

A learning model for design-build project selection in the public sector

Modelo de aprendizaje para la selección de un proyecto diseño-construcción (llave en mano) en el sector público

Alfonso Bastias*¹, Keith R. Molenaar**

* Universidad del Desarrollo, Santiago. CHILE

**University of Colorado, Boulder. USA

Fecha de recepción: 28/ 01/ 2010
Fecha de aceptación: 15/ 03/ 2010
PAG. 05 - 20

Abstract

The primary method of public sector project delivery in the United States (U.S.) has traditionally been design-bid-build delivery. The public sector has historically separated design and construction contracts. In the 1990s, the U.S. public sector began to experiment with design-build project delivery, which combines design and construction in one contract. In 1997, a decision support system was developed to provide a formal selection model for public sector design-build projects. The model supports public owners in determining which projects are appropriate for design-build delivery. This initial model was static in nature and was based on a regression analysis of 104 projects. The analysis resulted in a predictive model with five performance criteria: overall satisfaction; administrative burden; conformance to expectations; schedule variance; and budget variance. Since 1997, the number of design-build projects has increased dramatically and public sector design-build methods have evolved. The original model can be improved with new data and a new framework to provide for an adaptive model as the industry continues to evolve. This paper presents a formalized application and use of learning capabilities to supplement the original static model. This model adjusts parameters and functions using artificial intelligence as the main knowledge engine. This approach can be adapted to many applications of decision support in the design and construction industry.

Keywords: Design-build, learning system, neural networks, decision making, construction engineering and management

Resumen

El método primario de ejecución de proyectos en el sector público en los Estados Unidos (U.S.), tradicionalmente ha sido la ejecución diseño-licitación-construcción. El sector público históricamente ha separado los contratos de diseño y construcción. En la década de los 90, el sector público norteamericano comenzó a experimentar con la ejecución de proyectos diseño-construcción (llave en mano), que combina el diseño y la construcción en un solo contrato.

En 1997 se estableció un sistema de apoyo a la toma de decisiones, con el fin de entregar un modelo de selección formal para la ejecución de proyectos en el sector público. El modelo apoya a los propietarios del sector público a determinar cuáles son los proyectos adecuados para la ejecución diseño-construcción (llave en mano). Este modelo inicial por naturaleza era estático y estaba basado en un análisis de regresión de 104 proyectos. El análisis produjo un modelo predictivo con cinco criterios de rendimiento: satisfacción general, carga administrativa, cumplimiento de expectativas, variación del programa, y variación del presupuesto. Desde 1997, el número de proyectos diseño-construcción ha aumentado dramáticamente y los métodos diseño-construcción del sector público han evolucionado. El modelo original puede ser mejorado con nuevos datos y una estructura que se traduce en un modelo adaptativo, mientras la industria continúa evolucionando. Este documento presenta una aplicación formal y el uso de capacidades para complementar el modelo estático original. Este modelo se ajusta a parámetros y funciones a través del empleo de inteligencia artificial, como principal motor de conocimiento. Este enfoque puede ser adaptado a muchas aplicaciones de apoyo a la toma de decisiones en la industria del diseño y construcción.

Palabras Clave: Diseño-construcción (llave en mano), sistema de aprendizaje, redes neuronales, toma de decisiones estratégicas, ingeniería en construcción y gestión

1. Introducción y motivación

Los propietarios del sector público en los Estados Unidos (U.S.) históricamente se han restringido a la ejecución de proyectos diseño-licitación-construcción. Los propietarios contratan a los diseñadores a través de una selección basada en las competencias profesionales para diseñar un proyecto. Una vez finalizado el diseño, los propietarios consiguen a los constructores basándose en la mejor propuesta económica. A comienzo de la década de los 90, los propietarios del sector público comenzaron a experimentar con la ejecución de proyectos diseño-construcción (llave en mano), en la cual contrataban a una sola entidad,

1. Introduction and motivation

Public sector owners in the United States (U.S.) have historically been constrained to design-bid-build project delivery. Owners hire designers through qualifications-based selection to design a project. Upon completion of the design, owners procure contractors based upon the lowest bid. In the early 1990s, public owners began to experiment with design-build project delivery in which they contract with one entity,

¹ Autor de correspondencia / Corresponding author:
E-mail: abastias@udd.cl

el diseñador-constructor, para completar la etapa de diseño y construir el proyecto. Un gran número de experiencias exitosas llevó a los propietarios a aumentar el número de proyectos diseño-construcción. Sin embargo, muchos otros experimentaron fracasaron, ya que escogieron proyectos que no eran apropiados para la ejecución del método diseño-construcción.

En 1997 se implementó un sistema apoyo a la decisión estratégica, para entregar un modelo de selección formal para la ejecución de los proyectos diseño-construcción. El modelo apoya a los propietarios del sector público a determinar cuáles son los proyectos apropiados para la ejecución diseño-construcción, aumentando así sus probabilidades de éxito (Molenaar y Songer 1998). El sistema de apoyo resultante en la toma de decisión, disponible en internet, tiene el nombre de Selector del Diseño-Construcción (SDC) (Molenaar y Songer 2001). La investigación original analizó 104 proyectos, a través de un enfoque de casos de estudios retrospectivos, que derivó en un modelo predictivo con cinco criterios: satisfacción general, carga administrativa, cumplimiento de expectativas, variaciones del programa y variaciones presupuestarias. Los propietarios pueden ingresar las características de su proyecto al sistema de apoyo de decisiones, disponible en internet, para cotejar los candidatos diseñador-constructor con los 104 proyectos del caso de estudio. Pueden variar la importancia de los objetivos del proyecto, a través de una comparación en pares de los cinco criterios. El resultado del modelo arroja un puntaje que es comparado con los proyectos del caso de estudio, empleando el puntaje de los criterios de rendimiento combinados, para cada uno de los criterios de rendimiento.

El objetivo de la presente investigación es desarrollar un motor de aprendizaje para el Sistema SDC, con el fin de adaptar el modelo, mientras la ejecución de proyectos del sector público evoluciona. Desde 1997, la herramienta SDC en internet ha sido visitada por más de 12.000 personas; y la herramienta como tal, ha sido empleada en más de 200 proyectos, lo que representa sobre 5 mil millones de dólares en diseño y construcción. Actualmente existe una considerable cantidad de datos de nuevos proyectos que pueden ser usados para mejorar el modelo estático original.

Una revisión de 93 Sistemas de Soporte en la Toma de Decisiones (DDS) en el campo de la construcción durante los últimos 30 años, demuestra que la mayoría son estáticos, con parámetros, funciones y normas fijas (Bastias 2006).

the design-builder, to complete the design and construct the project. A number of high-profile successes led owners to increase the number of public sector design-build projects. However, many owners experienced failures because they chose projects that were not appropriate for design-build project delivery.

In 1997, a decision support system was developed to provide a formal selection model for public sector design-build projects. The model supports public owners in determining which projects are appropriate for design-build delivery thereby increasing their chance of success (Molenaar and Songer 1998). The resulting web-based decision support system is named the Design-Build Selector (DBS) (Molenaar and Songer 2001). This original research analyzed 104 projects through a retrospective case study approach to derive a predictive model with five performance criteria: overall satisfaction; administrative burden; conformance to expectations; schedule variance; and budget variance. Owners can input characteristics of their projects in a web-based decision support system to benchmark their design-build project candidates against the original 104 case study projects. They can vary their importance of the project goals through a pairwise comparison of the five performance criteria. The output of the model yields a score that is compared to the case study projects through a combined performance criteria score and for each of the performance criteria.

