

# Sistema neuro-borroso de apoyo al control de la ejecución de proyectos

**Anié Bermudez Peña**

Correo electrónico:abp@uci.cu

**Artículo Original**

**José Alejandro Lugo García**

Correo electrónico:jalugo@uci.cu

**Ilíana Pérez Pupo**

Correo electrónico:iperez@uci.cu

**Pedro Yobanis Piñero Pérez**

Correo electrónico:ppp@uci.cu

Universidad de las Ciencias Informáticas (UCI), La Habana, Cuba

**Gil Cruz Lemus**

Correo electrónico:gil@tesla.cujae.edu.cu

Instituto Superior Politécnico José Antonio Echeverría, Cujae, La Habana, Cuba

## Resumen

Durante el control de ejecución a sus proyectos, las organizaciones emplean disímiles herramientas para asistir a los especialistas en la toma de decisiones. Con el objetivo de lograr una valoración integral del proyecto, se examina un conjunto de indicadores claves (tiempo, costos, calidad, logística y rendimiento de recursos humanos) aplicando técnicas de *soft computing* mediante el uso de sistemas de inferencia borrosos. Sin embargo, en ocasiones, las reglas de inferencia borrosas que evalúan los indicadores se construyen a partir del juicio de expertos, lo cual introduce imprecisiones y vaguedad en los límites de los conceptos lingüísticos. En este trabajo, se propone un sistema neuro-borroso de apoyo al control de la ejecución de proyectos, que permite optimizar la base de reglas existente de manera eficiente y eficaz. Los beneficios potenciales de la propuesta se relacionan con la mejora en la toma de decisiones en organizaciones orientadas a la producción por proyectos.

Palabras claves: control de ejecución de proyectos, optimización de reglas borrosas, sistema neuro-borroso, *soft computing*, toma de decisiones

Recibido: 17 septiembre del 2013

Aprobado: 8 de abril del 2014

## INTRODUCCIÓN

El éxito de los proyectos depende de la aplicación e integración adecuada de los procesos de dirección: inicio, planificación, ejecución, seguimiento y control, y cierre. Especialmente el proceso de seguimiento y control se encarga de medir y supervisar regularmente el avance, a fin de identificar las variaciones respecto al plan de gestión del proyecto, de tal forma que se tomen medidas correctivas cuando sea necesario para cumplir con los objetivos del proyecto. Además, permite anticipar posibles polémicas, de modo que puedan ser tratadas antes de que se conviertan

en críticas. La aplicación apropiada de conocimientos, procesos, habilidades, herramientas y técnicas tiene un impacto significativo en el éxito de los proyectos [1].

El desarrollo de la Dirección Integrada de Proyectos (DIP), apoyada por los sistemas informáticos profesionales, permite llevar a cabo un cronograma de ejecución y sobre este mostrar el avance del proyecto a través de un conjunto de indicadores claves, que reflejen su comportamiento, destacando los problemas y sus causas para realizar la toma de decisiones a partir de una estrategia de prioridades previamente establecidas [2].

La mala gestión de proyectos y las insuficiencias en el manejo de los datos en la DIP causan innumerables pérdidas económicas con elevado impacto social. Entre las principales causas de fracaso en esta área se pueden citar:

- Falta de conocimiento de buenas prácticas y experiencia en el seguimiento y control de proyectos.
- Debilidades de las herramientas para la evaluación automática o semiautomática de proyectos de manera eficiente (tiempo y recursos) y eficaz (calidad en la clasificación).
- Dificultades en el tratamiento de la incertidumbre de los datos y la ambigüedad.

Los avances tecnológicos en la esfera de la gestión de proyectos han posibilitado conocer en un instante la acción que es necesario tomar para solucionar un problema. Esto se debe a las herramientas de soporte a la toma de decisiones, que están fundamentadas en indicadores claros y medibles. No obstante, el empleo de estas herramientas continúa marcado por el uso de métodos tradicionales para el análisis de información donde se identifican los siguientes aspectos:

- Presencia de datos numéricos.
- Incertidumbre en los datos, ruido provocado por errores de medición y la apreciación de las personas.
- Vaguedad en los conceptos para la toma de decisiones.

Una alternativa de solución es la introducción de técnicas de *soft computing* que promueven la competencia y la calidad, en particular los sistemas de inferencia borrosos (SIB) y neuro-borrosos [3].

Con el objetivo de lograr una valoración integral en una fecha de corte del proyecto, se realiza la evaluación de un conjunto de indicadores de forma cualitativa y cuantitativa, aplicando técnicas de *soft computing*. Estos indicadores están relacionados con áreas de conocimiento claves de la gestión de proyectos correspondientes a tiempo, costos, calidad, logística y rendimiento de recursos humanos [4]. Sin embargo, en ocasiones, las reglas de inferencia borrosas que procesan los indicadores se construyen a partir del juicio de expertos, lo cual introduce imprecisiones y vaguedad en los límites de los conceptos lingüísticos. Las insuficiencias en la adaptación y el aprendizaje automático en los sistemas para la evaluación de proyectos afectan la calidad de la clasificación en la ayuda a la toma de decisiones.

Como objetivo de este trabajo se propone un sistema neuro-borroso (SNB) con un algoritmo de aprendizaje inspirado en redes neuronales artificiales (RNA) que permitan optimizar la base de reglas existente para la evaluación de la ejecución de proyectos de manera eficiente y eficaz.

En la siguiente sección, se analizan las principales investigaciones en el ámbito del empleo de mecanismos de apoyo al control de la ejecución de proyectos mediante hibridación con técnicas de *soft computing*, así como tendencias en la optimización de reglas de inferencia borrosas aplicables a dicho fin. A partir de ese análisis se deciden ajustar los parámetros de las funciones de pertenencia de

los conjuntos borrosos de un sistema de inferencia mediante técnicas basadas en redes neuronales. También se muestran los pasos detallados que se aplican para el desarrollo del SNB. Dichos pasos incluyen la definición de un SNB híbrido tipo Sugeno Grado Cero, el diseño de la topología de la red neuronal y el modelo de las neuronas de cada capa. Para la optimización de las reglas borrosas se concibe un novedoso algoritmo de aprendizaje supervisado basado en redes neuronales. El artículo continúa con los resultados de la aplicación del sistema en la herramienta de gestión de proyectos Xedro-GESPRO [5], con las principales vistas de generación de reportes para la evaluación de proyectos mediante indicadores. Finalmente se arriba a las conclusiones.

