

Metodologías de Inteligencia Artificial para la Toma de Decisiones en la Red/Cadena de Suministro en el Contexto de Incertidumbre*

Nicolay Mena O'Meara, Eduardo Vicens Salort, Francisco Cruz Lario

Centro de Investigación Gestión e Ingeniería de la Producción (CIGIP). UPV. Camino de Vera s/n, Edificio 8G.- Esc 4-Nivel 4. Valencia. nimeom@doctor.upv.es, evicens@omp.upv.es, fclario@omp.upv.es

Palabras clave: Metodologías, Inteligencia Artificial, Red/Cadena de Suministro

Resumen

Este trabajo presenta una serie de Metodologías de Inteligencia Artificial, que dan cabida al uso en la Cadena de Suministro. Esto con el ansia de presentar las diferentes Metodologías existentes hasta el momento en este ámbito de trabajo. Así dar una mirada a nuevas tendencias de resolución de problemas en la Red/Cadena de Suministro bajo Incertidumbre. Mostrando algunos de los trabajos en los que se han aplicado estas metodologías en la Planificación de la Red/Cadena de Suministro. En particular el objetivo general de esta investigación es utilizar una metodología de estas, para un Problema de Planificación Colaborativa en la Red/Cadena de Suministro.

1. Introducción

En muchas ocasiones, la mejora de la Red/Cadena de Suministro (R/CS) radica en la acertada toma de decisiones, en tiempo y forma. Por otro lado es difícil encontrar decisores que tengan las características necesarias para tomar decisiones más acertadas en todo momento. Estos decisores, necesitan herramientas que les permitan visualizar de un modo general, las fortalezas y debilidades de su R/CS, así como las áreas de oportunidad que pudieran llegar a presentarse. Además necesitan sistemas que les ayuden a mejorar la calidad de las decisiones que se toman día a día. Actualmente se está trabajando con sistemas de decisiones basados *en Inteligencia Artificial (IA)*, los cuales se han aplicado en una gran variedad de tareas, desde la enseñanza hasta la automatización de procesos productivos. La mayoría de los sistemas de IA (**McCulloch y Pitts**; 1943) tienen la peculiaridad de “aprender”, lo que les permite ir perfeccionando su desempeño conforme pasa el tiempo. Además estos sistemas pueden analizar volúmenes muy grandes de información a muy alta velocidad, lo que permite obtener indicadores puntuales de las operaciones de la R/CS.

Este artículo se exponen tres *Metodologías de Inteligencia Artificial (MIA)* que son de gran relevancia para el estudio de la Incertidumbre en la R/CS.

2. Metodologías de Inteligencia Artificial para la R/CS bajo Incertidumbre

La mayoría de investigadores que trabajan en temas de IA han definido diferentes metodologías y teorías fundamentales. A partir de estas se define una metodología teniendo en cuenta el trabajo realizado por Li, D. y Du, Y. (2008), el cual se subdivide en: Simbolismo,

* Este trabajo es realizado en el ámbito del Proyecto del MINISTERIO DE EDUCACIÓN Y CIENCIA “De la Planificación a la Ejecución en la Cadena (Red) de Suministro: Dos visiones diferentes y sus herramientas (DPI2004-06916-C02-01)”

Conexionismo y Conductismo. El Simbolismo está basado en la hipótesis de un sistema de símbolo físico, es decir, un sistema de operadores simbólicos y una teoría de racionalidad limitada. El Conexionismo concierne a los sistemas de Redes Neuronales Artificiales (ANN) y Computación Evolutiva. Y por último el Conductismo, que se enfatiza en particular, en las relaciones entre la percepción y la acción. Como se ve en la figura 1 las MIA se subdividen en tres metodologías, a su vez cada subdivisión está conformada por varios modelos. Podemos ver en la Figura 1 que los modelos más trabajados en la R/CS están sombreados. Más adelante se hacen referencias de algunos de estos trabajos en el apartado 3.