The intent of the present research is to develop a learning engine for the DBS so that the model can adapt as public sector project delivery evolves. Since 1997, the web-base DBS tool has been visited by over 12,000 people and the DBS tool itself has been used on more than 200 projects representing over \$5 billion in design and construction. There is now considerable amounts of new project data that can be used improve the original static model.

A review of ninety-three Decision Support Systems (DSS) in the construction field over the past 30 years shows that the majority are static, with fixed parameters, functions, and business rules (Bastias 2006).

Los modelos estáticos pueden volverse obsoletos con rapidez, demandando ajustes manuales para recobrar importancia el dinámico ambiente de la ingeniería en construcción y gestión. Un enfoque mejorado para solucionar los problemas de cambios en el ambiente de decisión estratégica, es desarrollar modelos dinámicos basados en sistemas de aprendizaje (Bastias y Molenaar 2005; Bastias 2006; Taylor y Bernstein 2009).

Este documento presenta una aplicación formal y el uso de capacidades de aprendizaje para complementar el modelo estático original SDC. A través de esta presentación, se espera que el enfoque general pueda ser adaptado a muchas aplicaciones en el apoyo a la toma de decisiones estratégicas, en la industria del diseño y construcción.

2. Antecedentes del modelo diseño-construcción en el sector público

Un método de ejecución de proyecto es un proceso amplio en el cual diseñadores, constructores y varios consultores proveen servicios para el diseño y construcción, con el fin de entregar un proyecto completo al propietario. Los dos métodos de ejecución en el sector público norteamericano (U.S.) son diseño-licitación-construcción y diseño-construcción. La Figura 1 muestra gráficamente lo métodos de ejecución, indicando el contrato y el flujo de la comunicación inherente a cada método.

Static models can quickly become obsolete, requiring manual adjustments to be relevant in the dynamic environment of the construction engineering and management field. A better approach to solving the problem of changes in the decision environment is to develop dynamic models based on learning systems (Bastias and Molenaar 2005; Bastias 2006; Taylor and Bernstein 2009).

This paper presents a formalized application and use of learning capabilities to supplement the original DBS static model. Through this presentation, it is hoped that this general approach can be adapted to many applications of decision support in the design and construction industry.

2. Background of public sector design-build

A project delivery method is the comprehensive process by which designers, constructors, and various consultants provide services for design and construction to deliver a complete project to the owner. Two primary delivery methods in the U.S. public sector are design-bid-build and design-build. Figure 1 graphically depicts project delivery methods by showing the contract and communication flow inherent in each method.

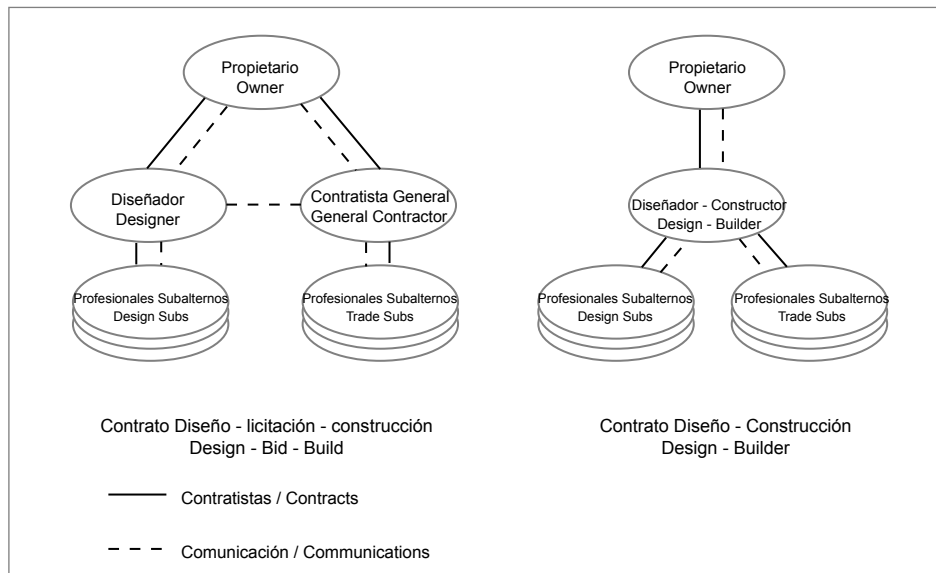


Figura 1. Métodos de Ejecución de Proyectos
Figure 1. Project delivery methods

Al emplear un método de ejecución de proyectos diseño-licitación-construcción, un propietario encarga a un diseñador proporcionar los servicios de diseño y luego adjudica el contrato de construcción por separado, sobre la base de la completa documentación de construcción entregada por el diseñador. El propietario es responsable por los detalles del diseño y el contratista constructor es responsable de cumplir con la calidad en los documentos de la construcción. La Figura 1 muestra que los contratos ubican al propietario entre el diseñador y el constructor en el proceso de ejecución del proyecto. La naturaleza lineal del proceso hace que el contrato diseño-licitación-construcción sea de un esfuerzo mayor. El proceso del contrato diseño-licitación-construcción también coloca la responsabilidad de la precisión de los detalles del diseño, en el curso de la construcción, claramente sobre el propietario. Como resultado, el propietario es responsable por los errores u omisiones en costos de diseño, frente al constructor. Existe poco incentivo para el constructor en minimizar o mejorar los costos. En realidad, puede originarse el efecto contrario. Cuando los proyectos diseño-licitación-construcción son adjudicados en base a la mejor oferta económica, el contratista puede considerar las modificaciones post-adjudicación como un medio de aumentar las ganancias.

Los contratos diseño-licitación-construcción no dan la oportunidad de entregar sugerencias de diseño al contratista general, ya que éste es seleccionado en base a la mejor oferta económica, después que el diseño ya ha sido terminado. Así el propietario debe confiar sólo en el diseñador para la estimación de costos y la revisión de la constructibilidad, durante el proceso de diseño. Por el contrario, en el método de ejecución diseño-construcción de proyectos, el propietario conserva ambos servicios, de diseño y construcción, en un mismo contrato. La Figura 1 indica que el enfoque contractual es directo. La ejecución diseño-construcción involucra al contratista desde el inicio del diseño y éste provee opiniones de constructibilidad inherentes al proceso de diseño. El diseñador-constructor es la entidad legal que posee el detalle del diseño durante la construcción y, como resultado, es responsable frente al propietario por los costos, errores u omisiones que se produzcan durante la construcción. Puesto que el propietario ya no posee los detalles del diseño, su relación con el diseñador-constructor debe estar basada sobre un fuerte grado mutuo de confianza profesional. El diseñador-constructor puede controlar literalmente la ejecución del proyecto. Como resultado, el método de ejecución diseño-construcción ha demostrado ser altamente exitoso, al reducir el período de ejecución del proyecto.