## MÉTODOS

Como parte de la investigación se elabora un marco teórico sobre investigaciones en el ámbito del empleo de mecanismos de apoyo al control de la ejecución de proyectos mediante hibridación con técnicas de *soft computing*, así como tendencias en la optimización de reglas de inferencia borrosas aplicables a dicho fin. El análisis arroja las principales corrientes y mecanismos existentes hasta la actualidad. Más adelante, en esta sección, se detallan los pasos definidos para el desarrollo del SNB propuesto, los cuales son:

- Definición del SIB tipo Sugeno Grado Cero.
- Diseño del SNB híbrido.
- Diseño de la topología de la red neuronal.
- Diseño del modelo de las neuronas de cada capa.
- Definición del algoritmo de aprendizaje basado en redes neuronales.

### Control de la ejecución de proyectos y *soft computing*

En los últimos años investigaciones como las propuestas por Dweiri [6], Bhatt [7], Gao [8], Certa [9] y Newada [10] han recomendado soluciones teóricas basadas en técnicas de *soft computing* útiles para el control de la ejecución de proyectos. Lugo [4] propone un nuevo modelo para el control de la ejecución de proyectos utilizando indicadores y lógica borrosa, aplicado sobre una herramienta de gestión de proyectos (Xedro-GESPRO). Sin embargo, aún no se resuelven de forma práctica los problemas relacionados con el apoyo al control de la ejecución de proyectos, partiendo del uso de mecanismos de optimización de reglas borrosas, que permitan mejorar la calidad de la evaluación de la ejecución en forma eficiente y eficaz. La aplicación de este enfoque puede mejorar la toma de decisiones en organizaciones orientadas a la producción por proyectos.

### Tendencias en la optimización de reglas de inferencia borrosas

El centro de los sistemas borrosos es la base de reglas. Cuando esta es construida solamente a partir del conocimiento adquirido por un experto o grupo de ellos, podría no funcionar correctamente al ser aplicada. Las principales causas son debidas a que los expertos pueden equivocarse en cuanto a la localización de los parámetros correspondientes a las

funciones de pertenencia de los conjuntos borrosos, respecto al número de reglas o en relación con los antecedentes y consecuentes que la forman.

En el aprendizaje y la optimización de las reglas borrosas se pueden aplicar varios enfoques [3]:

- Generar reglas duras y transformarlas en borrosas.
- Generar la base de reglas borrosas candidatas y refinarlas.
- Generar la base de reglas borrosas inicial y optimizarlas.

La presente investigación se centra en el tercer enfoque. Se parte de un conjunto de reglas inicial, que permite realizar la evaluación de proyectos según varios indicadores.

Para optimizar la base de reglas se pueden aplicar varias alternativas [3]:

- Asignarle pesos a las reglas borrosas y ajustarlos.
- Modificar los parámetros de las funciones de pertenencia.
- Transformar la estructura de la base de reglas.
- alguna combinación de las anteriores.

El presente trabajo parte de un conjunto de reglas iniciales que se optimizan mediante el ajuste de los parámetros de las funciones de pertenencia de los conjuntos borrosos. Para ello se tienen en cuenta casos de proyectos terminados de los que se conoce su correcta evaluación por expertos obtenida a partir del método Delphi.

En el ajuste de las funciones de pertenencia de los conjuntos borrosos sobresalen las siguientes tres estrategias [3]:

- Métodos derivados de RNA basados en el gradiente.
- Métodos heurísticos que no usan información de gradiente.
- Algoritmos evolutivos, principalmente Algoritmos Genéticos (AG).

La estrategia a) tiene su base en la probada efectividad de los mecanismos de aprendizaje de las RNA, algoritmos como el *backpropagation* son muy utilizados. Su principal limitación está dada por la restricción que impone a las funciones de pertenencia de los conjuntos borrosos, que deben ser derivables ya que basan su funcionamiento en el cálculo del gradiente. Una estrategia que ha ganado en popularidad es la combinación de gradiente descendente con otros métodos [11]. Existen varias aplicaciones de algoritmos que siguen la estrategia a) combinada con otros métodos, para el aprendizaje y la optimización [12, 13].

La estrategia b) basa su funcionamiento en la aplicación de heurísticas y no de gradiente. En varios de los métodos analizados se detecta que al realizar la modificación de los parámetros no se tiene en cuenta las relaciones entre diferentes conjuntos borrosos y se obvia el concepto de variable lingüística [3, 13].

La estrategia c) optimiza las reglas utilizando algoritmos evolutivos, especialmente AG. Este enfoque tiene como base la probada eficiencia de los algoritmos evolutivos en la optimización y las pocas restricciones que imponen a los modelos. Sin embargo, los AG clásicos presentan dificultades en la optimización de funciones con interacciones no lineales entre las variables debido a que por su naturaleza están preparados para el trabajo con variables independientes [13, 14].

Los SNB pertenecen a la estrategia b). Estos aúnan la capacidad de aprendizaje de las RNA, con la facilidad de trabajo con información incierta y su traducción a reglas, de los SIB [15]. La unión de ambas técnicas permite ganar en robustez, eficiencia, adaptabilidad y equilibrio adecuado entre poder de predicción y facilidad de interpretación.

Se decide implementar un SNB para la optimización de reglas de inferencia borrosas que permita mejorar la calidad de la clasificación en la evaluación de proyectos durante el proceso de seguimiento y control del avance de los mismos.

### Sistema de inferencia borroso tipo Sugeno

El SIB aplicado se basa en un modelo tipo Sugeno [16], caracterizado por tener entradas lingüísticas y procesar (agregar) los datos mediante un clasificador (reglas borrosas). Devuelve como salida los grados de pertenencia a los términos lingüísticos utilizados para expresar el resultado final. Este modelo carece de desborrador, siendo la función de salida una combinación polinomial del resultado de agregación de las variables de entrada. Para la aplicación en problemas de clasificación, con frecuencia, se utiliza el Sugeno Grado Cero por la estructura de las reglas que este tipo de sistema representa [3]. Este modelo también conocido como TSK, por sus autores Takagi, Sugeno y Kang [16], utiliza reglas de la forma: Si "*x* es *A*" y "*y* es *B*" entonces *z* = *f*(*x*, *y*), como se muestra en la figura 1. Donde *A* y *B* son conjuntos borrosos en el antecedente y *z* usualmente es un polinomio *f*(*x*, *y*), cuyo grado determina el grado del modelo borroso. Cuando *f* es una constante al sistema borroso correspondiente se le llama "modelo borroso Sugeno de Grado Cero".