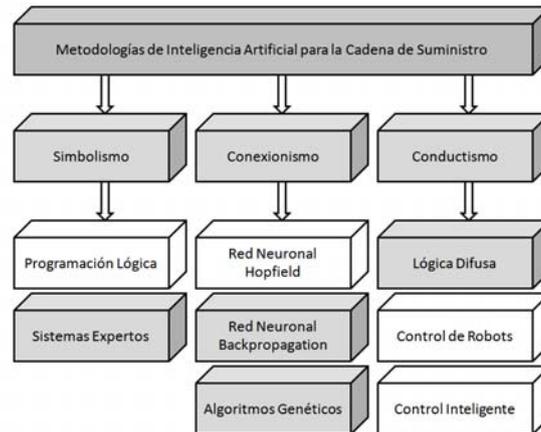


Figura 1.- Metodologías de Inteligencia Artificial para la R/CS.

2.1. Metodología del Simbolismo

La Metodología del Simbolismo se origina a partir de la Cognición Computacional. El propósito de la Cognición Computacional es dar como pauta el estudio de la cognición humana para entrar en una fase científica de investigación regular. Simon, H. A., (1997) dijo, años atrás el desarrollo de la ciencia cognoscitiva, “antes de que el ordenador fuera considerado como un sistema de procesamiento de símbolos universales, había muy pocos conceptos científicos y enfoques para el estudio de la naturaleza de la cognición y la inteligencia. La Cognición Computacional llegó a ser el principio de una línea de la Inteligencia Artificial, Psicología Cognoscitiva y Lingüística Matemática, ayudando enormemente al avance de la IA (Simon, H. A., 1997). El simbolismo en términos de cognición es el procesamiento de símbolos y en que el proceso del pensamiento humano puede ser descrito por ciertas clases de símbolos. En otras palabras, el pensamiento es la computación (o la cognición es la computación). Esta ideología constituye una de las bases filosóficas para la inteligencia artificial.

2.1.1. Lenguajes de Programación Lógica

En 1959, basándose en el cálculo de Alonzo Church “‘list structure’”; Simon y Newell, John McCarthy introdujeron el desarrollo la famosa LISP (Lista de Procesamiento de Lenguaje), que más tarde fue el lenguaje que más ha ayudado en la investigación de Inteligencia Artificial (Church, A., 1941). LISP es un lenguaje funcional de procesamiento simbólico, que trata de un programa hecho de subfunciones funcionales. Su estructura funcional es análoga a la estructura de la función recurrente en matemáticas, siendo capaz de construir nuevas funciones desde unas funciones básicas de ciertos medios. Por lo tanto, es un lenguaje de programación funcional. También es un lenguaje de programación lógico, porque su cálculo está basado en símbolos más bien que números y esto realiza deducciones por medio del cálculo simbólico. PROLOG (Programador de Lógica) es otro famoso lenguaje de

programación lógico, puesto en práctica en 1972 por el grupo de investigación de Alain Colmerauer de la Universidad de Marsella en Francia.(Colmerauer, A., 1990) Más Tarde, Pillipe Roussel introdujo el intérprete de PROLOG; y David Warren contribuyó con el primer compilador de PROLOG. (Rousel, P., 1975)

2.1.2. Sistemas Expertos

La base matemática para el simbolismo, fue mejorada día a día por el perfeccionamiento, en sistemas matemáticos o sistemas lógicos, los cuales han sido diseñados con alguna clase de sistema de regla de producción. La mayor parte de categorías del conocimiento han sido representadas por reglas de producción basadas en el cálculo de predicado y el principio de resolución, los cuales han proporcionado una base teórica para el desarrollo de sistemas expertos, en diferentes campos del conocimiento en este siglo de tecnologías de la información. Es sobre la base de tal Sistema de Producción que el sistema experto es desarrollado. Y los lenguajes de programación lógicos como LISP y PROLOG han ayudado al diseño del sistema como una herramienta poderosa. Hablando en general, un sistema experto es un sistema que trabaja a través de experiencia y conocimiento. Esto hace una inferencia y simulación a los procesos de toma de decisiones para resolver problemas complejos que por lo general toman a un experto en el campo para su solución, usando tecnología de IA; también basándose en el conocimiento de uno o más expertos (Lin, Y., Zhang, B., y Shi, C., 1988) y (He, X., 1990).