Using the design-bid-build project delivery method, an owner engages a designer to furnish design services and then awards a separate construction contract on the basis of the designer's completed construction documents. The owner is responsible for the details of design and is responsible to the construction contractor for the quality of the construction documents. Figure 1 shows that the contracts place the owner between the designer and the builder in the project delivery process. The linear nature of the process make design-bid-build a lengthy endeavor. The design-bid-build process also allocates responsibility for the accuracy of the design details during construction clearly on the owner. As a result, the owner is accountable to the contractor for the cost of any design errors or omissions. There is little incentive for the builder to minimize change order cost. In fact, there can be quite the opposite effect. When design-bid-build projects are awarded on a low-bid basis, a winning bidder may look to post-award changes as a means to increase profits. Design-bid-build also provides no contractor input to the design because the general contractor is selected based on a low bid after the design is complete. Thus, the owner must rely on the designer alone for cost estimating and constructability review during the design process.

In contrast, design-build is a project delivery method in which the owner retains both design and construction services in the same contract. Figure 1 shows that the contracting approach is direct. Design-build delivery involves the contractor early in design and provides inherent constructability input to the design process. The design-builder is the legal entity that owns the details of design during construction and as a result, is accountable to the owner for the cost of any errors or omissions encountered in construction. As the owner no longer owns the details of design, its relationship with the design-builder must be based on a strong degree of mutual professional trust. The design-builder can literally control the project delivery process. As a result, the design-build delivery method has proven to be highly successful in compressing the project delivery period.

Debido a la mínima cantidad de diseño desarrollado, al momento de la adjudicación del contrato, el diseñador-constructor generalmente es seleccionado en base a la contratación de la mejor oferta, combinando costo y precio. Los proyectos del sector público frecuentemente emplean el aprovisionamiento de dinero por suma alzada en el método diseño-construcción, pero también es viable garantizar un precio máximo.

Aunque el modelo diseño-construcción ha sido utilizado durante siglos, no fue hasta fines de la década de los 90 que el sector público comenzó a emplearlo en los Estados Unidos (U.S.). En el curso de los 80s y 90s varias agencias federales y estatales experimentaron con el modelo diseño-construcción para alojamientos militares, dormitorios colectivos, posadas (moteles), bodegas, tribunales, instalaciones de distribución de correos, instalaciones para mantenimiento de vehículos, laboratorios, clínicas de salud, tribunales federales, y autopistas. (Molenaar et. al 1999). Sin embargo, los proyectos típicamente se ejecutaron bajo una legislación o disposición legal especial, puesto que el método diseño-construcción no era ampliamente aceptado por las leyes de adjudicación del sector público. No fue sino hasta 1996 que el Acta de Reformas de Adquisiciones concedió a las autoridades federales la autoridad legal para contratar proyectos diseño-construcción (Molenaar et. al 1999). El rápido crecimiento y la novedad del método diseño-construcción en el sector público, crearon la necesidad de contar con un apoyo en la toma de decisión estratégica, a fin de escoger los proyectos del sector público que son apropiados para este modelo.

3. Solucion SDC original

El sistema de apoyo en la toma de decisiones estratégicas identificó cinco criterios de rendimiento (variables dependientes), que están directamente relacionados con el desarrollo de la ejecución general del proyecto. Los criterios de rendimiento son obtenidos evaluando 36 características del proyecto (variables independientes), a través de un cuestionario orientado a obtener información objetiva sobre un proyecto específico. El cuestionario está dividido en cuatro secciones, como se muestra en la Figura 2 (Molenaar y Songer 1998).

Due to the minimal amount of design at the time of contract award, the design-builder is generally selected through a best-value procurement that combines cost and price. Public sector projects most frequently use a lump sum pricing provision in design-build, but guaranteed maximum pricing is also viable.

Although design-build has been used for centuries, it was not until the late 1960s that the public sector began using design-build in the U.S. Through the 1980s and 1990s various federal and state agencies experimented with design-build for military housing, dormitories, lodges (motels), warehouses, courthouses, mail distribution facilities, vehicle maintenance facilities, laboratories, medical clinics, federal courthouses, and highways (Molenaar et. al., 1999). However, the projects were typically done with special legislation or legal provision because design-build was not widely allowed by public sector procurement laws. It was not until the 1996 Federal Acquisitions Reform Act gave federal authorities legal authority to engage in design-build projects (Molenaar et. al 1999). The rapid growth and novelty of design-build in the public sector created the need for decision support in choosing which public sector projects are appropriate for design-build.

3. Original DBS solution

The original DBS decision support system identified five performance criteria (dependent variables) that are directly related to overall project delivery performance. The performance criteria are obtained evaluating 36 project characteristics (independent variables) through a questionnaire that is oriented to obtain objective information about a specific project. The questionnaire is divided into four sections as shown in Figure 2 (Molenaar and Songer 1998).




Figura 2. Jerarquía de las Preguntas en la Selección del Proyecto Diseño-Construcción
Figure 2. Hierarchy of design-build selection questions

Una definición exitosa puede incluir muchos criterios. Costo, programa y satisfacción al cliente son las principales categorías usadas para definir el éxito de un SDC. Los cinco criterios de rendimiento son (Molenaar y Songer 1998):

1. Satisfacción general: La satisfacción general de los propietarios con el proyecto. La escala va desde 1 (no satisfecho) a 6 (mejor que lo esperado).
2. Carga administrativa: La carga administrativa para un potencial proyecto diseño-construcción en comparación con otros proyectos. La escala va desde 1 (baja) a 6 (alta).
3. Cumplimiento Expectativas: El cumplimiento de expectativas para un potencial proyecto diseño-construcción en comparación con otros proyectos. La escala va desde 1 (no cumplimiento) a 6 (mejor que lo esperado).
4. Variación del Programa: La variación en el programa del proyecto desde que el contratista fue adjudicado hasta la finalización del proyecto. La escala va desde -4 (<10% dentro de programa) a +4 (>10% por encima del programa).
5. Variación Presupuestaria: Esta ecuación predice la variación del presupuesto del proyecto, desde el momento en que el contratista fue adjudicado hasta la finalización del proyecto. La escala va desde -4 (<10% dentro del presupuesto) hasta +4 (>10% sobre el presupuesto).

Cada criterio de rendimiento es modelado por una regresión lineal múltiple. Los modelos de regresión para los criterios de rendimiento están basados en los 104 casos de estudio originales (Molenaar y Songer 1998). Para obtener un puntaje del proyecto general, se combinaron cinco ecuaciones de regresión individuales, a través de un modelo lineal, en el cual los valores relativos para cada uno de los criterios de rendimiento, son únicamente determinados por el usuario de cada proyecto. El puntaje final se predice de la siguiente manera.

$$\text{Puntaje General} = w_1 * \text{Satisfacción General} + w_2 * \text{Carga Administrativa} + w_3 * \text{Cumplimiento de Expectativas} + w_4 * \text{Variaciones en el Programa} + w_5 * \text{Variaciones Presupuestarias}$$

Donde,

$$w_i > 0$$

$$\sum_{i=1}^5 w_i = 1 \quad (1)$$

A definition of success can take on many criteria. Cost, schedule, and client satisfaction are the main categories used to define success in the DBS. The five performance criteria are (Molenaar and Songer 1998):

1. Overall Satisfaction: The owners overall satisfaction of the project. The scale ranges from 1 (not satisfied) to 6 (better than expected).
2. Administrative Burden: The administrative burden for a potential design-build project as compared to other projects. The scale ranges from 1 (low) to 6 (high).
3. Conformance to Expectations: The conformance to expectations for a potential design-build project as compared to other projects. The scale ranges from 1 (did not conform) to 6 (better than expected).
4. Schedule Variance: The variance in the project's schedule from the time the design-builder was hired to project completion. The scale ranges from -4 (<10% under schedule) to +4 (>10% over schedule).
5. Budget Variance: This equation predicts the variance in the project's budget from the time the design-builder was hired to project completion. The scale ranges from -4 (<10% under budget) to +4 (>10% over budget).