Fig. 1. Representación de bloques que ilustra el funcionamiento de un SIB tipo Sugeno

### Sistema de inferencia neuro-borroso híbrido

Existen dos tipos de combinaciones de RNA y SIB con el objetivo de optimizar un SIB: los sistemas cooperativos y los sistemas híbridos. En el primer enfoque, la RNA y el SIB trabajan independientes, la combinación radica en la determinación de ciertos parámetros del SIB mediante una RNA. Se dice que el aprendizaje es *offline*, cuando la RNA se utiliza antes de la aplicación del SIB. Los parámetros que se ajustan pueden ser los de las funciones de pertenencia de los conjuntos borrosos, o bien los de la estructura de las reglas. Se dice que el SNB aprende los parámetros de forma online cuando se ajustan durante el uso del SIB. Para ello debe disponerse de un conjunto de funciones de pertenencia y de reglas borrosas iniciales, así como definir una medida de error que permita realizar el aprendizaje.

Los SNB híbridos presentan una arquitectura unificada; son capaces de aprender tanto *online* como *offline*, pero siempre en modo supervisado. La idea de un SNB híbrido es interpretar la base de reglas de un SIB en términos de una RNA, donde las variables de entrada y salida, así como las reglas pueden verse como neuronas. Uno de los primeros modelos de este tipo fue el Adaptive Network Fuzzy Inference System (ANFIS) propuesto por Jang en 1993 [17], el cual es aplicado actualmente en disímiles esferas [18, 19]. En este trabajo se aborda un problema de aprendizaje supervisado en un SNB híbrido. Las principales entradas del sistema son el conjunto inicial de reglas de inferencia borrosas con sus correspondientes funciones de pertenencia. El aprendizaje se realiza a partir de un conjunto de objetos (proyectos terminados) dados como entrada, donde se conoce su clasificación correcta (bien, regular o mal). A partir de la muestra de proyectos se induce nuevo conocimiento (ajuste de los parámetros de las funciones de pertenencia de los conjuntos borrosos). Una vez entrenada la red se podrá introducir un proyecto nuevo y evaluarlo adecuadamente. La figura 2 muestra la representación general del SNB híbrido definido, en el cual se ajustan los parámetros de los conjuntos borrosos mediante el cálculo del error de la clasificación que da el sistema como respuesta, contra el conjunto de entrenamiento (proyecto con clasificación correcta).

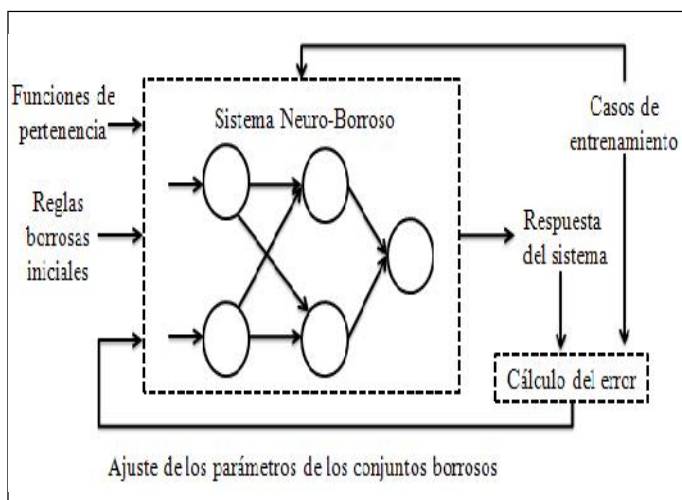


Fig. 2. Esquema de un SNB híbrido para el aprendizaje de los parámetros de las funciones de pertenencia

### Diseño de la topología de la red orientada a nodos

El SNB tiene una topología de red orientada a nodos. Los parámetros de las funciones de pertenencia residen dentro de los nodos. Esta topología facilita la interpretación del sistema de inferencia al no tener en cuenta pesos en las conexiones, cuyo significado semántico con frecuencia es difícil de explicar [3]. Las capas de la red no están completamente conectadas sino que las conexiones tienen lugar a partir de la presencia de las reglas borrosas y las relaciones que estas representan dentro del sistema borroso. Las variables de entrada y salida, así como las reglas se tratan como neuronas en la red. En la capa de los antecedentes se encuentran los conjuntos borrosos correspondientes a los indicadores y sus funciones de pertenencia, esta es la capa principal donde tiene lugar las modificaciones durante el aprendizaje. En la capa de los consecuentes se encuentran los conjuntos borrosos concernientes a la evaluación del proyecto. La última capa corresponde a la evaluación final que brinda el SNB para el proyecto. La figura 3 muestra una red de cinco capas orientada a nodos representativa del problema.

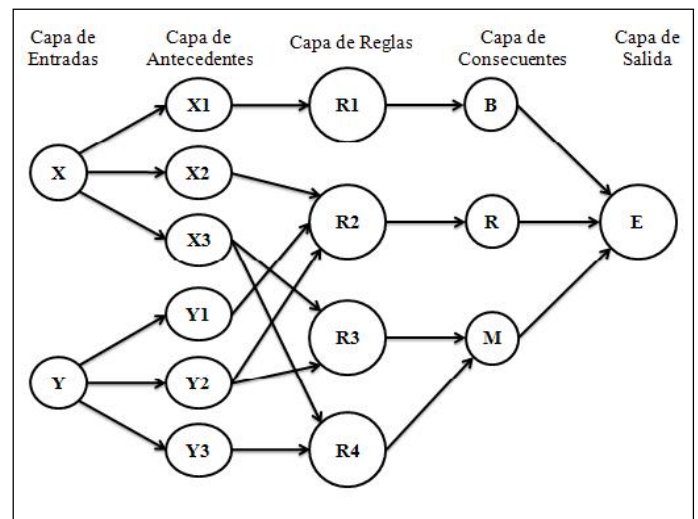


Fig. 3. SNB con topología de red de 5 capas y orientado a nodos

En la modelación borrosa se definen como variables lingüísticas los indicadores que permiten medir el desempeño de los recursos humanos, el costo, la calidad, el tiempo y la logística. Como conjuntos borrosos asociados a una misma variable, se definen los términos bajo, medio y alto; correspondientes a la evaluación parcial del proyecto en función del grado de pertenencia a dichos conjuntos borrosos de la variable de salida.