2.2. Metodología del Conexionismo

McCulloch W. S., y Pitts, W., (1943) pioneros del conexionismo. Tenían en cuenta que para simular la inteligencia humana, es necesario construir un modelo cerebral con la ayuda de la biónica. Y también que la unidad básica del pensamiento humano son las neuronas, más bien que los símbolos y que la inteligencia es el resultado de la competición de las neuronas interconectadas y coordinadas. Sosteniendo vistas diferentes de la hipótesis de un sistema de símbolo físico, creyendo que el cerebro humano no es lo mismo que un ordenador. Cuando el ordenador es usado para simular el cerebro humano, debería hacerse énfasis que la simulación estructural, es decir, simular la estructura de una red de sistema neuronal humano biológico. Ellos también creen que las funciones, las estructuras, y el comportamiento están estrechamente relacionadas y que las diferentes funciones y comportamientos son representados por estructuras diferentes.

2.2.1. Modelo de Red Neuronal de Hopfield

En el enfoque Conexionista, su representación típica es el Modelo de Redes Neuronales Hopfield (NNH), desempeñando un rol importante en el resurgimiento de la investigación en las ANN. La NNH se compone de una sola capa, un modelo de retroalimentación completo; con las siguientes características técnicas (Hopfield, J.J., 1982):

1. La NNH es una conexión completa de una sola capa y de un sistema de retro alimentación completo compuesto de componentes no lineales. Cada neurona de la red esta interconectada desde su salida a otras neuronas a través de conexiones, y al mismo tiempo, recibe la información enviada de otras neuronas.
2. Un rasgo importante de la NNH es su estabilidad. Cuando la función de energía alcanza mínimos, esto es un estado estable para la red. Aquí la función de energía representa una tendencia de transición en el estado de la red. El estado varía con las reglas de operación Hopfield y es finalmente capaz de alcanzar la función objetivo de un valor mínimo.

- Mientras la NNH es puesta en marcha, la conexión entre pesos de cada neurona permanecen fijos, sólo el estado de salida es actualizado. Para la red de la misma estructura, con el cambio de parámetros de la red (pesos y umbrales), el número de mínimos de la función de energía en la red (llamado “punto de equilibrio para la estabilización del sistema”) y los valores de mínimos también son cambiados. Por lo tanto, la necesidad de un patrón de memoria puede ser diseñado con un punto de equilibrio estabilizado en un estado de red fijo.

2.2.2. Modelo de Red Neuronal Back-Propagation

Este modelo es otro tipo de estructura del conexionismo propuesto por Werbos, P. J., (1974). Poco después Parker, D., (1982) y Rumelhart, D., (1986) llegaron al algoritmo Back-Propagation, solucionando el problema de aprendizaje en los valores de pesos de conexiones en unidades de capas ocultas en una Red Neuronal Multicapa. En un modelo de propagación feed-forward²⁹, las señales de entrada son procesadas desde una capa a la siguiente por capas ocultas múltiples y después de esto, se propagan a la capa de salida. Cada neurona de salida en una capa sólo afecta el estado de la siguiente capa. Un modelo back-propagation consiste en minimizar el tipo de error en el aprendizaje, cuyo proceso de aprendizaje es realizado en dos partes: propagación feed-forward de entrada y propagación feed-back de error. El error es propagado hacia atrás cuando aparece entre la entrada y la salida esperada durante el proceso feed-forward. Durante se efectúa el back-propagation, los valores de los pesos en cada conexión entre cada capa de neuronas son corregidos y gradualmente ajustados hasta que el error de salida mínimo sea alcanzado. La figura 10 es un diagrama de una red de back propagation.