Each performance criteria is modeled by a multiple linear regression. The performance criteria regression models are based on the original 104 case studies (Molenaar and Songer 1998). To obtain an overall project rating, the five individual regression equations are combined through a linear model in which the weights for each of the five performance criteria are uniquely determined by the user for each project. The final score is predicted as follows.

$$\text{Overall Score} = w_1 * \text{Overall Satisfaction} + w_2 * \text{Administrative Burden} + w_3 * \text{Conformance to Expectations} + w_4 * \text{Schedule Variance} + w_5 * \text{Budget Variance}$$

Where,

$$\text{and } w_i > 0$$

Los resultados del puntaje general indican al usuario la información de apoyo estratégica que puede ser usada para aumentar la probabilidad de éxito del proyecto individual (Molenaar 1997; Molenaar y Songer 1998). Mientras el usuario puede generar distintos valores relativos para todo el modelo, basándose en las necesidades individuales de su proyecto, las ecuaciones de criterio de rendimiento individual están basadas sólo en los 104 proyectos empleados originalmente para crear la herramienta de apoyo en la toma de decisión estratégica SDC.

4. Solución de aprendizaje

El punto de partida para esta investigación se enfoca en el modelo de habilidades de aprendizaje. Los modelos adaptables pueden variar con el tiempo, ajustando sus parámetros y funciones para aumentar la precisión del resultado, mientras se obtiene mayor información. En general, existen tres tipos de datos: datos de entrada, datos de factor de tiempo, datos de resultados. Dado un proceso con N pares de datos de entrada/resultado, (ver Ecuación 2), el objetivo principal del modelo adaptable es escoger el modelo que cumpla con (ver Ecuación 3) (Harris, Hong et al., 2002). Se han desarrollado técnicas para acercarse a esta ecuación en el campo de la inteligencia artificial.

$$D_N = [x(t), y(t)]_{t=1}^N \quad (2)$$

$$\hat{y} = f(x, w), w \in \Omega \quad (3)$$

En la Ecuación 1, D_N representa un conjunto de pares de datos entrada/resultados, donde $x(t)$ es el dato de entrada del tiempo t y $y(t)$ es el resultado para el tiempo t .

En la Ecuación 2, w es un vector parámetro desconocido para el modelo estructura $f(x(t), w)$

La inteligencia artificial es una rama de la ciencia informática que ha sido desarrollada con el propósito de resolver problemas de aprendizaje. Aunque existen muchos enfoques distintos en inteligencia artificial tales como computación evolutiva, lógica difusa, algoritmos genéticos (por mencionar algunos), la aplicación más prolifera de la inteligencia artificial para conceptos de aprendizaje es la red neuronal (Jain y Martín 1998). Las redes neuronales aprenden, por definición, a través de un entrenamiento y/o adaptación, dependiendo del algoritmo de aprendizaje utilizado en cada caso. Una investigación anterior ha estudiado la aplicabilidad general de redes neuronales en el campo de la construcción (Moselhi, Hegazy et al., 1991),

The results of the overall score points the users to decision support information that can be used to increase the probability of individual project success (Molenaar 1997; Molenaar and Songer 1998). While the user can generate different weightings for the overall model based on their individual project needs, the individual performance criteria equations are static and based only on the 104 projects that were originally modeled to create the DBS decision support tool.

4. Learning solution

The point of departure for this research focuses on the model's learning capabilities. Adaptive models can change over time, adjusting their parameters and functions to increase output accuracy as more information becomes available. In general, there are three kinds of data: input data, time factor data, and output data. Given a process with N input-output data pairs, (see Equation 2), the main objective of adaptive modeling is to choose a model where (see Equation 3) (Harris, Hong et al., 2002). Techniques for approaching this equation have been developed in the artificial intelligence field.

In the Ecuación 1, D_N represents a set of pair input/output, where $x(t)$ is the input for time t and $y(t)$ is Output for time t .

In the Ecuación 2, w is an unknown parameter vector for the model structure $f(x(t), w)$

Artificial intelligence is a branch of computer science that has been developed for the purpose of solving learning problems. Although there are many different approaches in artificial intelligence such as evolutionary computation, fuzzy logic, and genetic algorithms (to name a few), the most prolific application of artificial intelligence for learning concepts is the neural network (Jain and Martin 1998). Neural networks learn by definition, through a training and/or adaptation, depending on the learning algorithm used in each case. Previous research has studied the general applicability of neural networks in the construction field (Moselhi, Hegazy et al., 1991)



así como soluciones más específicas a los problemas de construcción, tales como licitaciones (Moselhi, Hegazy et al. 1993), estimaciones (Chao y Skibniewski 1995), y adjudicación de proyectos (Kumaraswamy and Dissanayaka 2001). Por consiguiente, las redes neuronales han sido combinadas con otras tecnologías, tales como la lógica difusa y algoritmos genéticos, con el fin de producir sistemas de aprendizaje más sofisticados y realistas (Jain y Martin 1998; Harris, Hong et al. 2002; Cheng y Ko 2003).

and also for more specific solutions to construction problems such as bidding (Moselhi, Hegazy et al., 1993), estimation (Chao and Skibniewski 1995), and project procurement (Kumaraswamy and Dissanayaka 2001). Subsequently, neural networks have been mixed with other technologies, such as fuzzy logic and genetic algorithms, to produce more sophisticated and realistic learning systems (Jain and Martin 1998; Harris, Hong et al., 2002; Cheng and Ko 2003).

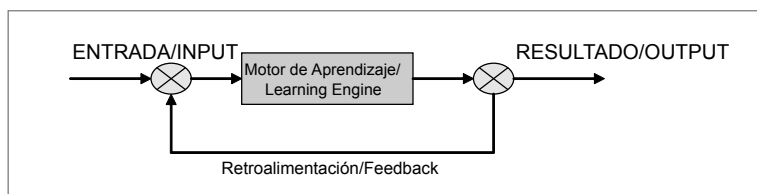


Figura 3. Diagrama de un sistema básico de aprendizaje
Figure 3. Basic learning system diagram

Figura 3 muestra un diagrama básico del sistema de aprendizaje. Existen tres componentes principales: entrada, motor de aprendizaje y salida. Este diagrama constituye el enfoque básico del sistema que se propone. Sirve como referencia para crear los pasos necesarios para identificar y desarrollar la estructura y los procedimientos de un sistema de aprendizaje. Las tres componentes se describen a continuación.

Entrada: Los datos de entrada son la información más sensible proporcionada al modelo. Su precisión impactará directamente el resultado. Cualquier modelo es sensible a las variables de entrada, por lo que un análisis profundo del tipo y calidad de información es necesario para la creación de un modelo exitoso.

