

# "TÉCNICAS DE INTELIGENCIA ARTIFICIAL APLICADAS A LA TOMA DE DECISIONES EMPRESARIALES EN PROCESOS RECURRENTE"<sup>1</sup>

Reiner Solís Villanueva

## Resumen

El presente artículo propone un modelo de predicción de la probabilidad de éxito o fracaso de un proyecto antes de iniciarse, mediante un sistema de ayuda para la toma de decisiones empresariales frente al problema que asume una empresa ante la propuesta de iniciar un nuevo proyecto y tomar la decisión de aceptarlo o descartarlo, a fin de que la gerencia de la empresa pueda decidir si ejecuta o descarta el proyecto, confirmando las predicciones de éxito o fracaso del proyecto, o realizando un replanteo de las mismas.

El modelo proporciona un mecanismo para revisar sus resultados de calificación del riesgo de un proyecto, mediante la creación y empleo de una base de datos con indicadores históricos. Se propone el diseño de indicadores históricos para medir el impacto de los factores de riesgos sobre los objetivos de un proyecto de infraestructura, bajo un esquema de rentabilidad, comparando los datos históricos con los riesgos identificados en el negocio, usando para tal fin las redes neuronales artificiales como herramienta de análisis. En el presente documento se revisan las características comunes de las redes neuronales artificiales y se analiza la viabilidad de su aplicación en los procesos con indicadores recurrentes.

Palabra clave: Redes neuronales artificiales, toma de decisiones, riesgo.

---

<sup>1</sup> Este artículo está basado en el proyecto de investigación “Modelo de Gestión de Riesgos basado en redes neuronales para la toma de decisiones empresariales”, del Instituto de Investigación científica de la Universidad de Lima.

## **1. Introducción**

La decisión de llevar a cabo un proyecto implica el riesgo de tener éxito o fracaso en su ejecución, por tal motivo se hace necesario realizar una evaluación del riesgo que se está asumiendo, escogiendo una métrica adecuada. Sin embargo el riesgo no solo hay que evaluarlo por la probabilidad de éxito o fracaso del proyecto sino también por la importancia de la meta que se quiere llegar.

Una debilidad de las prácticas existentes es la incapacidad para comparar los riesgos identificados contra el rendimiento de proyectos similares acontecidos en la empresa. Este documento realiza una propuesta de indicadores de medición de los factores de riesgo, que impactan sobre los objetivos del proyecto bajo un esquema de rentabilidad, aplicando un mecanismo de control que compare los riesgos actuales con los datos históricos de proyectos pasados de la organización, utilizando como herramienta de análisis las redes neuronales artificiales, siguiendo el modelo de validación de eficiencia adoptado por Cantone Giovanni, Sarcia Salvatore y Basili Victor (2007). En este artículo se proporciona una visión general de los elementos del proceso de toma de decisiones; asimismo, se revisan las características comunes de las redes neuronales artificiales y se analiza la viabilidad de su aplicación en los procesos que cuentan con indicadores recurrentes.

## **2. Fundamentos teóricos**

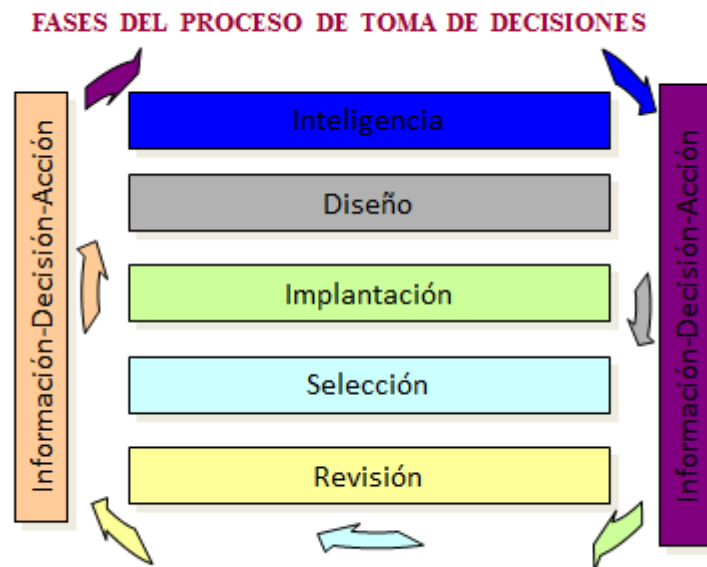
### **2.1 El proceso de toma de decisiones**

La toma de decisiones es el proceso que facilita la conversión de la información en acción (Cano, 2013). En el proceso de toma de decisiones, el decisor racional (Simon,1980) identifica y enumeran las alternativas posibles, asimismo analiza, valora y compara las consecuencias derivadas. La información de la que dispone el decisor (Dixon, 1970) en el proceso de toma de decisión pueden tomarse en un contexto de certidumbre, incertidumbre o riesgo. En el estado de certidumbre se conocen todos los datos necesarios para tomar la decisión, en el estado de incertidumbre la información es incompleta, y la decisión es una consecuencia de suposiciones. Finalmente, existe riesgo de éxito o fracaso para cada alternativa.

Es posible utilizar métodos cuantitativos de ayuda a la toma de decisiones (Vicens, Albarracín y Palmer, 2005; Serra, 2004) y/o métodos cualitativos (Herrera, Herrera-Viedma y

Verdegay, 1996; Zimmermann, 1991). El proceso de toma de decisiones necesita algún tipo de información, aunque sea muy escasa (González, 2001)

La Figura 1 establece cinco las fases del proceso de toma de decisiones (Cano, 2013)



**Figura 1. Fases del proceso de toma de decisiones**

**Fuente: Cano, 2013**

A continuación se describen la Fases del proceso de toma de decisiones (Cano, 2013):

**Fase de inteligencia:** Se identifica y define el problema respecto del cual se pretende tomar una decisión (Greenwood, 1978). Se realiza un análisis para buscar el origen problema, el cual consiste en la evaluación del riesgo del proyecto. El análisis depende de la forma en que el decisor percibe el problema y recibe, organiza e interpreta la información.

**Fase de diseño:** Se identifican las alternativas y estrategias posibles. Se realiza un análisis con el fin de que no queden alternativas sin identificar.

**Fase de selección:** Se realiza la elección de una alternativa. La elección se realiza en función de la cantidad y calidad de información disponible.