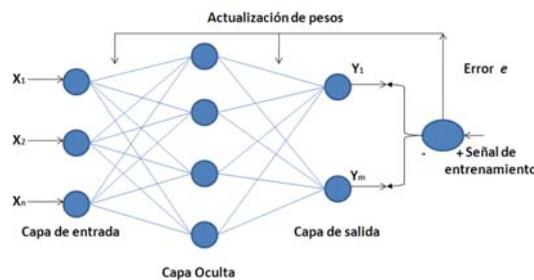


Figura 2.- Red Neuronal Back-propagation

2.2.3. Algoritmos Genéticos

Los algoritmos genéticos requieren para su aplicación de representaciones codificadas como un cromosoma. Cada cromosoma tiene varios genes que corresponden a los parámetros del problema en cuestión. En la naturaleza, los cromosomas se encuentran ubicados en parejas en el interior del núcleo celular, y los genes son una secuencia de nucleótidos, es decir, fragmentos de ADN en una determinada localización del cromosoma como se observa en la figura 3.

²⁹ En computación, el concepto feed-forward normalmente hace referencia a redes multicapa en las que las salidas de las neuronas van a las siguientes capas pero no a las anteriores, de modo que no hay bucles de retroalimentación.

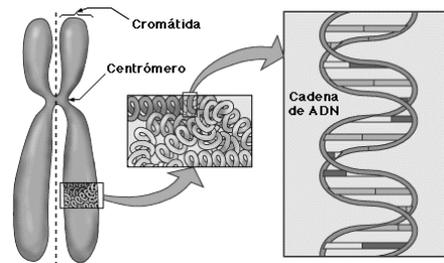


Figura 3.- Célula, cromosoma y gen.

Para poder trabajar con estos genes en el programa, es necesario representarlos en una cadena n elementos (genes), es decir, una secuencia donde cada gen puede tomar cualquier valor dentro de un conjunto de longitud finita:

$$\theta = \{s_1, \dots, s_k\} \quad (1)$$

Este conjunto θ , formará el genotipo del individuo (cromosoma), que se manifestará también como un fenotipo. El fenotipo representa las características tangibles u observables del individuo, es decir, los rasgos morfológicos.

Posteriormente, para evaluar la adaptación del fenotipo al entorno se emplea la función objetivo y las restricciones. Como se ha comentado, los cromosomas están constituidos por genes que son las N variables del problema, a su vez cada gen puede estar constituido por n dígitos cuyo valor representa un alelo. Alelo significa literalmente la forma alternativa, es decir, la variación alternativa de un determinado gen y por lo tanto de un rasgo característico.

2.3. Metodología del Conductismo (Behaviorism)

Esta es una de las más usadas por la investigación en la I.A. Los conductistas creen que la inteligencia depende del comportamiento y la percepción, proponiendo un modelo "comportamiento-percepción" de comportamiento intelectual, usualmente llamado conductismo. (Li, Z., y Tu, Y., 2003). El temprano enfoque del conductismo se basa en funciones y comportamientos intelectuales humanos en el proceso del control tales como auto-optimización, auto-adaptación, auto-ajustador, auto-calma, auto-organización y auto-aprendizaje, y en el desarrollo también llamado "animats³⁰".

2.3.1. Lógica Difusa

La Lógica Difusa se adapta mejor al mundo real en el que vivimos, e incluso puede comprender y funcionar con nuestras expresiones, del tipo "hace mucho calor", "no es muy alto", "el ritmo del corazón está un poco acelerado", etc.

La clave de esta adaptación al lenguaje, se basa en comprender los cuantificadores de nuestro lenguaje (en los ejemplos de arriba "mucho", "muy" y "un poco").

³⁰ Son animales artificiales; El término incluye robots físicos y simulaciones virtuales. La investigación de Animat, es un subconjunto de los estudios de la Vida Artificial. La palabra fue una idea de S.W. El Wilson en 1991, en las primeras medidas de la Simulación del Comportamiento Adaptable, que también fue llamado desde Animales para ser Animats.

