



Ajuste paramétrico c_1 y c_2 en el desempeño del algoritmo de optimización de partículas – PSO

Parametric adjustment c_1 and c_2 in the performance of particle swarm optimization – PSO

MSc, Bodero Poveda Elba María¹
ebodero@unach.edu.ec

MSc, Villacrés Cevallos Edison Patricio¹
evillacres@unach.edu.ec

MSc, Ricaurte Ortiz Paúl Stalin¹
pricaurte@unach.edu.ec

MSc, Paredes Herrera Marco Marcel¹
mparedes@unach.edu.ec

MSc, Chiriboga Zamora Patricia Alexandra¹
pchuriboga@unach.edu.ec

Recibido: 1/12/2018; Aceptado: 1/02/2019

RESUMEN

La estimación de costos es un proceso vital en la planificación de la producción industrial, garantizando una mayor exactitud. Un producto en su ciclo de vida parte de la estimación de costos, logrando con ello establecer los elementos de diseño, viabilidad y márgenes de utilidad. El algoritmo metaheurístico poblacional Optimización de Enjambre de Partículas (PSO) desde su aparición ha demostrado ser eficiente en la solución de problemas de optimización, la variación de sus parámetros ha permitido mejorar su eficiencia. Entre los parámetros de configuración se encuentran los coeficientes de aceleración c_1 y c_2 . El presente trabajo está centrado en realizar un estudio del ajuste paramétrico de c_1 y c_2 en el desempeño de

¹ Universidad Nacional de Chimborazo.
Ecuador

PSO para resolver un problema de estimación de costos en la fabricación de tuberías. Dado que los diseñadores son propensos a cometer errores y en la búsqueda de modelos que representen al fenómeno estudiado, se ha demostrado que la modelación de problemas no lineales, basada en Redes Neuronales Artificiales (ANNs) provee aproximaciones con bajo margen de error. En consecuencia, en este artículo es mostrada la implementación de una Red Neuronal Artificial (ANN) tipo feedforward sigmooidal con aprendizaje PSO para lograr mejorar la exactitud en la estimación de costos. El estudio de caso utilizado para evaluar el modelo, corresponde a datos provenientes de la producción de tubería para la transferencia de fluidos en la industria minera con información relacionada al peso, tipo de soldadura, diámetro y el correspondiente costo. Los valores evaluados como coeficientes de aceleración estuvieron en el rango 0 a 10, los demás parámetros, en este caso factor inercial y el tamaño de enjambre se trabajaron con valores fijos. La función objetivo utilizada es el Error Cuadrático Medio (MSE), calculado entre los valores observados y los valores estimados por la ANN. A partir de los resultados se puede observar que valores muy pequeños de c_1 y c_2 obtienen baja exactitud en la estimación de costos de fabricación de tubería, en tanto que la mejor exactitud es lograda por medio de una ANN con aprendizaje PSO, cuyos coeficientes de aceleración son mayores o iguales a 0.5.

Palabras Clave: coeficientes de aceleración, metaheurística poblacional, método estocástico, particle swarm optimization

ABSTRACT

The estimation of costs a vital process in the planning of industrial production, guaranteeing greater accuracy. A product in its life cycle starts from the estimation of costs, achieving in this way to establish the elements of design, viability and profit margins. The metaheuristic population algorithm Optimization of Particulate Swarm (PSO) since its appearance has proven to be efficient in solving optimization problems, the variation of its parameters has allowed to improve its efficiency. Among the configuration parameters are the acceleration coefficients c_1 and c_2 . The present work is focused in carrying out a study of the parametric adjustment of c_1 and c_2 in the performance of PSO to solve a problem of estimation of costs in the manufacture of pipes. Given that designers are prone to make mistakes, and in the search for models that represent the phenomenon studied, it has been demonstrated that the modeling of nonlinear problems, based on Artificial Neural Networks (ANNs), provides approximations with a low margin of error. Consequently, this article shows the implementation of an Artificial Neural Network (ANN) type sigmooidal feedforward with PSO learning to improve the accuracy of cost estimation. The case study used to evaluate the model corresponds to data from the pipeline production for the transfer of fluids in the mining industry with information related to the weight, welding type, diameter and the corresponding cost. The values evaluated as coefficients of acceleration were in the range 0 to 10, the other parameters, in this case inertial factor and the size of swarm were worked with fixed values. The objective function used is the Mean Square Error (MSE), calculated between the observed values and

the values estimated by the ANN. From the results it can be seen that very small values of c_1 and c_2 obtain low accuracy in the estimation of pipe manufacturing costs, while the best accuracy is achieved by means of an ANN with PSO learning, whose acceleration coefficients they are greater than or equal to 0.5.