**Fase de implantación:** Se desarrolla la acción. Ejecuta la alternativa elegida para solucionar el problema.

**Fase de revisión:** Realiza un control de la acción respecto de la decisión ejecutada, y verifica si es necesario reiniciar el proceso.

### **2.1.1 Clasificación del tipo de decisiones**

Describimos tres clasificaciones de las decisiones que se pueden tomar en la empresa siguiendo a Claver et al. (2000) y Menguzzato y Renau (1995).

#### **La clasificación por nivel.**

Distingue tres tipos de decisiones que dependen de la posición jerárquica del decisor. Estas decisiones son:

Decisiones estratégicas. Los decisores son altos directivos. Se deciden los objetivos generales y planes a largo plazo. La información debe ser oportuna y de calidad.

Decisiones tácticas. Los decisores son directivos intermedios. Es la ejecución de las decisiones estratégicas. Son útiles para repartir eficientemente los recursos limitados.

Decisiones operacionales. Los decisores son los ejecutivos de operación: supervisores y gerentes. Se ejecutan las actividades funcionales y rutinarias.

#### **La clasificación por métodos.**

Se realiza dependiendo del procedimiento utilizado para elegir la alternativa final (Simon, 1977). Estas decisiones son:

Decisiones programadas. Se deciden con un procedimiento establecido que define, predecir y analizar los elementos del problema y sus relaciones.

Decisiones no programadas. Son decisiones nuevas, no estructuradas e importantes. No existe un procedimiento para tratar estos sucesos inesperados. El decisor utiliza su intuición, creatividad o criterio.

#### **Clasificación sintética.**

Se basa en las dos anteriores, en función del nivel jerárquico y el método utilizado, distinguiendo entre decisiones estructuradas, semiestructuradas y no estructuradas (Keen y Scoot Morton, 1978). Estas decisiones son:

Decisiones estructuradas. Se usan métodos de cálculo matemáticos en todas las fases. Las tres fases principales (inteligencia, diseño y elección) son estructuradas.

Decisiones semiestructuradas. No es posible usar métodos de cálculo matemática en la fase de inteligencia, diseño y selección, sin embargo, una vez identificado el problema, es posible el uso de modelos matemáticos.

Decisiones no estructuradas. No se pueden utilizar métodos matemáticos. Ninguna de las fases es estructurada.

## **2.2 Redes neuronales artificiales**

Las Redes Neuronales Artificiales forman parte de un conjunto de metodologías emergentes que se usan como soporte de trabajo de las organizaciones inteligentes y que actualmente tienen la denominación de *análisis avanzado*.

Las redes neuronales artificiales no son programadas, aprenden a partir de ejemplos. Normalmente a una red neuronal artificial le presentamos una serie de patrones ejemplos a través de los cuales ellas deben aprender. Debido a que el aprendizaje es por ejemplos, las redes neuronales artificiales tienen un gran potencial para crear sistemas de computación que no necesitan ser programados. Esto supone un enfoque radicalmente distinto a los clásicos sistemas de software de desarrollo. En los programas de cómputo cada paso que el computador ejecuta debe ser anteriormente especificado por el programador, un solo proceso absorbe tiempo y recursos. Las redes neuronales comienzan con ejemplos de entradas y salidas y aprenden a producir la salida correcta para cada entrada. El enfoque de las redes neuronales consiste en que no requieren identificación de características, ni el desarrollo de algoritmos y programas para la resolución de problemas particulares. Sin embargo presentan dos desventajas: el tiempo de aprendizaje de la red no puede ser conocido a priori, y el diseño de una red por prueba y error puede ser muy compleja. Esto quiere decir que mientras la red no haya concluido su proceso de aprendizaje no puede ser descartada (Isasi y Galvan, 2004).

Actualmente existen variados modelos de redes neuronales artificiales que son usados en diversos campos de aplicación, destacando los modelos de Michie, Spiegelhalter y Taylor (1994) que es considerado como el estudio comparativo más completo entre redes neuronales artificiales y modelos estadísticos orientado a la clasificación (Sarle, 2002), el modelo de la red de propagación hacia atrás (Rumelhart, Hinton y Williams, 1986) y los mapas auto organizados de Kohonen (1982). Estas estructuras pueden ser utilizadas en la clasificación y predicción del comportamiento de sistemas no lineales con información borrosa o incompleta como es el caso del proceso de toma de decisiones.

### **3. Realidad Problemática**

#### **3.1 Definición del problema**

Es conveniente tener en cuenta que el riesgo es la probabilidad de tener éxito o fracaso, cuando se toma la decisión de llevar a cabo un proyecto (Del Carpio Gallegos, Javier y Roberto Eyzaguirre Tejada, 2007), por tal motivo se hace necesario realizar una evaluación del riesgo que asume una empresa frente a la propuesta de iniciar un nuevo proyecto y tomar la decisión de aceptarlo o descartarlo.

El problema principal que enfrenta una empresa es poder calcular con el mínimo error posible la probabilidad de éxito o fracaso de un proyecto de infraestructura antes de iniciarse, a fin de que la gerencia de la empresa pueda decidir si ejecuta o descarta el proyecto, confirmando las predicciones de éxito o fracaso del proyecto, o realizando un replanteo de las mismas.

Sin embargo, es posible que la empresa logre realizar un cálculo subjetivo de la probabilidad de éxito o fracaso de un proyecto antes de ser iniciado, basándose en las consultas a expertos o en consultas directas a todas las partes interesadas del proyecto, lo que debería proporcionar una calificación subjetiva para cada riesgo identificado. No obstante, este proceso de estimación del riesgo contiene demasiada incertidumbre y no puede ser calificado como confiable.

Asimismo, es posible que la empresa realice un cálculo objetivo y estime el riesgo del proyecto antes de ser iniciado en base a una evaluación de variables mediante la comparación de valores umbrales con proyectos similares ejecutados, calificando el proyecto antes de ser iniciado como éxito o fracaso. No obstante, el problema que puede ocurrir es que los valores umbrales considerados pueden contener demasiada incertidumbre para definir el umbral de comparación, ya que simplemente se basa en una media ponderada de la exposición al riesgo de los datos históricos de la organización, o en algunos casos el problema que puede ocurrir es que la empresa adopte valores teóricos de comparación (por ejemplo valores pertenecientes a otras organizaciones), a fin de predecir el éxito o fracaso de un proyecto. En ambos casos el proceso de estimación del riesgo contiene demasiada incertidumbre y no es confiable.