En la teoría de conjuntos difusos se definen también las operaciones de unión, intersección, diferencia, negación o complemento, y otras operaciones sobre conjuntos (ver también subconjunto difuso), en los que se basa esta lógica.

Para cada conjunto difuso, existe asociada una función de pertenencia para sus elementos, que indican en qué medida el elemento forma parte de ese conjunto difuso. Las formas de las funciones de pertenencia más típicas son la trapezoidal, lineal y curva.

2.3.2. Control de un Robot

La teoría de control es una rama importante de la investigación en la robótica. Los problemas tratados son los sistemas sensoriales, movimientos óptimos de brazos, y planificación de métodos para la implementación de secuencia en la ejecución de un robot, del cual el control es una parte importante para estas investigaciones. Analógicamente a la psicología “la estimulación” hace a un robot hacer y tomar determinadas acciones a través del control, una vez que cada condición realizada es satisfecha.

El desarrollo rápido de la investigación en la robótica es gracias al avance en la automatización industrial y a la investigación en la IA. La combinación de automatización e intelectualización³¹ probablemente fue empleada para simular estados de procesamiento de automatización industrial, describir la transformación de un estado de producción a otro, y de programas de como la secuencia de acción son llevados a cabo y de como la ejecución de planes son supervisados. Con la ayuda del ordenador, el proceso de información y el control de actividades son generalizados como actividades intelectuales y de producción intelectualizada.

2.3.3. Control Inteligente

La metodología de teoría de control tradicional se basa en la relación entrada y salida del objeto a controlar el cual se expresará por una función de transferencia a partir de un modelo matemático exacto, que es a menudo difícil de realizar. Algunos investigadores han trabajado en el mecanismo de control de auto-aprendizaje y auto-organización; introduciendo tecnología de inteligencia artificial en el sistema de control. El control inteligente se refiere a una amplia categoría de la estrategia de control con algunos dispositivos con características intelectuales aperi³². Esto concierne al objeto controlado cuyos parámetros de modelos, hasta estructuras, son variables duras para ser descritas exactamente en métodos matemáticos, por tener propiedades no lineales, inciertas y variables en el tiempo. Cuando el control inteligente se encuentra en un ambiente externo es difícil que sea restrictivo con parámetros matemáticos, por lo cual requiere ser capaz de auto-organizarse, auto-aprender y auto-adaptarse, en pocas palabras tener comportamiento inteligente.

³¹ Es la supervisión de procesos productivos de máquinas computarizadas, programadas, y su reparación si hay necesidad de esta. La tendencia a una mayor calificación e intelectualización del trabajo se constata en varias ramas, son trabajadores que vigilan la maquinaria, técnicos de mantenimiento, programadores, controles de calidad, técnicos en sector de investigación, ingenieros de coordinación técnica y de la gestión de la producción.

³² En matemáticas, **La constante de Apery** es un número curioso que aparece en diversas situaciones. Se define como el número $\zeta(3)$,
$$\zeta(3) = 1 + \frac{1}{2^3} + \frac{1}{3^3} + \frac{1}{4^3} + \dots$$

3. Aplicación de Metodologías de IA para mejorar la Incertidumbre en la R/CS

Desde que McCulloch y Pitts; (1943) mencionaron por vez primera este término, se han pensado innumerables aplicaciones para estas metodologías. Metodologías que van de lo trivial a lo formal, de los juegos a la salud, de la guerra al salvamento de vidas. Pero hay infinidad de áreas que aún no se han beneficiado de las ventajas de esta tecnología, o bien no la han utilizado en gran escala. Concretamente el área de la R/CS una de ellas, la cual brinda un abanico muy amplio y atractivo que bien puede ser llenado fácilmente por las MIA, coadyuvando en la creación de sistemas expertos o bien funcionando como componente de sistemas más complejos de toma de decisiones, para que sean utilizados como herramientas invaluableles por los grandes empresarios actuales.