Keywords: acceleration coefficients, population metaheuristics, stochastic method, particle swarm optimization

Introducción

Particle Swarm Optimization (PSO) es un método estocástico de optimización global que inicia con estudios realizados por Kennedy y Eberhart (1995, 2001), donde, el proceso evolutivo se reduce a mover cada partícula dentro del espacio de soluciones con una velocidad que variará de acuerdo a la actual, a la memoria de la partícula y a la información global que comparte el resto del enjambre, utilizando una función de fitness para cuantificar la calidad de cada partícula en función de la posición que ésta ocupe, más allá de la propia naturaleza del método, los esquemas existentes para la implementación son muy diversos. En la investigación realizada por Carlisle y Dozier (2001) se muestran variantes dependiendo de cómo se actualicen las posiciones de las partículas, y surgen las versiones síncrona y asíncrona del algoritmo. Adicionalmente, dependiendo de cómo se haga influir la experiencia acumulada por el enjambre sobre el movimiento de cada una de las partículas que lo integran, se puede distinguir entre PSO local y global, como lo indican Eberhart y Shi (2001).

Dado que el problema de ajuste paramétrico en sistemas adaptables puede asimilarse como un problema de optimización, se aprovecha este hecho para realizar el proceso utilizando PSO.

Son muy extensas las variantes que los autores e investigadores plantean a nivel mundial, con el propósito de mejorar el rendimiento del algoritmo original en aplicaciones concretas. Al trasladar la filosofía de PSO al campo de la vida artificial y del cómputo evolutivo, entre las múltiples áreas donde ha sido aplicado con éxito, destacan por su importancia: optimización de funciones y resolución de problemas matemáticos complejos (Laskari et al., 2002), (Hu et al., 2003)), optimización de pronóstico sobre algoritmos clásicos (Barba y Rodríguez, 2015), optimización de estimación de datos con redes neuronales artificiales (Barba y Boderó, 2017), (Boderó y Leguizamón, 2018), entrenamiento de redes neuronales (Ismail y Engelbrecht, 2000), (Srinivasan et al., 2003), (Eberhart, Hu, 1999), (Wang et al., 2004), optimización de sistemas dinámicos (Hu y Eberhart, 2002), (Vesterstrom y Riget, 2002), procesado de señal (Zhao y Zheng, 2004), (Lu y Yan, 2004), gestión, planificación y optimización de recursos en redes de distribución de energía eléctrica (Naka et al., 2001), (Koay y Srinivasan, 2003), (Naka et al., 2003), (Miranda y Fonseca, 2002), (Gaing, 2003), (Chang y Lu, 2002), gestión de redes de sensores (Veeramachaneni y Osadciw, 2004(1)), (Veeramachaneni y Osadciw, 2004(2)), planificación de red en servicios de telecomunicación (Yangyang et al., 2004), gestión empresarial (Tasgetiren y Liang, 2003) y teoría de juegos (Franken y Engelbrecht, 2004), entre otros.

Por otro lado, una Red Neuronal Artificial, ANN por sus siglas en inglés de Artificial Neural Network, conocida como Perceptrón Multicapa es un modelo inspirado en el sistema neurológico humano, cuyo objetivo es imitar el paradigma de aprendizaje. Las ANNs han sido ampliamente implementadas en procesos de estimación, predicción, y extracción de características. La aplicación de las ANNs en procesos de estimación ha sido observada en diferentes tipos de industrias, tales como química (Svozil, 1997), pesca (Sholahuddin et al., 2015), agricultura (Dokić and Jovićen, 2017), entre otras. En todos los trabajos citados se ha encontrado que las ANNs constituyen un buen apoyo para la toma de decisiones. Parmee (2003), propone el uso de Redes Neuronales Artificiales en la Ingeniería de construcción para superar la incertidumbre ocasionada al momento de planificar los costos, debido generalmente a definiciones erradas. Ante ésta necesidad de mejorar los procesos de toma de decisión asociados a la construcción de nuevos productos, los modelos de estimación necesariamente deben entregar mayor exactitud.