Para revertir la situación planteada a continuación se plantean las siguientes

interrogantes:

¿Cómo lograr calcular con el mínimo error posible la probabilidad de éxito o fracaso de un proyecto antes de ser iniciado?

¿Es posible volver inteligente el proceso de toma de decisiones en la fase de inteligencia y diseño, de modo de que pueda predecir de manera confiable la probabilidad de éxito o fracaso de un proyecto de infraestructura antes de ser iniciado?

¿Es posible construir un modelo basado en técnicas de inteligencia artificial que pueda calcular la probabilidad de éxito o fracaso de un proyecto de éxito o fracaso de un proyecto de infraestructura antes de ser iniciado?

#### **4. Estrategia de solución**

Un proceso más confiable, que reduzca la incertidumbre del cálculo del riesgo objetivo del proyecto antes de ser iniciado, podría servir para confirmar las predicciones subjetivas de éxito o fracaso del proyecto, o realizar un replanteo de las mismas. Nuestra propuesta consiste en establecer un modelo que utilice los datos históricos de proyectos similares ejecutados por la organización, buscando identificar los factores de riesgo que afecten las variables de éxito (Salvatore y Basili, 2007) del proyecto. El modelo propuesto usa como herramienta de análisis las redes neuronales artificiales, afín que pueda determinar los umbrales de comparación de éxito o fracaso de un proyecto antes de ser iniciado.

El modelo propuesto será construido en base a los datos históricos de proyectos similares ejecutados por la organización, usando como herramienta las redes neuronales artificiales y tendrá como salida o variable de evaluación estimada el indicador del objetivo del proyecto (efectividad, eficiencia y calidad) y cálculo del riesgo en términos de la probabilidad de éxito o fracaso del proyecto antes de ser iniciado. Esta medida estimada del riesgo, debe definir las estrategias y planes de monitoreo o mitigación de riesgos.

Durante la fase inteligencia, diseño del proceso de toma de decisiones de la Figura 1, la evaluación del riesgo constituye la información primaria para el proceso decisorio, por lo tanto nos encontramos con el problema de averiguar en qué medida los riesgos pueden repercutir en los objetivos del proyecto. Por ejemplo, si los riesgos impactan demasiado sobre el proyecto, debemos obtener baja probabilidad de éxito. Sin embargo debemos tener en cuenta para los resultados, la base o umbral de comparación que arroja el modelo. Por ejemplo, supóngase como objetivo del proyecto la efectividad que se mide en el índice de efectividad (resultados alcanzados sobre resultados planificados) a fin de definir el éxito o

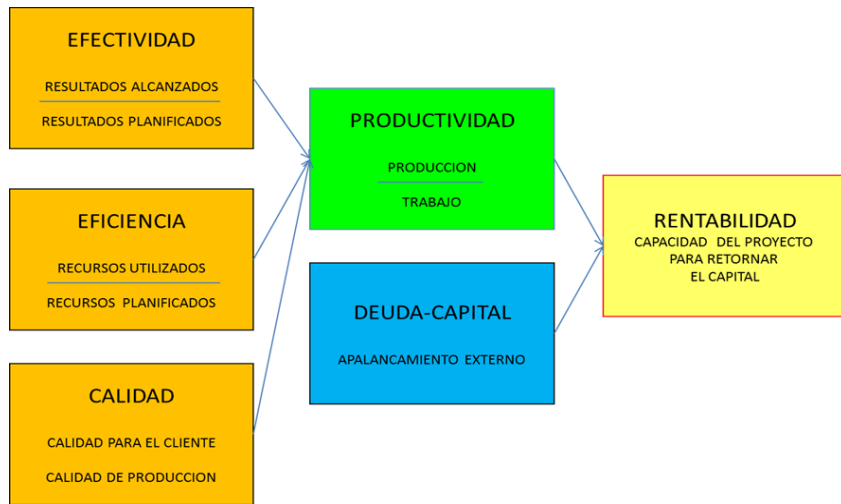
fracaso de un proyecto, y lo comparamos con los índices de efectividad de proyectos similares de la empresa. Supongamos que para un proyecto se obtiene el índice de Efectividad “E1” entre 0,7 y 0,8. Si se define un índice de efectividad teórico de éxito  $E2=1.0$  como umbral de comparación, entonces el proyecto es considerado como fracaso, porque  $E1 < E2$ . Por el contrario, si hemos elegido, como umbral el valor que arroja el modelo basado en redes neuronales artificiales teniendo como dato la información de todos los proyectos similares ejecutados por la organización ( y esta fuera,  $E3 = 0,65$ ) tendríamos un éxito ( $E1 > E3$ ). Esto último ocurre porque el objeto de comparación se basa en experiencia reales de la organización. Por lo tanto, debemos procurar calibrar el criterio de evaluación de los datos observados en base a las actuaciones reales de la empresa, procurando que la información sea suficiente y lo más actualizada como sea posible, a fin de estimar un modelo óptimo que use la herramienta de las redes neuronales artificiales.

La estrategia que se propone está basada en el diseño de indicadores históricos comunes a los proyectos de una organización, que permitan construir una base de datos históricos del comportamiento de la organización en la ejecución de proyectos similares, con el fin de calcular el impacto de los factores de riesgo sobre los objetivos del proyecto. El propósito en esta estrategia es generar una base de comparación del valor del riesgo.

Este documento propone definir los objetivos de un proyecto bajo un *esquema de rentabilidad* descrito en la Figura 2. El esquema permite identificar los indicadores del negocio, relacionando elementos cuantificables para luego transformarlos a indicadores básicos. El esquema de rentabilidad está sostenido por tres indicadores generales: Efectividad, Eficiencia y Calidad (Lezama, 2007). Este punto de vista se utilizará en el resto de este documento.

Con el fin de comprobar si un proyecto está cumpliendo sus objetivos declarados, consideramos los umbrales de *efectividad, eficiencia y calidad*. De esta manera, el éxito o el fracaso del proyecto se definen según cómo se establecen estos umbrales. Esta interpretación, nos permite definir un proyecto como exitoso sobre la base de un aspecto específico (por ejemplo, un proyecto puede considerarse exitoso si el factor de efectividad supera o iguala el umbral establecido por el modelo, en caso contrario el proyecto puede considerarse un fracaso). Sin embargo este concepto puede ser representado por una función de muchas variables, que calcula la métrica que hemos elegido para representar el éxito.