Motor de Aprendizaje: La componente más compleja de cualquier tipo de sistema de aprendizaje, es el motor de aprendizaje. Este ha sido diseñado para realizar cambios de parámetros y funciones, empleando la información del resultado. En la mayoría de los casos, se emplea un tipo de inteligencia artificial como motor (ejemplo: redes neuronales, lógica difusa, algoritmos genéticos o una combinación de técnicas).

Resultado: Generalmente el resultado es fácil de medir y produce información valiosa. El resultado es la información empleada para tomar la decisión estratégica. Los resultados variarán de problema a problema, y debido a la naturaleza del sistema de aprendizaje, serán determinados por la habilidad de proveer al sistema con datos de entrada confiables.

Figure 3 shows a basic diagram of a learning system. There are three main components: input, learning engine, and output. This diagram is the basic approach of the framework being proposed. It serves as reference to create the necessary steps for identifying and developing the structure and procedures of a learning system. The three components are described as follows.

Input: The data input is the most sensitive information provided to the model. Its accuracy will directly impact the output. Any model is sensitive to input variables, so a deep analysis of the type and quality of information is necessary for the creation of a successful model.

Learning Engine: The most complex component of any type of learning system, the learning engine, is designed to perform changes in parameters and functions, using the feedback information. In most cases some type of artificial intelligence is used as the engine (e.g., neural networks, fuzzy logic, genetic algorithms or a combination of techniques).

Output: The output is generally easily measurable and produces valid feedback. The outcome is the information used to make the decision. Outcomes will vary from problem to problem, and because of the nature of learning system, they will be determined by the ability to provide the system with reliable input information.

Las redes neuronales artificiales son modelos electrónicos relativamente rudimentarios, basados en la estructura neuronal del cerebro. La red funciona como un “cerebro” y aprende desde la experiencia. Este cerebro modelador también promete una forma menos técnica para desarrollar soluciones mecanizadas.

La estructura matemática original para el SDC es relativamente parecida a la estructura presentada por la red neuronal. El conjunto de datos de entrada/resultados en el DBE puede permanecer igual en la solución red neuronal, pero la estructura interna cambia. Los algoritmos y funciones usadas por la red neuronal son definidos por los datos arrojados en proyectos pasados. Mientras la estructura matemática del modelo lineal SDC original y las redes neuronales son similares; las redes neuronales tienen la capacidad de aprender usando nueva información que puede entregar un nuevo conjunto de datos entrada/resultado. Los algoritmos específicos de aprendizaje y el tipo de aprendizaje definidos para cada neurona en la red, gobiernan este aprendizaje.

El principal inconveniente en el uso de redes neuronales es la cantidad de datos requeridos para entrenar a la red. Para producir resultados precisos, con un número bajo de puntos de entrada de datos a entrenar, es importante usar una distribución eficiente y efectiva de este conjunto, que relativamente está sujeto a problemas. Los desafíos adicionales de las redes neuronales son la parálisis y los mínimos locales. La parálisis se refiere al caso cuando los valores relativos impredeciblemente llegan a un estado de paralización, y no se ajustan durante el entrenamiento. Los mínimos locales se refieren al caso cuando los valores relativos se ubican en un estado menor que el óptimo (óptimo local v/s óptimo global) (Jain and Martin 1998).

En la mayoría de los casos, las redes neuronales son ajustadas y/o entrenadas, a fin que un dato de entrada en particular conduzca a un resultado objetivo específico, como se muestra en la Figura 4. El ajuste de la red está basado en una comparación del resultado con el objetivo, hasta que la red enlaza el objetivo, o hasta que ocurra un error permitido. Existen dos tipos de conocimiento: supervisado o no-supervisado. El aprendizaje supervisado requiere de un “profesor”. El profesor puede ser un conjunto de datos de entrenamiento o un observador que clasifica el rendimiento de los resultados de la red. De cualquier forma, contar con un profesor es aprender por refuerzo. Cuando no existe un profesor externo, el sistema debe organizarse a sí mismo con algún criterio interno diseñado en la red. Otra característica interna importante de la red neuronal tiene relación con sus capas. Un gran número de capas, en la mayoría de los casos,

Artificial neural networks are relatively crude electronic models based on the neural structure of the brain. The network functions like a “brain” and learns from experience. This brain modeling also promises a less technical way to develop machine solutions.

The original mathematical structure for the DBS is relatively close to the structure presented by neural networks. The data set for input/output in the DBE can remain the same with a neural network solution, but the internal structure changes. The algorithms and the functions used by the neural network are defined by the data from the past projects. While the mathematical structure of the original DBS linear model and the neural networks are similar, neural networks have the capability to learn using new information that can be provided through a new input/output dataset. Specific learning algorithms and learning rates defined for each neuron in the network govern this learning.

The main drawback in the use of a neural network is the amount of data required to train the network. To produce sufficient accuracy in results with a low number of training data points, it is important to use an effective and efficient distribution of the training set, which is relatively problem dependent. Additional challenges with neural networks are paralysis and local minima. Paralysis refers to the case when the weights unpredictably come to a standstill status and do not adjust during training. Local minima, refers to the case when the weights settle on a less than optimum status (local optimum v/s global optimum) (Jain and Martin 1998).

In most cases, neural networks are adjusted and/or trained, so that a particular input leads to a specific target output, as shown in Figure 4. Adjustment of the network is based on a comparison of the output and the target, until the network matches the target, or until an allowed error occurs. There are two types of learning: supervised and unsupervised. Supervised learning requires a “teacher.” The teacher might be a training set of data or an observer who grades the performance of the network results. Either way, having a teacher is learning by reinforcement. When there is no external teacher, the system must organize itself by some internal criteria designed into the network. Another important internal characteristic of the neural network has to do with its layers. A higher number of layers, in most cases,

aumenta la precisión de los resultados, pero requiere de un mayor número de entrada de datos para entrenar a la red adecuadamente. (Hüllermeier, Renners et al. 2004; Hinton, Osindero et al., 2006)

increases the accuracy of the outcomes but requires more data input to train the network properly. (Hüllermeier, Renners et al., 2004; Hinton, Osindero et al., 2006)

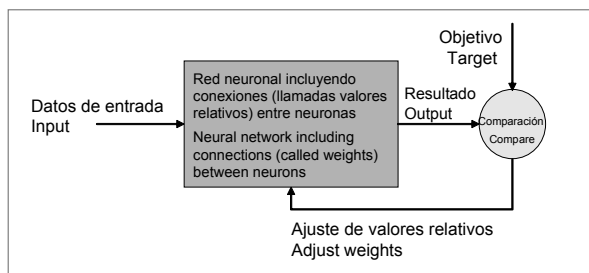


Figura 4. Diagrama de una Red Neuronal Artificial
Figure 4. Artificial neural network diagram

Algunas ventajas y desventajas notables:

- **Ventajas:** Las redes neuronales aprenden el comportamiento del sistema, usando los datos de entrada y resultados. La representación del proceso de pensamiento humano es lo suficientemente buena para solucionar muchos problemas, ya sea no resueltos o insuficientemente resueltos con las técnicas existentes. Las redes incorporan la información previa para satisfacer las siguientes soluciones avanzadas.
- **Desventajas:** El mayor problema es la naturaleza de la “caja negra”. No ha finalizado la comprensión de lo que se encuentra dentro de la caja negra. Es muy difícil determinar la apropiada estructura y la capa de la red para solucionar el problema. Manipular y adquirir parámetros de aprendizaje y convergencia, es una tarea cuya dificultad va en aumento. Otra desventaja importante se relaciona con la cantidad de conjunto de datos necesarios para entrenar a la red neuronal. Dependiendo del número de componentes y capas, la red neuronal pudiera requerir un mayor volumen de información: este es un factor que la industria de la construcción aún debe controlar.