Tomando estos antecedentes, se plantea un estudio del ajuste paramétrico que muestra los cambios en los coeficientes de aceleración en la actualización de la posición de las partículas en PSO, resolviendo un problema de estimación de costos, mediante una Red Neuronal Artificial (ANN) con aprendizaje PSO. La investigación está estructurada de la siguiente forma: la Sección 2 se describe la Metodología a utilizar, en la Sección 3 se presentan los Resultados y Discusión, y en la Sección 4 se muestran las Conclusiones.

Desarrollo

Metodología

Es importante que en las aplicaciones en el ámbito de la vida artificial se respeten cinco principios básicos para PSO sobre la inteligencia de grupo (Kennedy y Eberhart, 1995), (Millonas, 1994), los cuales son: proximidad, calidad, diversidad de respuesta, estabilidad y adaptabilidad.

En la formulación de PSO se define la velocidad de partícula como el único operador disponible para controlar la evolución de la optimización. Se considera una población de I partículas donde cada partícula del enjambre se identifica con dos variables de estado inicializadas aleatoriamente dentro del espacio N -dimensional que establece el problema a optimizar: un vector velocidad [1] y un vector de posición [2] que corresponde a una solución potencial al problema de optimización:

$$V_i = V_{i1}, V_{i2}, \dots, V_{in} \quad [1]$$

$$X_i = X_{i1}, X_{i2}, \dots, X_{in} \quad [2]$$

$$X_n \in (X_{n,}, X_{n,max}) \quad [3]$$

Los límites de los parámetros a optimizar [3] conforman en su conjunto el espacio de búsqueda al cual debe restringirse el movimiento del enjambre.

Adicionalmente cada partícula mantiene en memoria información de la posición espacial asociada con la mejor solución históricamente visitada por ésta [4] y también conoce la posición de la mejor partícula o solución encontrada por todos sus semejantes [5]. El movimiento del enjambre se realiza en pasos temporales, que se traducen a nivel de algoritmo en iteraciones contiguas.

$$P_i = p_{i1}, p_{i2}, \dots, p_{in} \quad [4]$$

$$G = g_1, g_2, \dots, g_n \quad [5]$$

En cada iteración del método, k , cada una de las partículas de la población recorre el espacio de soluciones con una velocidad V_i hacia nuevas posiciones X_i , de acuerdo con su propia experiencia P_i y con la experiencia aportada por el mejor de sus vecinos, G . En las primeras versiones del algoritmo (Kennedy y Eberhart, 1995) ésta formulación se reduce a las ecuaciones mostradas a continuación [2.1] y [2.2].

$$v_i(k+1) = v_i(k) + c_1 r_1(k) \cdot (p_{in}(k) - x_{in}(k)) + c_2 r_2(k) \cdot (g_n(k) - x_{in}(k)) \quad [2.1]$$

$$x_i(k+1) = x_i(k) + v_{in}(k+1) \cdot \Delta t \quad [2.2]$$

Entonces, $v_{in}(k)$ y $x_{in}(k)$ representan, la velocidad y posición en la iteración o instante de tiempo k de la partícula i en la dimensión n -ésima del espacio de búsqueda. Los factores c_1 y c_2 son las denominadas constantes de aceleración cognitiva y social, que determinan en qué medida influyen sobre el movimiento de la partícula su propia memoria y la cooperación entre individuos, respectivamente. Los términos $r_1(k)$ y $r_2(k)$ son dos números aleatorios uniformemente distribuidos entre 0 y 1, $U(0,1)$, cuyo objetivo es emular el comportamiento estocástico y un tanto impredecible que exhibe la población del enjambre. Después de calcular la nueva velocidad de la partícula i en la dimensión n , la nueva posición $x_{in}(k+1)$ se actualiza directamente de acuerdo con [2.2], donde se asume que la velocidad se aplica durante un cierto período de tiempo Δt , típicamente de valor unitario. El proceso descrito se extiende al espacio N -dimensional, de forma que se van componiendo iterativamente nuevos vectores de posición X_i , utilizando, como en cualquier otro método de cómputo evolutivo una función de fitness para ponderar la calidad de dicha solución parcial, actualizando los vectores P_i y G si se detectan resultados mejores.