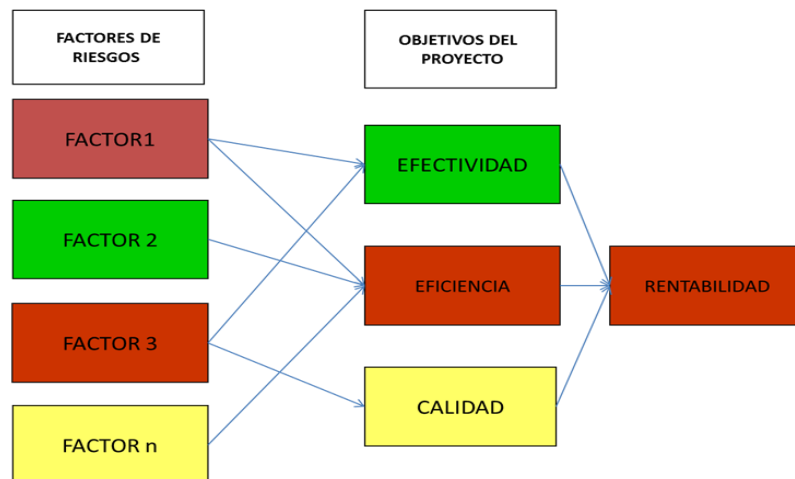




**Figura 2. Esquema de Rentabilidad.**

La Figura 3 proporciona un esquema de nuestra propuesta. Asimismo, podemos calcular usando la herramienta de redes neuronales artificiales, la probabilidad de éxito para el proyecto actual; si esta probabilidad es inferior al umbral escogido, el impacto de los factores de riesgo aumenta, y tienen que activarse un plan de contingencia para mitigar el riesgo, caso contrario, si esta probabilidad es superior al umbral definido, el impacto de los factores de riesgo disminuye, por lo tanto la influencia de los factores de riesgos sobre los objetivos del proyecto (esquema de rentabilidad) es mínima.

**IMPACTO DE LOS FACTORES DE RIESGO SOBRE EL ESQUEMA DE RENTABILIDAD**



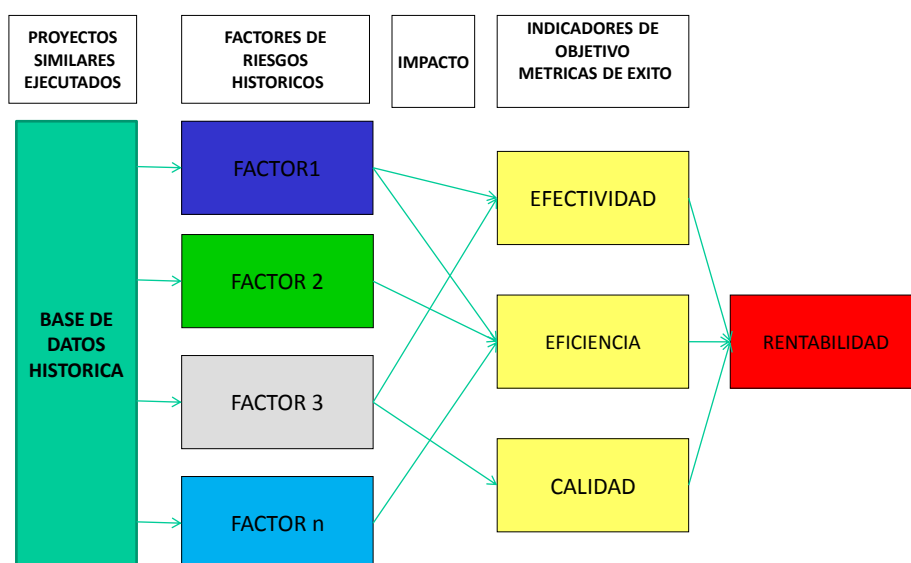
**Figura 3. Impacto de los factores del riesgo en el esquema de rentabilidad.**

Los datos históricos basados en los factores del riesgo permitirán construir una

función de regresión para la evaluación del riesgo, ya que permite generar como salida los umbrales de comparación de los objetivos del proyecto. Esta función es generada usando como herramienta las “redes neuronales artificiales”, cuyo resultado representa la métrica que hemos elegido para representar el éxito.

## 5. Metodología de solución

La Figura 4, describe el impacto de los factores de riesgo sobre los objetivos del proyecto en base a los datos históricos de la organización. Sin embargo, debemos definir los indicadores adecuados que permitan medir si los objetivos de un proyecto (efectividad, eficiencia y calidad) son alcanzados mediante la comparación de umbrales, a los que denotaremos métricas de éxito o *indicadores de objetivo*. Así mismo, se debe definir los indicadores que definen los factores de riesgo y que impactan sobre los objetivos del proyecto, a los que denotaremos *indicadores de factores de riesgo*.



**Figura 4: Base de datos histórica de proyectos similares ejecutados.**

## **5.1 Selección del proyecto.**

En este documento, la metodología solución propuesta será aplicada a las empresas que tengan proyectos recurrentes, en los cuales se pueda identificar los indicadores adecuados que permitan calcular con el mínimo error posible la probabilidad de éxito o fracaso de un proyecto de infraestructura antes de iniciarse, a fin de que la gerencia de la empresa pueda decidir si ejecuta o descarta el proyecto, confirmando las predicciones de éxito o fracaso del proyecto, o realizando un replanteo de las mismas. Asimismo los datos históricos basados en los factores del riesgo permiten generar como salida los umbrales de comparación de los objetivos del proyecto, usando como herramienta las “redes neuronales artificiales”, cuyo resultado representa la métrica que hemos elegido para representar el éxito.

Un ejemplo de empresas que ejecutan proyectos recurrentes son las empresas constructoras que ejecutan proyectos de infraestructura con el Estado, en el cual podemos definir los indicadores de objetivos y los indicadores de los factores del riesgo, los cuales nos permitirán calcular con el mínimo error posible la probabilidad de éxito o fracaso del proyecto antes de iniciarse mediante la técnica de inteligencia artificial: Redes neuronales artificiales.