### Diseño del modelo de las neuronas

El modelo de neurona queda definido de manera diferente para cada capa de la red. A continuación se especifica el funcionamiento de cada capa de neuronas (entradas, salida y cálculos que realiza cada una).

**Capa 1:** cada unidad en esta capa representa los valores para cada indicador que permite evaluar el proyecto. Las neuronas solo transmiten sus entradas a los correspondientes



conjuntos borrosos (capa 2) que conforman la variable lingüística asociada al indicador en cuestión.

**Capa 2:** el modelo de neurona para las unidades de esta capa, almacena los parámetros de la función de pertenencia. Cada unidad se conecta a exactamente una unidad de entrada y calcula el grado de pertenencia del valor recibido al conjunto borroso. De la función de pertenencia depende la utilidad del conjunto borroso para modelar un concepto o una etiqueta lingüística. Para la representación y construcción de las funciones de pertenencia se utilizan los modelos matemáticos: funciones triangulares para el conjunto del medio y funciones trapezoidales para los conjuntos de los extremos (alto, bajo), como se muestra en las figura 4 y 5.

Los valores de  $a$ ,  $b$ ,  $c$  y  $d$  son los parámetros que se modifican durante el aprendizaje supervisado de la red. La función trapezoidal para los conjuntos bajos tiene  $a=b$ , así como para los conjuntos altos se hace  $c=d$ .

**Capa 3:** cada unidad en esta capa representa una regla de tipo Sugeno Grado Cero, que se conecta a sus correspondientes antecedentes en la capa 2 y sus consecuentes en la capa 4. Las entradas de cada neurona son los grados de pertenencia del proyecto a los correspondientes conjuntos borrosos de la capa 2 que son antecedentes de la regla representada por la neurona. El resultado de cada regla se computa a partir de la suma pesada de la evaluación de los conjuntos borrosos contenidos en sus antecedentes, donde cada indicador tiene un grado de responsabilidad en la evaluación del proyecto.

**Capa 4:** las unidades de esta capa son constantes que representan las clases del SIB. Dichas clases corresponden a la evaluación del proyecto de forma general: bien, regular y mal. Cada nodo de la capa de consecuentes computa todas las respuestas de las reglas relacionadas con él, devolviendo el mayor valor.

**Capa 5:** la neurona de salida se encarga de conformar la respuesta final del SNB híbrido, a partir del análisis de los nodos consecuentes presentes en la capa 4. El consecuente que indica el mayor grado de pertenencia es devuelto como respuesta del sistema.

#### Definición del algoritmo de aprendizaje del SNB

Este SNB es entrenado mediante un novedoso algoritmo de aprendizaje basado en RNA [3], que permite la utilización de funciones de pertenencia que no sean derivables. Su nivel computacional no es elevado. Aporta un enfoque híbrido donde se potencian las ventajas de cada estrategia. Este método de aprendizaje tiene en cuenta el concepto de variable lingüística y la interrelación entre los conjuntos borrosos de una misma variable lingüística. Para ello los elementos de las funciones de pertenencia se dividen en parámetros de posición y de amplitud, permitiendo determinar la localización y el solapamiento entre las funciones triángulo respectivamente. En la figura 4 el parámetro  $b$  es posición, mientras que  $a$  y  $c$  son parámetros de amplitud. En el momento de la modificación se calcula un término delta que se suma o resta al parámetro en cuestión.




Fig. 4. Representación de función de pertenencia triangular, aplicada en la capa 2 de la red




Fig. 5. Representación de función de pertenencia trapezoidal, aplicada en la capa 2 de la red

A continuación se muestran los pasos del algoritmo para la optimización de la base de reglas.

**Paso 1:** Inicializar:

1.1 Configuración del sistema de inferencia borroso, que contiene los parámetros de las funciones de pertenencia de los conjuntos borrosos.

1.2 Contador de iteraciones en 1.

1.3 Vector de transformaciones para cada conjunto borroso en (0,0), que contiene dos componentes para indicar la dirección de las modificaciones de los parámetros del conjunto borroso (posición y amplitud), donde un valor negativo indica un desplazamiento hacia la izquierda, un valor 0 significa no transformación y un valor positivo significa un desplazamiento hacia la derecha.

**Paso 2:** Inicializar contador de casos correctamente clasificados en la configuración actual igual a cero.

**Paso 3:** Para cada uno de los proyectos  $p$  del conjunto de entrenamiento no procesados en la actual iteración:

3.1 Clasificar  $p$ , propagándolo por el conjunto borroso, y calcular el error que cometió cada uno de los consecuentes. El error es la diferencia entre el valor real y el esperado. Este último es 0 si la clase a la que pertenece  $p$  es distinta de la que representa la componente y 1 en caso contrario.

3.2 Si el caso  $p$  fue correctamente clasificado, incrementar en 1 el contador de clasificaciones correctas.

3.3 Para cada regla de inferencia borrosa, calcular el error que cometió al clasificar al objeto  $p$ . Ver ecuación 1.

**Ecuación 1:** Cálculo del error de la regla  $i$  al clasificar al objeto  $p$ .

$$E_{Rip} = Y_{Rip} (1 - Y_{Rip}) (Y_{Rip} - D_{Rip})$$

$E_{Rip}$ : toma valores entre -1 y 1.

$Y_{Rip}$ : es el valor resultante de clasificar a  $p$  utilizando la regla  $i$ .

$D_{Rip}$ : es el valor de la salida esperada para esta regla respecto a  $p$ ; es 0 si la clase a la que pertenece  $p$  es distinta al consecuente de la regla  $Ri$  y 1 en caso contrario.

3.4 Para cada conjunto borroso, calcular su grado de responsabilidad en el error cometido por las reglas al clasificar al objeto  $p$ . Ver ecuación 2.

**Ecuación 2:** Cálculo de la responsabilidad del conjunto borroso  $\phi_j$  en la clasificación del objeto  $p$ .

$$E_{\{s_j p\}} = Y_{\{s_j p\}} (1 - Y_{\{s_j p\}}) \frac{\sum_{i=1}^{|B_R|} \text{ant}(\{s_j, R_i\}) \cdot E_{Rip}}{\sum_{i=1}^{|B_R|} \text{ant}(\{s_j, R_i\})} \quad -1 \leq E_{\{s_j p\}} \leq 1$$

Donde  $\text{ant}(\{s_j, R_i\})$  es 1 si el conjunto borroso  $\{s_j$  pertenece a la regla  $Ri$  y 0 en caso contrario.

