
- Whitley, D., Beveridge, J., & GuerraSalcedo J. (1997). Messy Genetic Algorithms for Subset Feature Selection. *Department of Computer Science*, 568–575.
- Yacim, J. A., & Boshoff, D. G. B. (2018). Impact of artificial neural networks training algorithms on accurate prediction of property values. *Journal of Real Estate Research*, 40(3), 375–418. <https://doi.org/10.1080/10835547.2018.12091505>
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. In *International Journal of Forecasting* (Vol. 14).
- Zhou, Y., Zhao, S., Wang, X., & Liu, W. (2018). Deep learning model and its application in big data. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10918 LNCS, 795–806. https://doi.org/10.1007/978-3-319-91797-9_55