A continuación se definen los indicadores de objetivo y los indicadores de factores del riesgo para el caso de una empresa constructora de obras de infraestructura tomando como referencia el modelo de gestión de indicadores de Salgueiro Amado (2003).

### **5.1.1 Indicadores objetivos**

En el ítem 4 de este documento se definió los objetivos de un proyecto bajo un *esquema de rentabilidad* descrito en la Figura 2. El esquema permite identificar los indicadores del negocio. El esquema de rentabilidad propuesto está sostenido por tres indicadores generales: Efectividad, Eficiencia y Calidad.

A continuación identificamos los indicadores de objetivos que son medidas de éxito o fracaso en relación a los objetivos de un proyecto, a los cuales denominaremos métricas de éxito del proyecto. Los indicadores son definidos para el caso de una empresa constructora de obras de infraestructura tomando como referencia el modelo de gestión de

indicadores de Salgueiro Amado (2003).

### 5.1.1.2 Indicador de efectividad

Este indicador proporciona información cuantificable sobre el cumplimiento del objetivo planteado (utilidad), y representa la capacidad del proyecto para alcanzar la utilidad programada en el proyecto. En el siguiente cuadro se diseña el indicador de efectividad propuesto.

Descripción del Indicador	Medición
<p><b>EFFECTIVIDAD EN LAS UTILIDADES DEL PROYECTO (EFU)</b>                      Lo definiremos como el grado de cumplimiento del plan de presupuesto económico del proyecto ejecutado, en términos de utilidad y la denotaremos por la variable EFU.</p>	$EFU = \frac{UTILIDAD\ OBTENIDA}{UTILIDAD\ PROGRAMADA}$

### 5.1.1.3 Indicadores de eficiencia

Representan la capacidad del proyecto de lograr concluir el proyecto en el mínimo tiempo y con el menor costo unitario posible (Lezama, 2007). En este sentido se propone el siguiente indicador de eficiencia:

Descripción del Indicador	Medición
<p><b>RELACION DEL PLAZO DE EJECUCION DEL PROYECTO:</b>                      Indica la capacidad de lograr concluir el proyecto en el mínimo tiempo posible.</p>	$\frac{PLAZO\ PROGRAMADO\ DE\ EJECUCION}{PLAZO\ REAL\ DE\ EJECUCION}$
<p><b>NIVEL DE INVENTARIOS</b>                      Indica la eficiencia en uso de capital invertido en inventarios respecto a las ventas netas del proyecto. Eficiencia en el uso de insumos del proyecto.</p>	$\frac{COSTO\ DEL\ INVENTARIO}{VENTAS\ NETAS}$

### 5.1.1.4 Indicadores de calidad

Representan la capacidad del proyecto para satisfacer al cliente, cuantifica la mejora continua de los procesos y resultados. Los indicadores de calidad propuestos son:

<b>Descripción del Indicador</b>	<b>Medición</b>
<b>RENDIMIENTO DE CALIDAD</b> Mide la calidad del proceso, permitiendo detectar las deficiencias en el proyecto (Apaza, 2003). Es una relación entre el avance de ejecución de obra aprobado por el cliente o la supervisión del proyecto (metrado ejecutado conforme) y el avance de ejecución de obra realmente ejecutado (metrado ejecutado real).	$\frac{\text{METRADO DE EJECUCION CONFORME}}{\text{METRADO DE EJECUCION REAL}}$
<b>CALIDAD DEL SERVICIO</b> Mide la calidad del servicio del proyecto con base a la aceptación del cliente (Apaza, 2003). Es una relación entre el avance de obra observado por el cliente (metrado ejecutado observado) y el avance de ejecución de obra total (metrado ejecutado real).	$\frac{\text{METRADO DE EJECUCION OBSERVADO}}{\text{METRADO DE EJECUCION REAL}}$

### 5.1.1.5 Indicadores de rentabilidad.

Miden la efectividad de la administración del proyecto para controlar los costos y gastos, representa la capacidad del proyecto de retornar la inversión. Los indicadores propuestos son:

<b>Descripción del Indicador</b>	<b>Medición</b>
<b>RENTABILIDAD TOTAL</b> Es la utilidad medida en términos de la capacidad de los activos disponibles del proyecto (Lezama, 2007).	$\frac{\text{UTILIDAD NETA}}{\text{ACTIVO TOTAL PROMEDIO}}$
<b>MARGEN NETO</b> Mide la rentabilidad en función de las ventas del proyecto.	$\frac{\text{UTILIDAD NETA}}{\text{VENTAS NETAS}}$

### 5.1.2 Indicadores de los factores del riesgo

Durante la fase de inteligencia y diseño del proceso de toma de decisiones (Figura 1), debemos identificar los eventos que podrían impedir, degradar, demorar, o mejorar el logro de los objetivos de la empresa (por ejemplo la utilidad esperada del proyecto). Estos eventos constituyen las fuentes externas o internas del riesgo en relación a los objetivos de la empresa, que adelante denominaremos *factores del riesgo*.

Sin embargo, se debe tener especial cuidado al definir los factores de riesgo, procurando identificar factores característicos del negocio, de modo que estos no resulten teóricos, irreales o de medición complicada. Se debe lograr que los datos sean lo más

exactos posibles y puedan ser obtenidos con facilidad. Se deben identificar los factores del riesgo que tienen impacto positivo o negativo en los objetivos de un proyecto de infraestructura.

Los factores de riesgo que afectan o impactan la medición de las métricas de éxito del proyecto deben ser expresados por indicadores a calcularse para todo proyecto de infraestructura. Estos indicadores son las entradas al modelo propuesto de la Figura 4 que tiene como salida la métrica de éxito del proyecto y que será expresada en una función de regresión no lineal. El modelo requiere un gran número de indicadores de factores del riesgo, para obtener buenos resultados; sin embargo, si el número de indicadores crece, la métrica de éxito del proyecto será más difícil de estimar utilizando la estadística clásica. Una solución a este problema es usar la herramienta de redes neuronales artificiales, en particular el modelo multicapa “feed-forward Backpropagation” para calcular los valores de la funciones de regresión, de modo que el número de factores considerados no influyen sobre el procedimiento (Cantone et al. 2007). Este documento toma como referencia el modelo de validación de eficiencia adoptado por Cantone Giovanni, Sarcia Salvatore y Basili Victor (2007) basado en el análisis de redes neuronales artificiales como un medio para estimar una función de regresión no lineal, incluso si el número de factores de riesgo es elevado.