El movimiento de los agentes sobre el espacio de soluciones y el rendimiento del algoritmo está condicionado por el grado de contribución de las tres componentes de la velocidad en [2.1] y que tienen que ver con el comportamiento social como método de optimización global: hábito o inercia, para considerar la tendencia de la partícula; memoria, nostalgia o autoaprendizaje para incluir la experiencia de la propia partícula, y cooperación, conocimiento social, conocimiento de grupo o información compartida, para reflejar el intercambio de información y el comportamiento social como grupo (Kennedy, 1997).

Existen diferentes métricas para evaluar el rendimiento de la ANN, en este trabajo se calculan la Raíz Cuadrada del Error Cuadrático Medio – RMSE [2.3] y el Coeficiente de Determinación - R^2 [2.5], como se muestra a continuación,

$$RMSE = \sqrt{MSE} \quad [2.3]$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad [2.4]$$

$$R^2 = 1 - \frac{\sum_{i=1}^{N_s} (x_i - \hat{x}_i)^2}{\sum_{i=1}^{N_s} (x_i - \bar{x}_i)^2} \quad [2.5]$$

donde x_i es el i -ésimo valor observado, \hat{x}_i es el i -ésimo valor estimado, \bar{x} es la media del valor observado, y N es el número de muestras.

Resultados y Discusión

En la aplicación empírica, se realiza la variación de coeficientes de aceleración de PSO por medio de una ANN feedforward sigmoïdal para la estimación de costos de construcción industrial.

Para este estudio se utilizaron 2253 datos de un fabricante real de elementos de tubería para transferencia de fluidos en operaciones de minería a gran escala (Rodríguez y Durán, 2013). La base de datos incluye un conjunto de 6 variables de entrada y 1 de salida. Las variables significativas fueron identificadas por medio de un análisis de correlación entre las entradas y las salidas, en este caso son, peso, tipo de soldadura y diámetro.

El conjunto de datos se divide en dos partes: un conjunto de datos de entrenamiento (con el 75%) y un conjunto de datos de prueba con el restante 25%. El éxito del algoritmo, radica en su capacidad de ajustar las posiciones de las partículas en un área del espacio de soluciones prometedora, de acuerdo a una función objetivo que se desea minimizar, en este caso el Error Cuadrático Medio (MSE).

En la Fig. 1 se muestran los resultados del desempeño de una ANN (3,5,1), de la función de costo Error Cuadrático Medio (Mean Squared Error, MSE), y coeficientes de aceleración, $c_1=0.05$, $c_2=0.05$. A partir de la figura, se observa que con más de 200 repeticiones el algoritmo converge en el mínimo. En la Fig. 2 se han variado los coeficientes a $c_1=0.2$, $c_2=0.2$, como resultado se observa que el algoritmo logra el mínimo con alrededor de 400 repeticiones. Mientras que en la Fig. 3, se ilustran los resultados con los parámetros $c_1=0.5$, $c_2=0.5$, la función converge en más de 300 iteraciones. En la Fig. 4, se presentan los resultados con los parámetros $c_1=0.95$, $c_2=0.05$, la función converge en 400 iteraciones, al igual que en la Fig. 5, la que usa $c_1=0.05$, $c_2=0.95$. En la Fig. 6 se presentan los resultados con los parámetros $c_1=0.95$, $c_2=0.95$, la función converge en menos de 400 iteraciones.

Todos los resultados de las métricas aplicadas para evaluar la exactitud de la estimación se muestran en la Tabla 1. A partir de los resultados se puede observar que valores muy pequeños de c_1 y c_2 (cerca de cero) obtienen baja exactitud en la estimación de costos de fabricación de tubería, en tanto que la mejor exactitud es lograda por medio de una ANN cuyos coeficientes de aceleración son mayores o iguales a 0.5. Los resultados presentados en las tablas guardan relación con las aseveraciones de Duarte y Quiroga (2010), quienes determinan que los dos coeficientes de aceleración cercanos a cero producirán una búsqueda fina en una región, mientras coeficientes cercanos a uno permitirán a la partícula la posibilidad de sobrepasar al G_{best} y al P_{best} , resultando en una búsqueda amplia.