El conjunto de datos entrada/resultado permanece idéntico entre la solución original y la nueva solución SDC. Un conjunto de 25 datos de entrada están relacionados con cinco resultados. Por lo que, la red neuronal posee 25 nodos de entrada asociados a cinco nodos de resultado. Un tipo categórico de nodo refleja una variable exclusiva, por ejemplo tipo de contrato. Como mencionamos anteriormente, la configuración inicial se realizó empleando 104 proyectos y fue validada por 18 proyectos en 1997. Desde entonces, se han finalizado muchos proyectos proporcionando nueva información al modelo para mejorar la precisión de los resultados.

Some notable advantages and disadvantages are:

- **Advantages:** Neural networks learn system behavior by using input-output data. The representation of the human thinking process is good enough for solving many problems that are either unsolved or inefficiently solved by existing techniques. The networks incorporate the previous information to meet and advance further solutions.
- **Disadvantages:** The major problem is the nature of the “black box”; the general understanding of what there is in the black box is incomplete. It is much harder to determine the appropriate structure and layer of the network for solving the problem. Manipulating and learning parameters for learning and convergence become increasingly difficult. Another important disadvantage is in respect to the number of data set needed to train the neural networks. Depending number of component and layer, the neural network might require a high volume of information, and usually in the construction industry this is a factor to be controlled.

The data set input/output remains the same between the original and the new DBS solution. A set of 25 input are related to five outcomes. So, the neural networks have 25 input nodes associated with five output nodes. A categorical type of node reflects an exclusive variable, for example, type of contract. As previously mentioned, the initial setup was developed using 104 projects and validated with 18 projects in 1997. Since then, many new projects have been completed giving the model new information to improve the accuracy of the results.

La tarea más compleja y tediosa de la construcción de la red neuronal, es la selección del número de capas ocultas ó nodos y los parámetros de aprendizaje, tales como la norma de aprendizaje y velocidad de aprendizaje. Existe una correlación implícita en la construcción de redes neuronales. Si el número de nodos es muy reducido, la red pierde su capacidad de aprender. Con el fin de diseñar “la red menos complicada, con rendimiento aceptable”, se hace necesario establecer un procedimiento “ensayo-error” (Cimikowski y Shope 1996).

Luego de un acucioso análisis y diseño de la red, se realizó un procedimiento ensayo-error agregando nodos a la capa oculta y una revisión al rendimiento mejorado de la red. Durante estos experimentos, los cambios fueron monitoreados con un indicador de rendimiento (puntaje final), el error cuadrático medio (MSE), el error medio (MEAN) y el error de desviación típica (STD). La solución propuesta incluye un conjunto de cinco redes neuronales asociadas a cada criterio de rendimiento. Todas las redes tienen la misma estructura, con una capa de entrada compuesta por tres neuronas y dos capas ocultas, donde la capa interior tiene dos neuronas y la capa resultado posee sólo una.

La Figura 5 muestra el diseño de la red para el criterio de rendimiento Satisfacción General. Para desarrollar la red se empleó una caja de herramientas Red Neuronal ® Matlab™. El algoritmo empleado por la red es de retropropagación, con Purelin como función de transferencia, Translm como función de transferencia de entrenamiento y Train como función adaptativa. La función de rendimiento minimizó el error cuadrático medio (MSE). La capa interior posee un vector de 8 puntos de datos con tres neuronas.

The most complex and tedious task in the construction of a neural network is the selection of the number of hidden layers or nodes and learning parameters, such as learning rule, and learning rate. There is a trade-off implicit in the neural network construction. If the number of hidden nodes increases the network get more stability in the weight and bias. However, if the number of nodes is too small, the network loses its ability to learn. In order to design “the least complicated network with acceptable performance,” a trial-and-error procedure is necessary (Cimikowski and Shope 1996).

After a comprehensive analysis and design of the network, a trial-and-error procedure was carried out by adding nodes to the hidden layer and checking for improved network performance. During these experiments, changes were monitored in the performance indicator (final score), the mean square error (MSE), the mean error (MEAN), and standard deviation (STD) error. The proposed solution includes a set of five neural networks associated to each performance criteria. All networks have the same structure, with an input layer composed by three neurons, and two hidden layers, where the inner layer has two neurons and the output layer only one.

Figure 5 shows the network design for the Overall Satisfaction performance criteria. Matlab™ with Neural Network toolbox® was used to develop the network. The algorithm used by the network is back propagation with purelin as the transfer function, translm as the transfer training function, and trains as the adapting function. The performance function minimized the MSE. The input layer has a vector of eight data points with three neurons.




Figura 5. Redes para el indicador de “Satisfacción General”
Figure 5. Network for the indicator “Overall Satisfaction”

Las redes neuronales deben ser entrenadas para ajustar el valor relativo y la propensión. El proceso de entrenamiento requiere, en la mayoría de los casos, una considerable cantidad de datos; sin embargo esta cantidad puede ser reducida si el conjunto de datos es representativo del problema a solucionar. La adaptación consiste en que la red, previamente entrenada, sea ajustada empleando nueva información a través de retroalimentación. La simulación es exactamente la evaluación de la red empleando ciertos datos de entrada.

El conjunto de datos para el nuevo modelo considera 152 proyectos, con la solución diseño-construcción (SDC). Con el fin de mantener un paralelo entre la solución original y este nuevo enfoque, la red fue entrenada con el mismo conjunto inicial de datos (es decir los 104 proyectos originales). Luego fue adaptada con 18 proyectos y evaluada con 29 proyectos. La Tabla 1 muestra los resultados de la evaluación en tres casos: la solución estática, la red neuronal inicial y la red neuronal adaptada por conjunto de datos adicionales.

The neural networks must be trained in order to adjust weight and bias. The training process requires, in most cases, a considerable amount of data, however, this amount can be reduced if the data set is representative of the problem to be solved. The adaptation is that the previously-trained network is adjusted using new information through feedback. The simulation is just the evaluation of the network using certain input.

The data set for the new model considers 152 projects in the DBS solution. In order to maintain a parallel between the original solution and this new approach, the network was trained with the same initial set of data (i.e. the 104 original projects). It was then adapted with 18 projects and evaluated with 29 projects. Table 1 shows the results in the evaluation for three cases: the static solution; the initial neural network; and the neural network adapted with additional data sets.

Tabla1. Análisi de error
Table 1. Analysis of error

	Solución Original Regresión Lineal Estática Original Solution Static Linear Regression	Red Neuronal Inicial Initial Neural Network	Red Neuronal Adaptada Adapted Neural Network
Error Medio Cuadrático/MSE	186.11	60.95	58.85
Media Desv./MEAN	11.35	5.97	5.72
Estándat/STD	7.91	5.26	5.33

La Figura 6 muestra cinco redes neuronales con la solución SDC y representa la topología general. El resultado de cada red neuronal es transformado a una escala de 1-100, y luego a un modelo lineal. El puntaje final es calculado como un promedio de cada criterio de rendimiento, en una escala ajustada. Este cálculo se realiza para hacer una comparación directa, puesto que los valores relativos son distintos para cada proyecto. Como discutimos con anterioridad, se realizó una dinámica comparación en pares en la solución SDC, para generar los valores relativos para cada proyecto exclusivo.