Para identificar los factores de riesgo que afectan los objetivos del proyecto, hemos tomado como referencia entre otros el modelo Goal Question Metric (Basili, Caldiera, Rombach, 1994). Si bien este modelo fue creado para estimaciones en proyectos de software, el enfoque Goal Question Metric proporciona un método eficaz para identificar factores e indicadores tanto del proceso como de los resultados de proyectos de infraestructura, considerando que un programa de medición puede ser más satisfactorio si es diseñado teniendo en cuenta los objetivos perseguidos. En este enfoque las preguntas potencialmente medibles ayudan a medir si se está alcanzando en forma exitosa la meta trazada. Algunas preguntas posibles son las siguientes: ¿Qué factores repercuten en el logro del objetivo de proyecto? ¿Cuál es el contexto del proyecto? ¿Cuál es el contexto de la organización?

El siguiente cuadro contiene nuestra propuesta de los factores de riesgo para proyectos de infraestructura y definición de indicadores del riesgo para medir el impacto sobre los objetivos (métricas de éxito) del proyecto. La escala de medición se elaboró en base a los datos provenientes de las experiencias de proyectos similares ejecutados (valores máximos y mínimos) por empresas ejecutoras de obras y de los valores límites permitidos por la legislación vigente. Por ejemplo, el precio ofertado por la ejecución de obras públicas por

una empresa constructora no puede ser menor al 0,9 ni mayor al 1,1 del presupuesto base establecido por la entidad estatal que requiere el servicio, de conformidad con el tercer párrafo del artículo 39 del Reglamento de la Ley de Contrataciones del Estado Peruano promulgado por el Decreto Supremo N° 184-2008-EF.

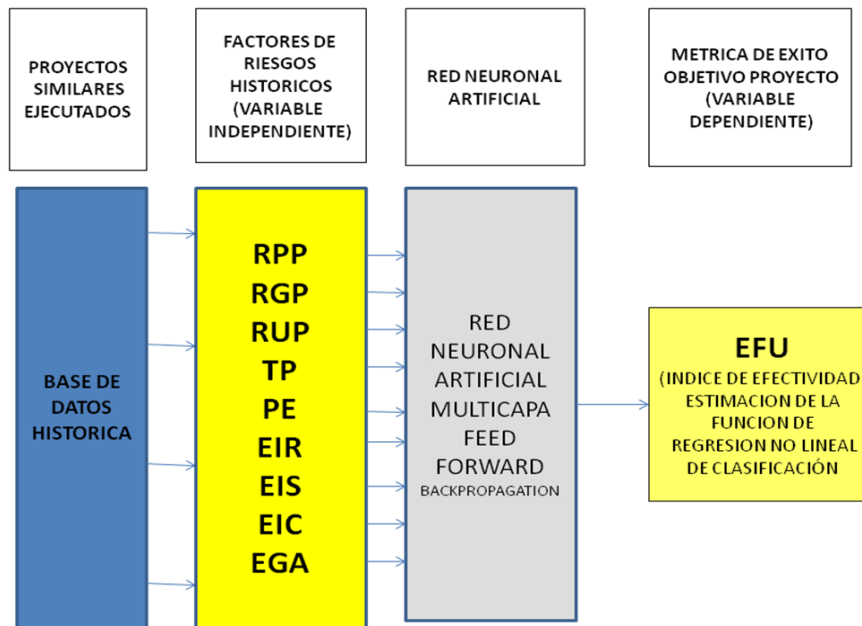
<b>FACTORES DE RIESGO</b>	<b>INDICADOR</b>	<b>MEDICION</b>	<b>SIMBOLO</b>	<b>ESCALA DE MEDICION</b>
Precio ofertado del proyecto	Relación presupuesto ofertado y presupuesto base.	$\frac{\text{PRESUPUESTO OFERTADO}}{\text{PRESUPUESTO BASE}}$	<b>RPP</b>	[0,9 ; 1,10]
Gastos generales del proyecto	Relación gastos generales totales (fijos mas variables) y el costo directo de la obra (presupuesto contratado menos impuestos, gasto generales y utilidades)	$\frac{\text{GASTOS GENERALES}}{\text{COSTO DIRECTO DEL PROYECTO}}$	<b>RGP</b>	[0,0 ; 0,5]
Utilidad prevista del proyecto	Relación utilidad y el costo directo de la obra (presupuesto contratado menos impuestos, gasto generales y utilidades)	$\frac{\text{UTILIDAD}}{\text{COSTO DIRECTO DEL PROYECTO}}$	<b>RUP</b>	[0,0 ; 1,0]
Tipo de proyecto	Tipo de proyecto: 1. Proyecto de edificación. 2. Proyecto de saneamiento. 3. Proyecto Energético. 4. Proyecto de irrigación. 5. Proyecto de carreteras y puentes.	TIPO DE PROYECTO	<b>TP</b>	[1,2,3,4,5]
Duración del proyecto	Plazo de ejecución del Proyecto.	DIAS	<b>PE</b>	[0;1000]
Experiencia en obras.	Experiencia del Ingeniero residente de obras.	AÑOS	<b>EIR</b>	[1;40]
Experiencia en seguridad.	Experiencia del Ingeniero de seguridad.	AÑOS.	<b>EIS</b>	[0;40]
Experiencia en Calidad.	Experiencia del Ing. de Calidad.	AÑOS.	<b>EIC</b>	[0;40]
Experiencia en administración.	Experiencia de la gerencia de administración.	AÑOS.	<b>EGA</b>	[1;40]
Variación de precios de materiales, equipos, mano de obra del sector construcción por inflación.	Factor de reajuste K. Proviene de la fórmula polinómica del proyecto y es calculado en base a los índices de precios unificados del sector construcción publicada por el	FORMULA POLINOMICA DEL PROYECTO	<b>K</b>	[0.5;2]