Gráfico 1. ANN (3,5,1), Fitness MSE, $c_1=0.05$, $c_2=0.05$

Fuente: (Bodero y Leguizamón, 2018)




Gráfico 2. ANN (3,5,1), Fitness MSE, $c_1=0.2$, $c_2=0.2$

Fuente: (Bodero y Leguizamón, 2018)




Gráfico 3. ANN (3,5,1), Fitness MSE, $c_1=0.5$, $c_2=0.5$

Fuente: (Bodero y Leguizamón, 2018)




Gráfico 4. ANN (3,5,1), Fitness MSE, $c_1=0.05$, $c_2=0.95$
Fuente: (Bodero y Leguizamón, 2018)




Gráfico 5. ANN (3,5,1), Fitness MSE, $c_1=0.95$, $c_2=0.05$
Fuente: (Bodero y Leguizamón, 2018)




Gráfico 6. ANN (3,5,1), Fitness MSE, $c_1=0.95$, $c_2=0.95$

Fuente: (Bodero y Leguizamón, 2018)

Tabla 1: Resultados de la exactitud en la estimación, para los coeficientes de aceleración c_1 y c_2

c_1	c_2	RMSE	R^2
0.05	0.05	0.1937	
	53.0%		
0.2	0.2	0.1859	56.8%
0.5	0.5	0.0640	94.9%
0.05	0.95	0.0615	95.3%
0.95	0.05	0.1031	88.2%
0.95	0.95	0.0623	95.1%
2.95	2.95	0.0618	95.3%
5.95	2.95	0.0612	95.2%
5.95	5.95	0.0612	95.3%
10	10	0.0675	95.3%

Fuente: Barba y Bodero (2017)

**los valores obtenidos en las métricas RMSE R^2 en el presente experimento, no difieren en mayor medida de los obtenidos por medio de un modelo neuronal más complejo, una ANN recurrente aplicada por Barba y Bodero (2017), para analizar los mismos datos.

Conclusiones

Al finalizar la investigación, se muestran las siguientes conclusiones:

En el modelo del algoritmo PSO el ajuste paramétrico de los coeficientes de aceleración c_1 y c_2 son variaciones consideradas importantes:

Las partículas serán independientes cuando $c_1 > 0$ y $c_2 = 0$, y colectivas con $c_1 = 0$ y $c_2 > 0$.

Las partículas serán atraídas por un valor promedio si $c_1 = c_2 > 0$.

La experiencia propia es mayor que la del grupo si $c_1 > c_2$ y la experiencia del grupo es mayor que la propia con $c_1 < c_2$.

Si c_1 y c_2 disminuyen, las trayectorias de desplazamiento de las partículas son suaves.

Si c_1 y c_2 aumentan, entonces los movimientos de las partículas serán abruptos.

Un mal ajuste de los parámetros puede provocar que el PSO converja a una solución en pocas iteraciones, o a una buena solución en muchas iteraciones. A menudo, PSO puede encontrar una mala solución en pocas iteraciones, conocida como convergencia prematura, o una mala solución en muchas iteraciones.

La capacidad de ajustar las posiciones de las partículas en un espacio de soluciones satisfactoria, tomando en cuenta la función objetivo a minimizar (Error Cuadrático Medio - MSE) garantizó el éxito del algoritmo del experimento. Para valores muy pequeños de c_1 y c_2 (cerca de cero) se obtiene una baja exactitud en la estimación de costos de fabricación de tubería. Una ANN ofrece mayor exactitud con coeficientes de aceleración mayores o iguales a 0.5, como lo indican en su estudio Duarte y Quiroga (2010).

Los resultados alcanzados en las métricas RMSE R^2 en este experimento utilizando una ANN tipo feedforward sigmooidal con aprendizaje PSO no difieren significativamente de los obtenidos por medio de una ANN recurrente aplicada por Barba y Bodero (2017), para analizar los mismos datos.