A partir de los planteamientos identificados en los apartados anteriores, se recopiló una serie de trabajos realizados donde se han aplicado estas metodologías en la R/CS. Siendo estas una base importante para determinar una metodología que busque dar solución a la Incertidumbre en la R/CS. Pensado en el contexto del sector cerámico, destacar la selección del modelo que sirve de referencia y de fundamento teórico para ser aprovechado para resolver el problema planteado. En virtud del futuro desarrollo del modelo, su validación práctica es necesaria, por lo que se identifican aquellos trabajos en los siguientes párrafos.

Chinnam, R.B., y Govind, R. (2006) se enfocan en el desarrollo de marcos metodológicos en la CS teniendo en cuenta 3 aspectos importantes. En el primer aspecto de este enfoque, desarrollan un marco metodológico centrado en el proceso genérico; de un marco de CS Multi-Agente (MAS), para completar las carencias de las metodologías genéricas. Este marco introduce la noción de una metáfora centrada en el proceso. Y adopta el Modelado de Referencia de Operaciones de la CS (SCOR), estando bien estructurado en lo genérico para el desarrollo de las metodologías MAS, las cuales son buenas guías para el Análisis y Diseño de Sistemas de la CS Multi-Agente (MASCs). En el segundo enfoque de implementación es un marco basado en un software que se compone de agentes para simplificar e incrementar el desarrollo de lo MAS, basados en un Marco Desarrollado en Agentes en Java (JADE). El tercer enfoque es un marco basado en requerimientos representados por diferentes segmentos de la R/CS en niveles detallados o agregados en modelos híbridos de resolución.

Lin, F. et. Al, (2008) en esta investigación proponen un Mecanismo de Coordinación Distribuida basada en Agentes (ADCM), que integra técnicas de negociación de Algoritmos genéticos, para una Planificación de fullfilment para encontrar los clientes con demanda. Evaluando así el mejoramiento y viabilidad de este modelo, con experimentos en una CS que fabrica moldes. Los resultados muestran que el ADCM propuesto es factible, para la organización y coordinación de la CS.

Sexton, R., S., et. Al, (1998) presentan en su publicación, un estudio que examina la búsqueda tabu, como una alternativa de mejoramiento de la Red Back-propagation. Para probar las propiedades de la búsqueda tabú, como técnica de búsqueda Global para optimizar las Redes Neuronales, emplean la simulación Monte Carlo. Mantienen constante la arquitectura de la red, para probar siete funciones de prueba y aplican una serie temporal de ecuaciones diferenciales Mackey-Glass. Concluyen que aplicando la búsqueda de tabú, se lograba considerablemente mejores soluciones junto con la Red Back-propagation. Comprueban también, que con menos iteraciones consiguen una mejor solución.

En el trabajo publicado por Feng y colaboradores (Feng et. Al, 2003), se presenta un Modelo de Demanda Determinística que varía en el tiempo sobre un horizonte Planificación Fija, para el Problema de Programación del Taller de Trabajo. Como contribución, investigan la aplicación de las Redes Perceptron Multi-Capa (MLP) al problema de estudio,

específicamente en diseñar y desarrollar un Sistema de Programación para el Taller de Trabajo. Dicho de otro modo, desarrollan un método para organizar la muestra de datos, que permite indicar la secuencia del procesamiento en el tiempo para un trabajo simultáneamente. Para controlar las soluciones mínimas locales, utilizan el proceso de entrenamiento de la Red Back-propagation, que por medio de un proceso Heurístico revisa y mejora el Programa de Producción inicial.

Chiu, M., et. Al, (2004) presentan un algoritmo para la Planificación Colaborativa de la CS, que tiene como objetivo, minimizar costes por medio de un modelo matemático que considera los agentes de colaboración, constituidos por las redes neuronales. La finalidad, es conseguir la ejecución para los pedidos comprometidos, a través de la R/CS, considerando aspectos como la Producción, Suministro y Entrega. Su estudio es aplicado para determinar la Planificación Colaborativa de la CS, a un conjunto de pequeñas firmas, que reúnen y proveen bienes a un corto plazo de entrega a un mercado regional. Los resultados de su propuesta, demostraron mejorar el rendimiento de las ANN, consiguiendo el mejoramiento de los pedidos comprometidos y aumentando la utilización de los recursos para los agentes la Cadena.