	Instituto Nacional de Estadística e Informática (INEI).			
--	---	--	--	--

## 5.2 Modelo de predicción de la métrica de éxito

El modelo de predicción tiene como finalidad la estimación de la métrica de éxito del proyecto representado por una función de regresión no lineal utilizando para tal fin la herramienta de redes neuronales artificiales. La métrica de éxito elegida es el índice de efectividad en las utilidades del proyecto (EFU) descrito en el ítem 5.1.1 y la estructura de la red neuronal artificial utilizada en el modelo es la de retro propagación conocida como red multicapa “feed forward” (Rumelhart, Hinton, Williams, 1986) donde las variables de entrada son los indicadores de los factores de riesgo del proyecto, y la salida es la métrica de éxito del proyecto (estimación de función de regresión no lineal). Una descripción de este modelo, se aprecia en la Figura 5, donde el modelo de predicción calcula la métrica de éxito del proyecto, dando como resultado el valor del indicador de efectividad EFU (Efectividad en las utilidades del proyecto). En síntesis, el modelo permite predecir el indicador de efectividad EFU de un proyecto nuevo y asimismo sirve para generar una base de datos donde estén clasificados los proyectos ejecutados por la empresa como con éxito o fracaso. En particular, si para un proyecto su indicador de efectividad (EFU) real es mayor que el indicador de efectividad estimado por el modelo de predicción (valor umbral estimado por la red neuronal) el proyecto se clasifica como éxito (1), caso contrario, se clasifica como un fracaso (0) y se almacena en la base de datos con los indicadores de los factores de riesgos que le corresponde.



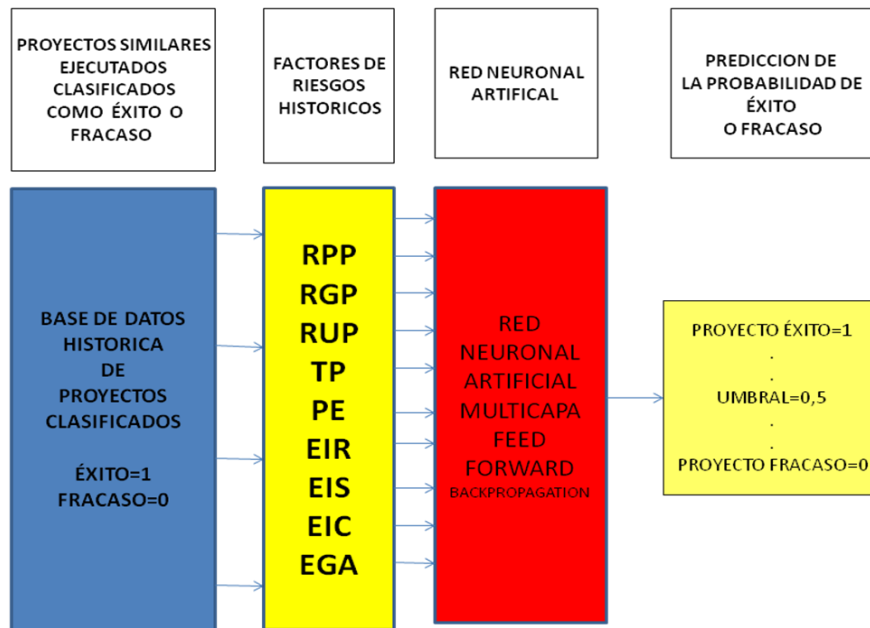


**Figura 5. Modelo de predicción de la métrica de éxito**

### 5.3 Modelo de predicción de éxito o fracaso

Es conveniente tener en cuenta que el riesgo es la probabilidad de tener éxito o fracaso, cuando se toma la decisión de llevar a cabo un proyecto (Del Carpio Gallegos, Javier y Roberto Eyzaguirre Tejada, 2007), por tal motivo se hace necesario realizar una evaluación del riesgo que se está asumiendo, y el riesgo será evaluado por la probabilidad de éxito del proyecto, en una métrica de cero a uno.

Una vez clasificados los proyectos ejecutados por la empresa, como éxito (1) y fracaso (0), agrupados en forma conjunta con los indicadores de los factores de riesgo que determinan su clasificación, es posible construir un modelo que pueda predecir la probabilidad de riesgo de un nuevo proyecto, indicando su tendencia de éxito o fracaso. Esta metodología implica el uso de una segunda red neuronal artificial “feed forward” donde las entradas son los indicadores de los factores de riesgo que afectan los objetivos del proyecto y la salida es un valor entre uno y cero que representa la probabilidad de riesgo de un nuevo proyecto. Para esto se establece un patrón de aceptación o rechazo (fijado en 0,5 o más) a fin de generar la probabilidad de eficiencia del proceso. En este caso, si el valor de salida es entre 0,5 y 1, se establece la tendencia de éxito del proyecto, y si el valor de salida es entre 0 y menos de 0,5 se establece la tendencia de fracaso del proyecto. Una descripción de este modelo se aprecia en la Figura 6.



**Figure 6: Predicción de la probabilidad de éxito o fracaso**

## 6. Caso de estudio

En este caso se considera un conjunto real de observaciones conformado por la información de los proyectos ejecutados por un grupo empresarial peruano formado por cinco empresas dedicados a la ejecución de proyectos de infraestructura. Se logró contar con la data histórica de 209 proyectos de construcción ejecutados por el grupo empresarial desde 1988. La información de cada proyecto se distribuye por empresa conforme el siguiente cuadro:

ITEM	EMPRESAS	GRUPO	ICONSA	R.U.C	NUMERO DE PROYECTOS	DATOS POR PROYECTO	TOTAL DATOS
1	ICONSA S.A			20101361137	70	11	770
2	PROJECT CONSULTING S.A			20259956197	69	11	759
3	CONSTRUCTORA SAN GRABRIEL S.A.C			20511662568	30	11	330
4	CONSTRUCTORA AMAZONAS S.A.C			20463422240	10	11	110
5	PROICE S.A.C.			20505746016	30	11	330
					209		2299

En cada proyecto se identificaron once indicadores haciendo un total de 2299 datos que representan los índices de los factores de riesgo diseñados en el ítem 5.1.2 del presente documento. El cuadro siguiente resume los indicadores usados para medir los factores de riesgo que afectan a los objetivos de cada proyecto:

ITEM	FACTORES DE RIESGO	INDICADOR	SIMBOLO	ESCALA DE	PASO	CARDINAL
------	--------------------	-----------	---------	-----------	------	----------