Referencias bibliográficas

- Barba, L., Rodríguez, N. (2015). Traffic Accidents Forecasting using Singular Value Decomposition and an Autoregressive Neural Network Based on PSO. *Cielo*, 33-38.
- Barba, L., Bodero, E. (2017). Redes Neuronales Artificiales para Estimación de Costos de Construcción Industrial. V Congreso Internacional de Investigación y Actualización en Ingenierías, Galápagos (Ecuador), 269-278.
- Bodero, E., Leguizamón G. (2018). Efecto de los coeficientes de aceleración de PSO en el desempeño de una Red Neuronal Artificial aplicada a la Estimación de Costos, *Revista Facultad de Ingeniería* Universidad Nacional de Chimborazo, NovaSinergia, Vol. 1, 33-40.
- Carlisle, A., Dozier, G. (2001). "An off-the-self PSO", *Proceedings of the Workshop on Particle Swarm Optimization*, Indianapolis (USA), pp. 1-6.
- Chang, R., Lu, C.N. (2002). "Feeder reconfiguration for load factor improvement", *Proceedings of the IEEE Power Engineering Society Winter Meeting*, New York (USA), Vol. 2, pp. 980-984.

- Dokić A., & Jović S. (2017). Evaluation of agriculture and industry effect on economic health by ANFIS approach, *Physica A: Statistical Mechanics and its Applications*, Volume 479, 2017, Páginas 396-399.
- Duarte, C., Quiroga, J. (2010). "Algoritmo PSO para identificación de parámetros en un motor DC." *Revista Facultad de Ingeniería Universidad de Antioquia* 55.
- Eberhart, R., Hu, X. (1999). "Human tremor analysis using particle swarm optimization", *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99*, Washington (USA), Vol. 3, pp. 1927-1930.
- Eberhart, R., Shi, Y. (2001). "Particle swarm optimization: developments, applications and resources", *Proceedings of the 2001 Congress on Evolutionary Computation*, Seoul (South Korea), Vol. 1, pp. 81-86.
- Franken, N., Engelbrecht, A.P. (2004). "PSO approaches to co-evolve IPD strategies", *Proceedings of the 2004 IEEE Congress on Evolutionary Computation*, Oregon (USA), pp. 356-363.
- Gaing, Z-L. (2003). "Discrete particle swarm optimization algorithm for unit commitment", *Proceedings of the 2003 IEEE Power Engineering Society General Meeting*, Toronto (Canada), Vol. 1, pp. 418-424.
- Hu, X., Eberhart, R. (2002). "Adaptive particle swarm optimization: detection and response to dynamic systems", *Proceedings of the 2002 Congress on Evolutionary Computation-CEC02*, Honolulu (USA), Vol. 2, pp.1666-1670.
- Hu, X., Eberhart, R., Shi, Y. (2003). "Engineering optimization with particle swarm", *Proceedings of the 2003 IEEE Swarm Intelligence Symposium*, Indianapolis (USA), pp. 53-57.
- Ismail, A., Engelbrecht, A. (2000). "Global optimization algorithms for training product unit neural networks", *Proceedings of IEEE-INNS-ENNS International Joint Conference on Neural Networks*, Como (Italy), Vol. 1, pp. 132-137.
- Kennedy, J. (1997). "The particle swarm: social adaptation of knowledge", *Proceedings of the 1997 IEEE International Conference on Evolutionary Computation-ICEC97*, Indianapolis (USA), pp. 303-308.
- Kennedy, J., Eberhart, R. (1995). "Particle swarm optimization", *Proceedings of the IEEE International Conference on Neural Networks-ICNN'95*, Perth (Australia), Vol.4, pp. 1942-1948.
- Kennedy, J., Eberhart, R. (2001). "Swarm intelligence", Morgan Kaufmann Publishers, San Francisco.
- Koay, C.A., Srinivasan, D. (2003). "Particle swarm optimization-based approach for generator maintenance scheduling", *Proceedings of the 2003 IEEE Swarm Intelligence Symposium*, Indianapolis (USA), pp. 167-173.
- Laskari, E., Parsopoulos, K., Vrahatis, M. (2002). "Particle swarm optimization for minimax problems", *Proceedings of the 2002 Congress on Evolutionary*