$Y_{\{s_j p\}}$  es el grado de pertenencia al conjunto borroso  $\{s_j$  del valor del atributo de  $p$ .

3.5 Para cada conjunto borroso  $\{s_{jp}\}$  calcular su vector de transformación  $V_{\{s_{jp}\}} = (r_p, s_p)$  a partir de su comportamiento en la clasificación del caso  $p$ . Ver ecuación 3.

**Ecuación 3:** Cálculo del vector de transformación para las funciones triangulares.

$$r_p = \frac{\text{signo}(b - v_p) + 1}{2} \text{signo}(b - v_p) E_{\{s_{jp}\}}$$

$$s_p = \frac{1 - \text{signo}(b - v_p)}{2} \text{signo}(b - v_p) E_{\{s_{jp}\}}$$

**Paso 4:** Para cada conjunto borroso  $\{s_j\}$  calcular el error cometido en la clasificación del conjunto de entrenamiento en la presente iteración. Ver ecuación 4.

**Ecuación 4:** Cálculo del error de cada conjunto borroso.

$$E'_{\{s_j\}} = \frac{\sum_{p=1}^n |E_{\{s_j p\}}|}{n}$$

$$E_{\{s_j\}} = E'_{\{s_j\}} \cdot \sqrt{\prod_{j=1}^{|s|} E'_{\{s_j\}}}$$

Donde  $|s|$  representa la cantidad de conjuntos borrosos que forman parte de la variable lingüística  $s$ .

**Paso 5:** Calcular el vector de transformación del conjunto borroso  $\{s_j$  respecto a cada uno de los casos  $p$  del conjunto de entrenamiento. Ver ecuación 5.

**Ecuación 5:** Cálculo del vector de transformación de cada conjunto borroso.

$$V_{\{s_j(r, s)\}} = \frac{1}{n} \sum_{p=1}^n V_{\{s_j p\}}(r_p, s_p) \quad \text{tal que } -1 \leq r_{\{s_j\}}, s_{\{s_j\}} \leq 1$$

**Paso 6:** Si se cumple la condición de parada terminar, sino continuar. La estrategia seguida está compuesta por una cota de cantidad de iteraciones y un porcentaje de casos clasificados correctamente.

**Paso 7:** Ajustar los parámetros de los conjuntos borrosos de la configuración actual teniendo en cuenta el error cometido durante la clasificación del conjunto de entrenamiento.

7.1 Calcular el vector de transformación  $\dagger = \text{sen}(2\pi T/k)$ ,  $0 < \dagger < 1$ , donde  $T$  indica el número de la iteración actual y  $k \in \mathbb{N}$ ,  $k > 2$  es un valor que regula la frecuencia de repetición de dicho factor.

7.2 Construir una nueva configuración del sistema borroso a partir de la configuración actual y la configuración anterior.

Ver ecuación 6.

**Ecuación 6:** Cálculo de la nueva configuración del sistema de inferencia borroso.

$$\text{Si } T = 1 \text{ se considera } \left| a_{\zeta,i} - a_{\zeta,i-1} \right| = 1 \text{ y } \left| c_{\zeta,i} - c_{\zeta,i-1} \right| = 1$$

$$\text{Sino } \Delta a = \dagger \left| a_{\zeta,i} - a_{\zeta,i-1} \right| E_{\zeta,i}^s, \Delta c = \dagger \left| c_{\zeta,i} - c_{\zeta,i-1} \right| E_{\zeta,i}^s$$

Si  $(r_{\zeta} \cdot s_{\zeta} \leq 0)$  entonces

$$a_{\zeta,i+1} = a_{\zeta,i} + \Delta a \cdot \text{signo}(r_{\zeta}), c_{\zeta,i+1} = c_{\zeta,i} + \Delta c \cdot \text{signo}(s_{\zeta})$$

Sino

$$\Delta D = \frac{\Delta a + \Delta c}{2} \cdot \text{signo}(r_{\zeta}), a_{\zeta,i+1} = a_{\zeta,i} + \Delta D, b_{\zeta,i+1} = b_{\zeta,i} + \Delta D$$

$$, c_{\zeta,i+1} = c_{\zeta,i} + \Delta D$$

**Paso 8:** Incrementar en 1 el contador de iteraciones y retornar al paso 2.

El algoritmo garantiza por su propia definición, un aprendizaje independiente del orden en que aparecen los casos del conjunto de entrenamiento, ya que la modificación de los parámetros de los conjuntos borrosos se realiza en correspondencia con el error cometido durante la clasificación del conjunto de entrenamiento y no de forma secuencial a medida que se procesan los casos.

## RESULTADOS


Desarrollado por el Laboratorio de Investigaciones en Gestión de Proyectos de la Universidad de las Ciencias Informáticas, Xedro-GESPRO es una *Suite* de Gestión de Proyectos basada en software de código abierto. En esta, se aplican resultados con valor agregado para el producto [20-23] y el SNB propuesto.

Xedro-GESPRO permite la DIP mediante el control por cortes de indicadores relacionados con áreas de conocimiento claves de la gestión de proyectos correspondientes a tiempo, costos, calidad, logística y rendimiento de recursos humanos, calculados de forma automática mediante frecuencia configurable (tabla 1).

Con el objetivo de lograr una valoración integral del proyecto en el corte, se sugiere la evaluación de los indicadores de forma cualitativa (bien, regular o mal) y cuantitativa, aplicando técnicas de *soft computing* mediante el uso de sistemas de inferencia borrosos que permiten evaluar y ponderar los indicadores. Los indicadores y la evaluación de la ejecución del proyecto se presentan en un cuadro de mando integral soportado por un sistema de colores y texto que indican la evaluación. La combinación de colores y texto garantiza

principios de accesibilidad para el trabajo de personas con discapacidad visual. Se incluyen en el cuadro de mando integral, una explicación de la inferencia basada en la respuesta del sistema respecto a la certidumbre en la inferencia de cada clase, como se muestra en la figura 6.