Figure 6 shows the five neural networks in the DBS solution and represents the general topology. The output of each neural network is transformed to a scale of 1-100, then to a linear model. The final score is calculated as an average of each performance criterion on an adjusted scale. This calculation is done to make a direct comparison as the weights are different for each project. As previously discussed, a pairwise comparison was used dynamically in the DBS to generate the weights for each unique project.

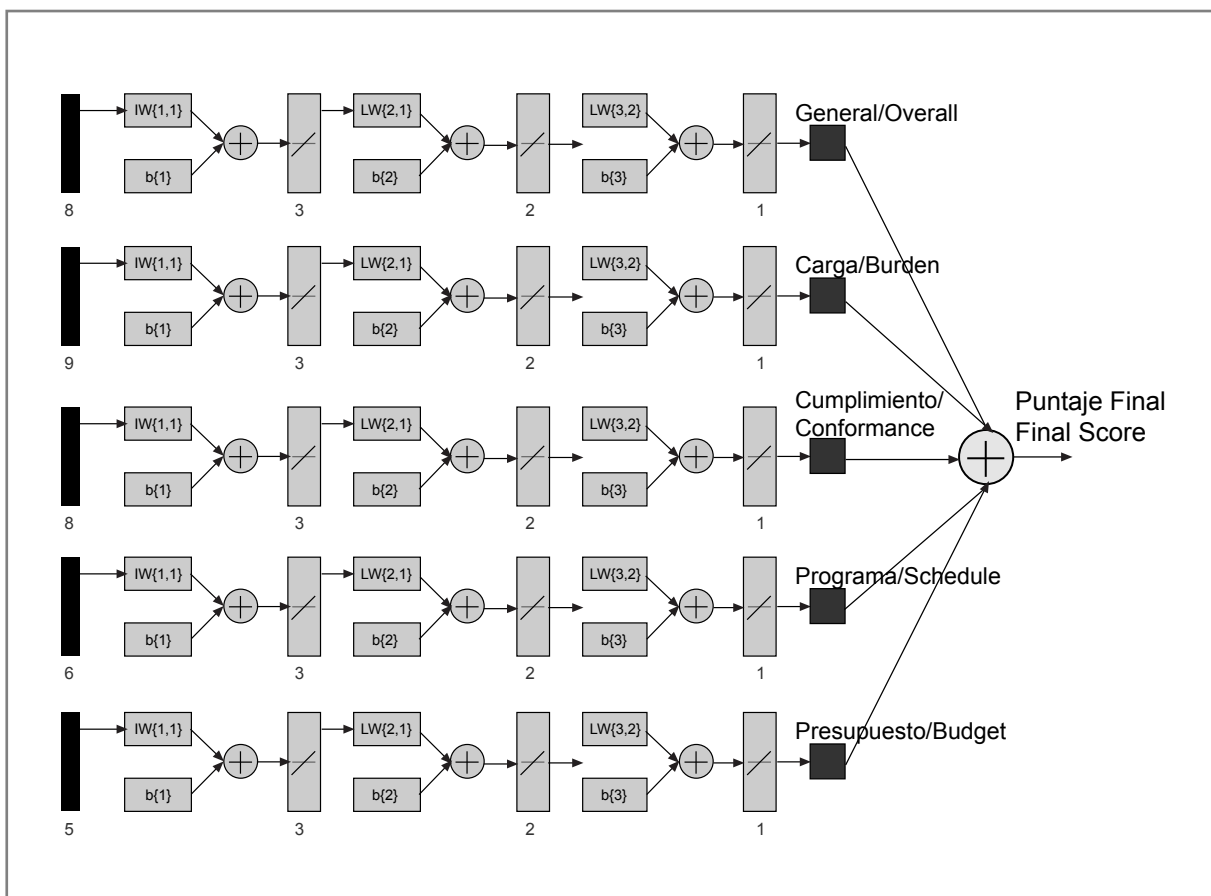


Figura 6. Topología Final de Redes Neuronales
 Figure 6. Final topology of neural networks

Como se muestra en la Tabla 1, el modelo muestra un particular mejoramiento a partir del modelo regresional. Como ejemplo, una gran universidad pública invirtió USD 12.000.000 en la extensión de un edificio auxiliar. La información de este proyecto fue empleada para analizar el rendimiento del actual nuevo modelo. La red neuronal indica la predicción de éxito para el proyecto y, por lo tanto, entrega información consultativa más precisa. El porcentaje de error de la estimación final disminuyó de 7.1% a 0.5%, en este caso particular. El resultado, a partir de la solución SDC, proporciona un puntaje general basado en las predicciones para cada una de las medidas de rendimiento. El resultado para este proyecto mostró que era un buen candidato para la ejecución diseño-construcción. Algunas de las características indicaron el mejoramiento que el propietario podría ejecutar en el área de rendimiento del programa.

As shown in Table 1, the learning model shows a distinct improvement from the original regression model. As an example, a large public university spent \$12,000,000 on an extension of its educational outreach building. The information from this project was used to analyze the performance of the current and new approach. The neural network presents a more accurate prediction of project success and therefore provides more accurate advisory information. The error in the final estimation decreased from 7.1% to 0.5% for this particular case. The output from the DBS provides an overall score and based on predictions for each of the five performance measures. The output for this project showed that it was a good candidate for design-build. Some of the project characteristics pointed to improvements that the owner could make in the area of schedule performance.

Para mayor detalle sobre esta información consultativa, ver investigación de Molenaar (Molenaar y Songer 2001).

Un aspecto importante de la solución SDC no es solamente la precisión adicional, sino que aún más relevante es cómo se empleó la información de retroalimentación para mejorar continuamente el resultado. Las características del propietario, del proyecto, el mercado y la relación, irán cambiando en la medida que el sector público evolucione y se familiarice con la ejecución diseño-construcción. Si el modelo de red neuronal puede ser provisto con datos adecuados, este modelo entregará predicciones más precisas y proporcionará información consultativa más aplicable.

5. Conclusión

Esta investigación fomenta el área de sistemas de apoyo a la decisión en ingeniería en construcción y gestión, al aplicar un modelo de aprendizaje a un problema originalmente resuelto con un modelo estático. Aunque por naturaleza, la ingeniería y gestión de la construcción es una disciplina muy dinámica, la gran mayoría de los sistemas de soporte a la decisión son estáticos. El SDC cumple como caso de estudio representativo, ya que es un sistema de decisión típico en esta área.

Aunque este documento provee sólo un caso de estudio para un modelo de aprendizaje, aplicado a la ingeniería en construcción y gestión, los autores ven muchas oportunidades de aplicaciones futuras. El caso de estudio SDC es un ejemplo de decisión estratégica que involucra la selección de un método de ejecución. Similares problemas dinámicos están presentes a este nivel estratégico, como se ve en la literatura. Esta metodología puede ser aplicada por una compañía contratista a la selección de proyectos internacionales (Han y Diekmann 2001), o a la decisión de un propietario por seleccionar contratistas pre-calificados (Russell et. al 1990). En un nivel estratégico, existen ciertas barreras tales como el tiempo requerido para reunir los resultados de retroalimentación, la cantidad de datos requeridos para un resultado confiable, el número de complicadas variables en las decisiones, y la aceptación de la información de apoyo a la decisión por los responsables de ésta. Sin embargo, como se muestra en el caso SDC, estas barreras pueden ser superadas con una planificación de largo plazo y una coherente recolección de datos.