- Computation-CEC02*, Honolulu (USA), Vol. 2, pp. 1576-1581.
- Lu, Z-S., Yan, S. (2004). "Multiuser detector based on particle swarm algorithm", *Proceedings of the IEEE 6th CAS Symposium on Emerging Technologies: Frontiers of Mobile and Wireless Communication*, Shanghai (China), pp. 783-786.
- Millonas, M.M. (1994). "Swarms, phase transitions, and collective intelligence", *Proceedings of Artificial life III*, Vol. XVII, SFI Studies in the Sciences of Complexity, Addison-Wesley.
- Miranda, V., Fonseca, N. (2002). "EPSO – Evolutionary particle swarm optimization, a new algorithm with applications in power systems", *IEEE/PES Transmission and Distribution Conference and Exhibition, Porto Alegre (Brazil)*, Vol. 2, pp. 745-750.
- Naka, S., Genji, T., Yura, T., Fukuyama, Y. (2001). "Practical distribution state estimation using hybrid particle swarm optimization", *Proceedings of 2001 Winter Meeting of the IEEE Power Engineering Society*, Columbus (USA), Vol. 2, pp. 815-820.
- Naka, S., Genji, T., Yura, T., Fukuyama, Y. (2003). "A hybrid particle swarm optimization for distribution state estimation", *IEEE Transactions on Power Systems*, Vol. 18, No. 1, pp. 60-68.
- Parmee, I. C. (2003). *Computational intelligence and civil engineering-perceived problems and possible solutions*, in *Towards a Vision for Information Technology in Civil Engineering*, I. Flood, Ed., ASCE, Nashville, Tenn, USA.
- Rodriguez, N., Duran, O. (2013). *Reduced Multivariate Polynomial Model for Manufacturing Costs Estimation of Piping Elements*, Hindawi Publishing Corporation *Mathematical Problems in Engineering*, Vol. 2013.
- Sholahuddin, A. Ramadhan. A. Supriatna, A. (2015). The Application of ANN-Linear Perceptron in the Development of DSS for a Fishery Industry, *Procedia Computer Science*, Volume 72, 2015, Pages 67-77.
- Srinivasan, D., Loo, W., Cheu, E. (2003). "Traffic incident detection using particle swarm optimization", *Proceedings of the 2003 IEEE Swarm Intelligence Symposium*, Indianapolis (USA), pp. 144-151.
- Svozil, D. Kvasnicka, V., & Pospichal. J. (1997). Introduction to multi-layer feed-forward neural networks, *Chemometrics and Intelligent Laboratory Systems*, Volume 39, Issue 1, 1997, Pages 43-62.
- Tasgetiren, M.F., Liang, Y-C. (2003). "A binary particle swarm optimization algorithm for lot sizing problem", *Journal of Economic and Social Research*, Vol. 5, No. 2, pp. 1-20.
- Veeramachaneni, K., Osadciw, L.A. (2004)1. "Optimal scheduling in sensor networks using swarm intelligence", *Proceedings of the Conference on Information Sciences and System*, Princeton University, New Jersey (USA).
- Veeramachaneni, K., Osadciw, L.A. (2004)2. "Dynamic sensor management using

- multi objective particle swarm optimizer", *Proceedings of the SPIE*, Vol. 5434, Multisensor, Multisource Information Fusion: Architecture, Algorithms, and Applications 2004, pp. 205-216.
- Vesterstrom, J., Riget, J. (2002). "Particle swarms: Extensions for improved local, multi-modal, and dynamic search in numerical optimization", Master's Thesis, University of Aarhus.
- Wang, Z., Durst, G., Eberhart, R., Boyd, D., Miled, Z. (2004). "Particle swarm optimization and neural network application for QSAR", *Proceedings of the 18th International Parallel and Distributed Processing Symposium (IPDPS'04)*, New Mexico, (USA).
- Yangyang, Z., Chunlin, J.I., Ping, Y., Manlin, L.I., Chaojin, W., Guangxing, W. (2004). "Particle swarm optimization for base station placement in mobile communication", *Proceedings of the 2004 IEEE International Conference on Networking, Sensing & Control*, Taipei (Taiwan), pp. 428-432.
- Zhao, Y., Zheng, J. (2004). "Particle swarm optimization algorithm in signal detection and blind extraction", *Proceedings of the 7th International Symposium on Parallel Architectures*, Hong Kong (China), pp. 37-41.