Tabla 1 Principales indicadores propuestos por áreas de conocimiento [4]	
Indicadores	Áreas de conocimiento en la Gestión de Proyectos
Evaluación de la ejecución del proyecto	Gestión de integración
IRE (Índice de rendimiento de la ejecución)	Gestión del cliente y los compromisos
IRP (Índice de rendimiento de la planificación)	Gestión de tiempo
IRC (Índice de rendimiento de los costos)	Gestión de costos
IREF (Índice de rendimiento de la eficacia)	Gestión de alcance y calidad
IRRH (Índice de rendimiento de los recursos humanos)	Gestión de Recursos Humanos
IRL (Índice de rendimiento de la logística)	Gestión de logística
ICD (Índice de calidad del dato)	Consistencia de la información



**Fig. 6.** Vista de los indicadores generados a nivel de proyecto (reporte de Xedro-GESPRO)

La combinación de colores y texto garantiza principios de accesibilidad para el trabajo de personas con discapacidad visual. Se incluyen en el cuadro de mando integral una explicación de la inferencia basada en la respuesta del sistema respecto a la certidumbre en la inferencia de cada clase.

Se presenta además en el sistema Xedro-GESPRO, un conjunto de reportes organizados por áreas de conocimiento que complementan la toma de decisiones y permiten generar información detallada del proyecto o centro, como se muestra en la figura 7.

Estos indicadores, una vez calculados, son guardados en una base de datos histórica de proyectos terminados, donde se almacena además una evaluación periódica de expertos (utilizando el método Delphi-salida esperada) a dichos proyectos en fechas de corte específicas. Esta fuente de información sirve como base para el aprendizaje y optimización de reglas borrosas existentes.

Para la validación del SNB se emplearon dos mecanismos. El primero, compara la clasificación obtenida por el SNB mediante un procedimiento de validación cruzada. En este, el algoritmo del SNB ajusta las reglas al tener como condición de parada en el entrenamiento de la red una cantidad de iteraciones máxima y una cota de error  $E$  (diferencia entre la salida deseada y la salida calculada por la red) establecida inicialmente, donde  $E$  es lo suficientemente pequeño como para no afectar el resultado global. El segundo mecanismo toma una muestra de 150 proyectos de una base de datos de proyectos terminados, que sirven como casos de entrenamiento. En la tabla 2 se presenta un fragmento de los resultados obtenidos, donde las tres últimas columnas muestran, para cada proyecto, dada una fecha de corte: la evaluación de expertos empleando el método Delphi, la evaluación dada por el sistema de reglas de inferencia borrosas construidas a partir del juicio de expertos y la evaluación dada por el SNB propuesto.

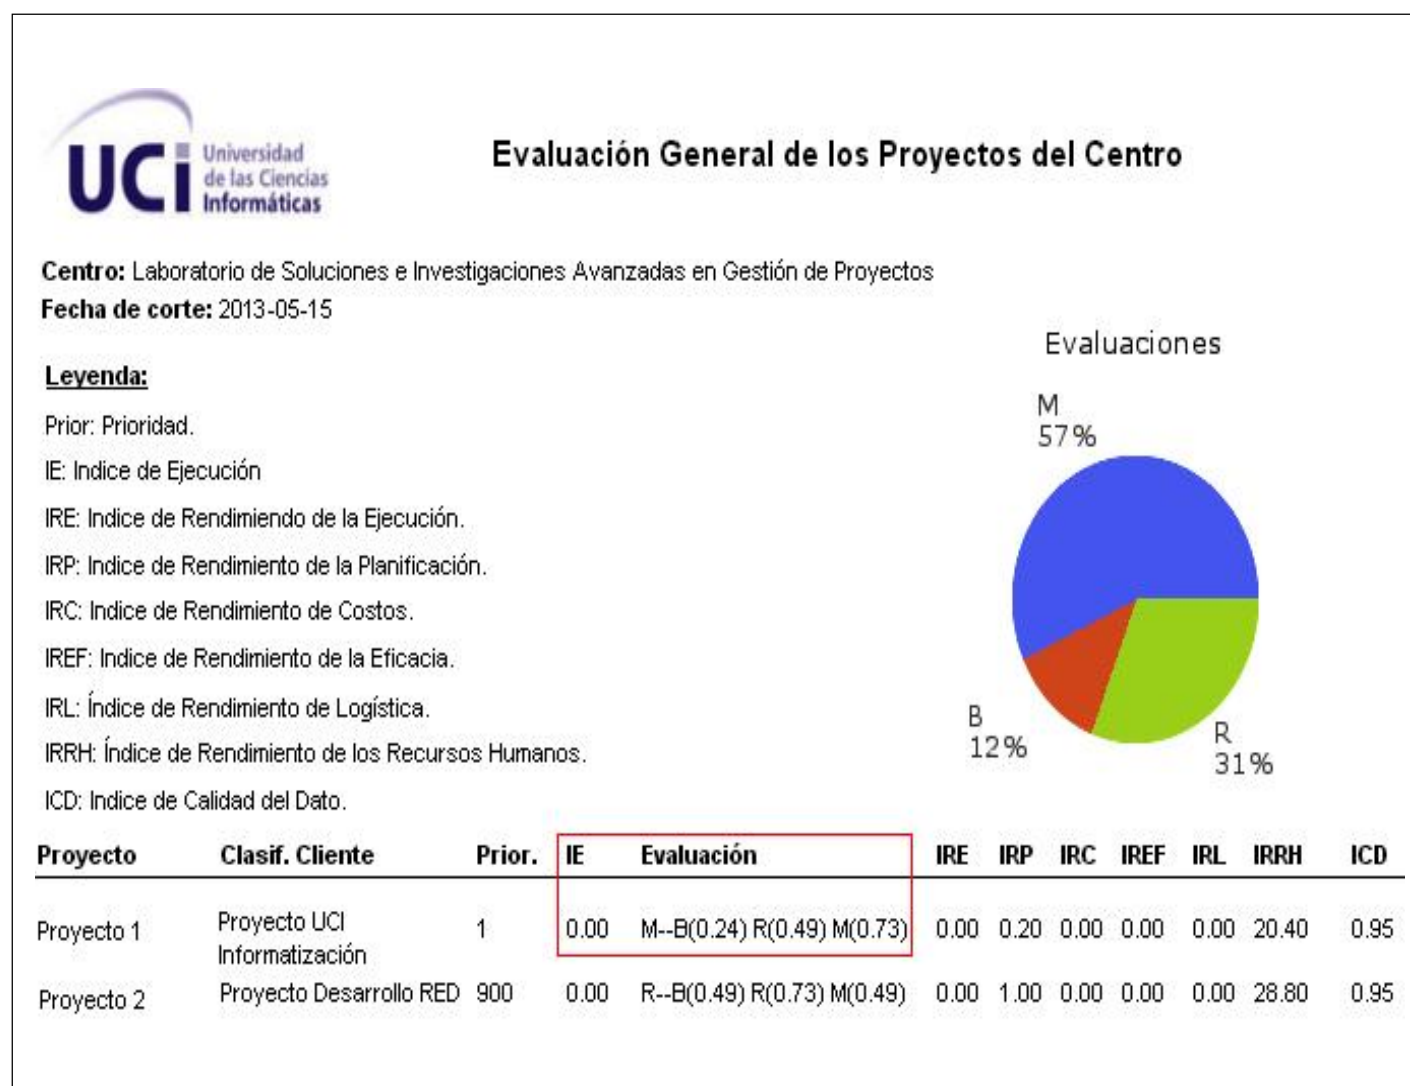


Fig. 7. Vista de reporte de la clasificación de los proyectos mediante SNB tipo Sugeno Grado Cero