Hnaien, et. Al, (2008) proponen un Algoritmo Genético que abarca las etapas y nodos de la CS, con el fin de verificar su robustez a través de diferentes escenarios de la CS. Además interpretan el tipo de solución, convergencia y tiempo de cálculo. Todo esto analizando la Planificación de Suministro de Sistemas de Ensamble de dos Niveles bajo Incertidumbre. Suponiendo que la demanda y la fecha de entrega son conocidas. Para que el proceso inicie en cada nivel se tienen en cuenta, los componentes necesarios para el inventario inicial. Si la demanda del producto final, no es entregada en la fecha estipulada, hay un coste adicional. De la misma manera, aparece otro coste adicional, cuando los componentes de cada nivel llegan antes de empezar la línea de emsamblaje. Teniendo como objetivo encontrar la fecha de salida de los componentes para minimizar el coste total.

Chen y lee (2004) presentan un modelo de Planificación de la Producción con demanda incierta y precios difusos. Desarrollan un programa no lineal entero no mixto con múltiples objetivos. Para tratar la demanda incierta consideran siete escenarios de de demanda con sus probabilidades de ocurrencia. La decisión final fuzzy se interpreta como la intersección de todos los objetivos fuzzy y los precios fuzzy de los productos. Aplican un método de optimización fuzzy de dos etapas. En la primera usa el operador mínimo y en la segunda emplean el operador de producto que maximiza el objetivo general tipo Nash.

Aliev et. Al, (2007) presenta un modelo de Planificación Agregada de Produccion y Distribución que frente a demanda y capacidades inciertas, y otros factores que introducen incertidumbre en la solución. Su modelo está formulado con función objetivo, variablesde decisión y restricciones fuzzy y recuelto mediante un algoritmo genético.

Peidro et. Al, (2007) formulan un problema de CS con un programa lineal entero mixto fuzzy donde los datos inciertos, y modelados mediante números fuzzy triangulares en el contexto de la teoría de la posibilidad. Todo esto a partir de un modelo de programación matematica difusa para la planificación táctica de la CS bajo incertidumbre de Suministro, Produccion y Demanda.

Lo distintos autores mencionados en este apartado han trabajado con diferentes Problemas de Incertidumbre presentes en la CS. Tales pueden ser implementados con las MIA. Siendo estas útiles a la hora de abarcar un problema en la R/CS. Pudiendo así, tener noción que tipo de metodología es más conveniente para el uso de determinado problema de la R/CS, ya sea, de Suministro, Producción, Demanda, etc.

4. Conclusiones

Sin tener en cuenta la diferencia de las tres metodologías, la mayoría de investigadores tratan sólo una pequeña categoría de la inteligencia humana. El gran abanico del concepto de IA es un gran paso para el estudio de la inteligencia biológica, especialmente en el estudio de la inteligencia humana. Esto si se tiene gran conocimiento del mecanismo trabajador de los dos, pudiendo simularlo con más eficacia.

A partir de las MIA se pretende desarrollar un sistema de Planificación Colaborativa basado en Redes Neuronales para resolver los problemas de Incertidumbre en la Red/Cadena de Suministro. Se quiere proporcionar mediante la integración de las Redes Neuronales y el Modelo Matemático Determinista una planificación más segura en cada etapa de la Red/Cadena de Suministro. Y mediante esta metodología lo que se pretende es tener una visión más amplia de la Inteligencia Artificial.