La aplicación de esta metodología de aprendizaje también puede ser aplicada a niveles de producción.

For more information on this advisory information, see Molenaar's research (Molenaar and Songer 2001).

The important aspect of the new DBS learning solution is not only the additional accuracy, but more importantly how the new information was used as feedback to continuously improve the output. The characteristics of the owner, project, market and relationship will be changing as the public sector evolves and becomes more familiar with design-build delivery. If the neural network model can be provided with adequate data, this model will provide more accurate predictions and provide more applicable advisory information.

5. Conclusion

This research advances the area of decision support systems in construction engineering and management by applying a learning model to a problem that was originally solved with a static model. Although the construction engineering and management discipline is very dynamic in nature, the large majority of the decision support systems are static. The DBS serves a representative case study because it is typical of decision support systems in this area.

While this paper provides only one case study of a learning model applied to construction engineering and management, the authors see many opportunities for further application. The DBS case study is an example of a strategic decision involving the selection of a project delivery method. Similar dynamic problems exist at this strategic level as seen in the literature. This methodology could be applied to the selection of international projects by a contracting company (Han and Diekmann 2001) or the decision to prequalify contractors by an owner (Russell et. al 1990). At the strategic level, there are certainly barriers such as the length of time needed to collect outcomes as feedback, the amount of data required for reliable output, the number of confounding variables in the decisions, and the acceptance of the decision support information by the decision makers. However, as shown in the DBS case, these barriers can be overcome with long-range planning and consistent data collection.

The application of this learning methodology could also be applied at the production level.

Estudios similares que pueden beneficiarse con esta metodología a nivel productivo incluyen recursos compartidos en construcción lineal (Perera 1983), optimización cargas pesadas múltiples, (Lin y Haas 1996), análisis de correlación tiempo-costo-calidad para construcción de carreteras (El-Rayes y Kandil 2005). La extensión del tiempo requerido para reunir resultados de retroalimentación y la cantidad de factores complicados es menor en el nivel productivo. Sin embargo, otras barreras para la implementación podrían incluir una estructura de menor tiempo en implementar los resultados y cambiar sistemas de producción, durante las operaciones. Pero estas barreras son mínimas en comparación con las ganancias potenciales que se pueden encontrar, al aplicar los mecanismos de aprendizaje a los sistemas de apoyo a la decisión de la industria.

Por último, el campo de la ingeniería en construcción y gestión se beneficiará con la incorporación de nuevas capacidades de aprendizaje de los modelos de apoyo a la toma de decisiones. El empleo de la inteligencia artificial aplicado a las capacidades de aprendizaje en sus modelos de decisiones es una forma apropiada; sin embargo, otros métodos también pueden ser usados. La clave es no dejar que los modelos permanezcan estáticos y usar nueva información para aumentar la precisión de futuros resultados. El caso SDC demuestra que, con una planificación adecuada, los sistemas dinámicos de apoyo a la decisión pueden mejorar el desarrollo, sin crear una excesivamente pesada recolección de datos y esfuerzo de análisis.

6. Agradecimientos

Los autores quisieran agradecer a todos los profesionales que contribuyeron con tiempo y datos al caso de estudio. Sin su apoyo, esta investigación no habría sido posible.

Similar studies that could benefit from this methodology at the production level include resource sharing in linear construction (Perera 1983), multiple heavy lifts optimization (Lin and Haas 1996), time-cost-quality trade-off analysis for highway construction (El-Rayes and Kandil 2005). The length of time needed to collect outcomes as feedback and the number of confounding factors is smaller at the production level. However, other barriers for implementation could include the short time frame to implement the results and the difficulty in changing production systems during operations. Nevertheless, these barriers are minimal when compared to the potential gains that could be found by applying learning mechanisms to decision support systems in the industry.

Ultimately, the construction engineering and management field will benefit from the incorporation of learning capabilities in decision support system models. The use of artificial intelligence to apply learning capabilities in its decision models is one appropriate way; however, other methods can be used. The key is not to let modes remain static and to use new information to increase the accuracy of future results. The DBS case demonstrates that, with proper planning, dynamic decision support systems can improve performance without creating overly burdensome data collection and analysis efforts.

6. Acknowledgments

The authors would like to thank all of the professionals who contributed their time and case study data. Without their support, this research would not have been possible.

7. Referencias / References

- Bastias A. (2006), Towards the application of learning systems for decision support in construction engineering and management. Civil Engineering. Boulder, University of Colorado.
- Bastias A. and K. Molenaar (2005), Classification and Analysis of Decision Support Systems for the Construction Industry. International Conference on Computing in Civil Engineering, Cancun, American Society of Civil Engineers.
- Cimikowski R. and P. Shope (1996), "A neural-network algorithm for a graph layout problem." IEEE Transactions on Neural Networks 7(2): 341-345.
- Chao L.-C. and M. J. Skibniewski (1995), "Neural Network Method of Estimating Construction Technology Acceptability." Journal of Construction Engineering and Management 121(1): 130-142.

- Cheng M.-Y. and C.-H. Ko (2003), "Object-Oriented Evolutionary Fuzzy Neural Inference System for Construction Management." *Journal of Construction Engineering and Management* 129(4): 461-469.
- Harris C., X. Hong et al. (2002), *Adaptive modelling, estimation, and fusion from data: a neurofuzzy approach*, Springer Verlag.
- Hinton G., S. Osindero, et al. (2006), "A fast learning algorithm for deep belief nets." *Neural Computation* 18(7): 1527-1554.
- Hüllermeier E., I. Renners et al. (2004), "An evolutionary approach to constraint-regularized learning." *Mathware & soft computing* 11(2-3): 109-124.
- Jain L. C. and N. M. Martin (1998), *Fusion of Neural Networks, Fuzzy Sets, and Genetic Algorithms: Industrial Applications*, CRC Press, Inc.
- Kumaraswamy M. and S. Dissanayaka (2001), "Developing a decision support system for building project procurement." *Building and Environment* 36(3): 337-349.
- Molenaar K. (1997), *Public sector design-build: a model for project selection*. Civil Engineering. Boulder, University of Colorado.
- Molenaar K. and A. Songer (1998), "Model for public sector design-build project selection." *Journal of Construction Engineering and Management* 124(6): 467-479.
- Molenaar K. and A. D. Songer (2001), "Web-based decision support systems: Case study in project delivery." *Journal of Computing in Civil Engineering* 15(4): 259-267.
- Moselhi O. and T. Hegazy et al. (1991), "Neural networks as tools in construction." *Journal of Construction Engineering and Management* 117(4): 606-625.
- Moselhi O., Hegazy T. et al. (1993), "DBID: analogy-based DSS for bidding in construction." *Journal of Construction Engineering and Management* 119(3): 466-479.
- Taylor J. and P. Bernstein (2009), "Paradigm Trajectories of Building Information Modeling Practice in Project Networks." *Journal of Management in Engineering* 25: 69-76.