Tabla 2  
Extracto de información empleada para validar el SNB

Fecha de corte	Proyecto	IRE	IRP	IRC	IREF	IRRH	IRL	ICD	Eval. expertos Método Delphi	Eval. SIB reglas expertos	Eval. SNB propuesto
14/12/2013	P1	1,36	1,06	0	0,52	82,3	0	1	B	B	B
14/12/2013	P2	1,26	1,33	0	0,29	50	0,99	1	R	B	B
14/12/2013	P3	1,21	1,06	0	0,54	82,3	0	0,99	B	R	B
14/12/2013	P4	1,19	1,04	0	0,59	81,1	0,99	1	B	R	B
14/12/2013	P5	1,19	1,09	0	0,54	82,15	0	0,99	R	M	R
...	...	...	...	...	...	...	...	...	...	...	...
14/12/2013	P150	1,16	1,00	0	0,72	79	0	0,97	B	R	B

## DISCUSIÓN

Utilizando como salida esperada de los casos de entrenamiento, la evaluación obtenida por el método Delphi (tabla 2), se observa una mejora en la clasificación dada por el SNB (91 %) en comparación con la clasificación del sistema de reglas de inferencia borrosas construidas a partir del juicio de expertos (72 %). Los datos empleados fueron sometidos a un proceso de preprocesamiento (selección, limpieza y transformación), con el objetivo de obtener un conjunto representativo de proyectos del universo de discurso donde fueron realizadas las pruebas.

El mecanismo automatizado que almacena el valor de los indicadores por proyectos se ejecuta semanalmente. Esto permite contar con una base de conocimiento confiable y actualizada obtenida con un mínimo de esfuerzo y errores en las operaciones de cálculo. Se promueve una evaluación periódica por expertos con frecuencia semestral de los proyectos almacenados en la base de datos de proyectos terminados, que permita contar con una base de casos de entrenamiento actualizada acorde al nivel de madurez de la gestión en la organización. Lo anterior implica, que el SNB debe ejecutarse para optimizar las reglas de inferencia borrosas existentes y con esto mejorar la calidad en la clasificación.

El SNB aplicado ha incidido positivamente en las funcionalidades de ayuda a la toma de decisiones de la herramienta Xedro-GESPRO, dándole un alto valor agregado a este producto. Xedro-GESPRO está siendo utilizado por más de 6 000 usuarios en las siguientes entidades: Red de Centros de Producción de la Universidad de las Ciencias Informáticas, Empresa Copextel División Tecnostar, entre otros centros cubanos vinculados al desarrollo de proyectos para la industria del software.

## CONCLUSIONES

La presente investigación expone como principal resultado, la aplicación de un sistema neuro-borroso de apoyo al control de la ejecución de proyectos, a través del cual se puede arribar a las siguientes conclusiones:

1. Las fuentes de datos relacionadas con la gestión de proyectos presentan imprecisión, vaguedad en los conceptos e incertidumbre en la información, situación donde el uso de técnicas de *soft computing* arroja buenos resultados para la clasificación.

2. Las ventajas que aporta el SNB propuesto aplicado a los productos y servicios brindados por Xedro-GESPRO, están asociadas con la mejora continua de herramientas para la toma de decisiones que se adapten a las condiciones cambiantes de los negocios y permitan la evaluación de proyectos en forma personalizada.

3. Xedro-GESPRO es comercializado bajo licencia GPL (*General Public Licence*) y la inclusión de técnicas de *soft computing* permite elevar la competitividad de este producto con un alto valor agregado, en comparación con otras herramientas libres y propietarias para la toma de decisiones en la gestión de proyectos existentes hasta la actualidad.

4. El SNB propuesto, permite optimizar la base de reglas vigentes de manera eficiente y eficaz, mejorando la calidad de la evaluación y con ello, el control de la ejecución y la toma de decisiones en las organizaciones orientadas a la producción por proyectos.

## REFERENCIAS

1. PMI. *Project Management Body of Knowledge (PMBOK)*. Pennsylvania, EE.UU.: PMI Publications. Project Management Institute. 2009. pp. 51-58. ISBN 1-930699-73-5.