Referencias

- Aliev, R.A., Fazlollahi, B., Guirimov, B.G. y Aliev, R.R., 2007. Fuzzy-genetic approach to aggregate production–distribution planning in supply chain management. *Information Sciences*, 177, 4241–4255.
- Chen, C.L. y Lee, W.C., 2004. Multi-objective optimization of multi-echelon supply chain networks with uncertain product demands and prices. *Computer & Chemical Engineering*, 28(6-7), 1131-1144.
- Chinnam, R.B., y Govind, R., 2006. Multi-agent Systems for Supply Chain Modeling: Methodological Frameworks. Wayne State University, Detroit, MI, USA.
- Chiu, M. y Lin. W., 2004. Collaborative supply chain planning using the artificial neural network approach. *Journal of Manufacturing Technology Management*. Vol. 15, Issue 8, Pag, 787-796.
- Church, A., 1941. The Calculi of Lambda Conversion. *Princeton University Press*. Princeton, NJ.
- Colmerauer, A., 1990. An Introduction to Prolog III, *Communications of the ACM*, Vol. 33, No. 7:69–90.
- Feng, S., Li, L., Cen. L., Huang, J., 2003. Using MLP networks to design a production scheduling system. *Computers and Operations Research* Volume 30 , Issue 6.
- He, X., 1990. *Knowledge Processing and Expert System*, National Defence Industry Press, Beijing.
- Hopfield, J. J., 1982. Neural networks and physical systems with emergent collective computational abilities *In: Proceedings of the National Academy of Sciences*, Vol. 79:2554–2558.
- Hnaïen, F., Delorme, X., y Dolgui, A., 2008. Genetic algorithm for supply planning in two-level assembly systems with random lead times. *Industrial Engineering and ComputeScience Centre Centre (G2I)*. Ecole des Mines de Saint Etienne, 158, cours Fauriel, 42023 Saint Etienne, France.
- Kotzab, H.; Seuring, S.; Müller, M.; Reiner, G., 2005. Research Methodologies in Supply Chain Management; Ed. Springer Company.
- Li, Z. y Tu, Y., 2003. *Apery Intelligent Control*. National Defence Industry Press, Beijing.

- Li, D. y Du, Y., 2008. *Artificial Intelligence with Uncertainty. Tsinghua University Beijing, China*. Edit. Chapman & Hall/CRC.
- Lin, F., Kuo, H., y Lin S., 2008. The enhancement of solving the distributed constraint satisfaction problem for cooperative supply chains using multi-agent systems. *Decision Support Systems* Volume 45, Issue 4.
- Lin, Y., Zhang, B., y Shi, C., 1988. *Expert System and Its Applications*, Tsinghua University Press, Beijing.
- McCulloch, W. S. y Pitts, W., 1943. A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, Vol. 5: 115–133.
- Parker, D. B., 1985. Learning-logic (Report TR-47). Cambridge, MA: MIT Center for Research in *Computational Economics and Management Science*.
- Peidro, D., Mula, J. y Poler, R., 2007. Supply chain planning under uncertainty: a fuzzy linear programming approach. *Fuzzy Systems Conference. FUZZ-IEEE 2007. IEEE International*. July 2007. Pp. 1-6.
- Roussel, P., 1975. Prolog: Manuel de Reference et d'Utilisation. Groupe d'Intelligence Artificielle, Faculté des Sciences de Luminy, Marseilles, France.
- Russell, S. y Norving, P., 2004. *Inteligencia Artificial. Un Enfoque Moderno*; (Pearson Prentice-Hall, 2004); Segunda Edición.
- Rumelhart, D.E., Hinton, G.E. y Williams, R.J., 1986. Learning Internal Representations by Backpropagating Errors, *Nature*, Vol. 323, No. 99: 533–536.
- Sexton, R.S., Dorsey, R.E. and Johnson, J.D., 1998. Toward global optimization of neural networks: a comparison of the genetic algorithm and backpropagation. *Decision Support Systems* **22** 2, pp. 171–185.
- Simon, H. A., 1997. *The Sciences of the Artificial*, 3rd ed., MIT Press, Cambridge, MA.
- Werbos, P. J., 1974. *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*, Ph.D. Thesis, Harvard University, Cambridge, MA.