2. **DELGADO, Roberto.** *La Dirección Integrada de Proyecto como Centro del Sistema de Control de Gestión en el Ministerio del Poder Popular para la Comunicación y la Información.* Caracas, Venezuela: CENDA, 2011, pp. 8-13: ISBN 9591602513.
3. **PIÑERO, Pedro Y.** "Un modelo para el aprendizaje y la clasificación automática basado en técnicas de softcomputing". Tutor: María M. García. Tesis de doctorado, Departamento de Ciencias de la Computación, Universidad Central de las Villas, Villa Clara, Cuba, 2005.
4. **LUGO, José A.** "Modelo para el control de la ejecución de proyectos basado en indicadores y lógica borrosa". Tutor: Pedro Y. Piñero. Tesis de maestría, Laboratorio de Gestión de Proyectos, Universidad de las Ciencias Informáticas, La Habana, Cuba, 2012.
5. **PIÑERO, Pedro Y. et al.** "GESPRO. Paquete para la gestión de proyectos". *Revista Nueva Empresa*, La Habana, Cuba, 2013, vol. 9, núm. 1, pp. 45-53. ISSN 1682-2455.
6. **DWEIRI, F.; KABLAN, M.** "Using fuzzy decision making for the evaluation of the project management internal efficiency". *Decision Support Systems*, Jordan, Elsevier, 2006, vol. 42, núm. 2, pp. 712-726.
7. **BHATT, M.** "Project Classification Using Soft Computing". En *International Conference on Advances in Computing, Control & Telecommunication Technologies*, IEEE Computer Society, Washington. 2010, pp. 537-539, ISBN 978-1-4244-5321-4.
8. **GAO, H.** "A fuzzy-ANP approach to project management performance evaluation indices system". En *International Conference on Logistics Systems and Intelligent Management*. IEEE. 2010, pp. 273-277. ISBN 978-1-4244-7331-1.
9. **CERTA, A.; ENEA, M.; GIALLANZA, A.** *A Synthetic measure for the Assessment of the Project Performance.* Ed. Springer. P. Taticchi-Business Performance Measurement and Management. Berlin, Springer-Verlag, 2010, pp. 167-180.
10. **MEWADA, K. M.; SINHAL, A.; VERMA, B.** "Adaptive Neuro-Fuzzy Inference System (ANFIS). Based Software Evaluation" *DCSI International Journal y Computer Science Issues*, 2013, 10(1): pp. 244-250. ISSN 1694-0814.
11. **PAL, Sankar K.; MITRA, Sushmita; MITRA, Pabitra.** "Rough Fuzzy MLP: Modular Evolution, Rule Generation and Evaluation", *IEEE Trans. on Knowledge and Data Engineering*. 2003, vol. 15, núm. d, pp. 14-25, ISSN 10414347.
12. **CASTELLANO, G., et al.** "Knowledge discovery by a neuro-fuzzy modeling framework", *Fuzzy Sets and Systems*. 2005, vol. 149, núm. d, pp. 187-207. ISSN 01650114.
13. **PEDRYCZA, Witold; REFORMATA, Marek.** "Genetically optimized logic models", *Fuzzy Sets and Systems*. 2005, vol. 150, núm. 2, pp. 351-371. ISSN 01650114.
14. **COTTA, C.; MOSCATO, P.** "Evolutionary Computation: Challenges and Duties". En *Frontiers of Evolutionary Computation*, Boston MA: Editor A. Menon. *Kluwer Academic Publishers*. 2004, pp. 53-72. ISBN 1-4020-7782-3.
15. **ALMEJALLI, Khaled.** "Intelligent Real-Time Decision Support Systems for Road Traffic Management". Tutor: Keshav Dahal. Tesis de doctorado, Department of Computing, University of Bradford, Bradford, Inglaterra, 2010.
16. **TAKAGI, T.; SUGENO, M.** "Fuzzy identification of systems and its application to modeling and control", *IEEE Transactions on Systems Man, and Cybernetics*, 1985, vol. 15, núm. 1, pp. 116-132. ISSN 00189472.
17. **JANG, Jyh-Shing R.** "ANFIS: Adaptive-Network-Based Fuzzy Inference Systems". *IEEE Transaction Systems Man & Cybernetics*, 1993, vol. 23, núm d, pp. 665-685. ISSN 00189472.
18. **THIPPARAT, Thoedtida.** *Application of Adaptive Neuro Fuzzy Inference System in Supply Chain Management Evaluation.* En *Fuzzy Logic Algorithms, Techniques and Implementations*, Thailand: Dadios. 2012, pp. 115-126. ISBN 978-953-51-0393-6.
19. **PRAYNLIN, E.; LATHA, P.** "Estimating Development Effort of Software Projects using ANFIS". En *International Conference on Recent Trends in Computational Methods, Communication and Controls (ICON3C 2012)*. 2012, *International Journal of Computer Applications*. ISSN 09528091.
20. **LUGO, José A., et al.** "Soft Computing para la toma de decisiones durante el control de la ejecución de proyectos". En *II Taller Internacional de Ciencias Computacionales e Informáticas (CICCI'2013)*. La Habana, Cuba, 2013. ISBN 978-959-7213-02-4.
21. **PÉREZ, Iliana, et al.** "Modelo para el aprendizaje automático. Aplicación en la Dirección Integrada de Proyectos". En *II Taller Internacional de Ciencias Computacionales e Informáticas (CICCI'2013)*. La Habana, Cuba, 2013, ISBN 978-959-7213-02-4.
22. **LUGO, José A.; PIÑERO, Pedro Y.; DELGADO, Roberto.** "Indicadores para el control y evaluación de proyectos en la herramienta GESPRO 11.05". En *UCIENCIA*, 2012, La Habana, Cuba, pp. d. ISBN 978-959-286-019-3.
23. **LUGO, José A. et al.** "Colección automática de métricas hacia un repositorio de mediciones". *Revista Facultad Ingeniería, Universidad Antioquia, Medellín, Colombia*, 2011, vol. d, núm. 58, pp. 199-207. ISSN 0120-6230.

## **AUTORES**

### **Anié Bermudez Peña**

Ingeniera en Ciencias Informáticas, Asistente, Universidad de las Ciencias Informáticas (UCI), La Habana, Cuba

### **José Alejandro Lugo García**

Ingeniero en Ciencias Informáticas, Máster en Gestión de Proyectos Informáticos, Asistente, UCI, La Habana, Cuba

### **Iliana Pérez Pupo**

Ingeniera en Ciencias Informáticas, Máster en Gestión de Proyectos Informáticos, Asistente, UCI, La Habana, Cuba

### **Pedro Yobanis Piñero Pérez**

Licenciado en Ciencias de la Computación, Doctor en Ciencias Técnicas, Profesor Auxiliar, UCI, La Habana, Cuba

### **Gil Cruz Lemus**

Ingeniero Químico, Doctor en Ciencias Técnicas, Profesor Auxiliar, Instituto Superior Politécnico José Antonio Echeverría, Cujae, La Habana, Cuba

# Neuro-Fuzzy System for Projects Execution Control Support

## **Abstract**

During execution control to their projects, organizations employ dissimilar tools to assist specialists in decision -making. In order to achieve a comprehensive evaluation of the project, a set of key indicators (time, cost, quality, logistics and human resource performance) are examined by applying soft computing techniques using fuzzy inference systems. However, sometimes the fuzzy inference rules that evaluate indicators are constructed from the judgment of experts, which introduces imprecision and vagueness in the boundaries of linguistic concepts. In this paper, a neuro-fuzzy system for projects execution control support which optimizes the existing rules base efficiently and effectively is proposed. The potential benefits of the proposal are related with decision-making improvement in organizations to projects-oriented production.

Key words: decision-making, neuro-fuzzy system, fuzzy rules optimization, projects execution control, soft computing