				MEDICION		
1	Precio ofertado del proyecto	Relación presupuesto contratado y presupuesto base.	<b>RPP</b>	[0,90 ; 1,10]	0,01	21
2	Gastos generales del proyecto	Relación gastos generales y el costo directo del presupuesto.	<b>RGP</b>	[0,01 ; 0,50]	0,01	50
3	Utilidad prevista del proyecto	Relación utilidad y el costo directo del presupuesto.	<b>RUP</b>	[0,01 ; 1,00]	0,01	100
4	Tipo de proyecto	Tipo de proyecto.	<b>TP</b>	[1,2,3,4,5]	1	5
5	Duración del proyecto	Plazo de ejecución del Proyecto.	<b>PE</b>	[1;1000]	20	50
6	Experiencia en obras.	Experiencia del Ingeniero residente.	<b>EIR</b>	[1;40]	1	40
7	Experiencia en seguridad.	Experiencia del Ingeniero de seguridad.	<b>EIS</b>	[0;40]	1	41
8	Experiencia en calidad.	Experiencia del Ing. de Calidad	<b>EIC</b>	[0;40]	1	41
9	Experiencia en administración.	Experiencia de la gerencia de administración.	<b>EGA</b>	[1;40]	1	40
10	Variación de precios de materiales, equipos, mano de obra del sector construcción por inflación.	Factor de reajuste K. (Índice de precios Unificados del Sector Construcción)	<b>K</b>	[0.5;2]	0,1	16

## 6.1 Elección del modelo

Las pruebas de clasificación se efectuaron con el modelo de red neuronal artificial multicapa “feedforward” (Rumelhart, Hinton, Williams, 1986) usando el algoritmo de aprendizaje de retro propagación de Levenberg-Marquardt (Gradiente descendente optimizado). A fin de mejorar la precisión de la red, se empleó una cantidad más amplia de datos, considerando un conjunto de prueba adicional al de validación. Se probaron 16 arquitecturas de redes neuronales artificiales. La distribución del número de capas como la cantidad de neuronas por capa se dio bajo la permutación de los números 5, 9, 10 y 20 (obtenidos por una función

random de rango [2; 20]). El programa utilizado para la simulación y entrenamiento de la red fue MatLab™ (*Neural Networks Toolbox*), asimismo se empleó el software Minitab Solutions para el cálculo de los datos estadísticos y la elaboración de histogramas. La función de transición empleada en la red perceptrón multicapa *feedforward*, es la función *sigmoidal*, para la capa de entrada y las capas ocultas, y una función lineal, para la capa de salida de la red.

De los 209 conjuntos de datos empleados (cada conjunto tiene 11 indicadores) en la preparación de las redes, se emplearon 171 en el conjunto de entrenamiento, 19 en el conjunto de validación y 19 en el de prueba.

## **6.2 Evaluación de la red**

El entrenamiento de las diferentes arquitecturas de redes neuronales artificiales, se evaluó teniendo en consideración dos métricas: el grado de error y el rendimiento (Mse). Para la medición del grado del error de cada arquitectura se empleó el error absoluto medio (Mean) del conjunto de validación y del conjunto de prueba. Finalmente, la definición del mejor modelo se realizó en base al cálculo del error absoluto medio (Mean) de ambos conjuntos.

Para la evaluación de los resultados de salida de las diferentes arquitecturas probadas, se empleó el índice de rendimiento (Mse) proporcionado por Matlab (Error cuadrático medio relativo al conjunto de entrenamiento) y la media del error absoluto (Mean) de los conjuntos de validación y prueba. Además se calculó la desviación estándar del error absoluto de ambos conjuntos para observar la estabilidad de la red. Los resultados se muestran en la Tabla 1.

**Tabla 1. Errores medio y desviación estándar.**

	Entrenamiento	Total		Validación		Test	
	Mse	Mean	StDev	Mean	StDev	Mean	StDev
5x5	0.000888	5.96%	5.25%	3.91%	4.71%	7.51%	5.09%
5x9	0.000177	9.78%	12.25%	3.61%	3.55%	15.95%	14.71%
5x10	0.000543	9.34%	6.38%	6.28%	5.18%	11.98%	6.34%
5x20	0.00573	16.76%	12.97%	12.07%	10.87%	21.33%	13.77%
9x5	0.00687	8.05%	4.84%	5.38%	4.22%	10.19%	4.03%
9x9	0.0000491	7.29%	4.71%	4.22%	3.67%	9.88%	3.78%
9x10	0.00166	9.45%	6.21%	6.39%	5.95%	11.80%	4.96%
9x20	0.00391	8.42%	6.15%	8.05%	5.99%	8.39%	6.37%
10x5	0.0024	6.22%	5.80%	5.04%	5.83%	7.21%	5.86%
10x9	0.000244	10.03%	10.78%	5.56%	5.23%	14.18%	13.22%
10x10	0.00809	9.95%	6.20%	10.28%	6.04%	9.39%	6.55%
10x20	0.000927	15.17%	8.24%	10.33%	7.76%	19.51%	6.19%
20x5	0.000602	7.11%	7.81%	6.26%	9.70%	7.75%	5.91%
20x9	0.000228	10.07%	12.77%	3.72%	3.83%	15.90%	15.63%
20x10	0.000666	5.67%	3.44%	5.27%	2.90%	5.85%	3.92%
20x20	0.00327	7.33%	5.58%	7.40%	4.84%	7.02%	6.35%

Los resultados mostrados en la Tabla 1, indican que la arquitectura que presenta menor error y que mejor se ajusta para la predicción del modelo es la red *feedforward* 20 x 10 (20 capas ocultas, 10 neuronas en la capa escondida, 10 neuronas en la entrada y una neurona en la salida). Por lo tanto, se escogió la mencionada red como la más apta para la predicción del modelo debido al bajo porcentaje de error que obtiene en los conjuntos de validación y prueba. Se descarta el índice del rendimiento pues es un índice referencial al entrenamiento y a la validación (Matlab solo emplea el conjunto de la prueba para la visualización gráfica de los resultados de la regresión).

### 6.3 Clasificación de los proyectos en dos clases: éxito y fracaso

Se procedió a clasificar los proyectos históricos de la empresa (proyectos ejecutados) en un conjunto de dos clases: éxito (1) o fracaso (0), mediante la comparación del valor que arroja la red: el valor umbral del índice de efectividad en las utilidades (EFU), el cual es comparado con el EFU real del proyecto ejecutado, si el EFU real es mayor o igual que el EFU que arroja el modelo de predicción, entonces lo clasificamos como éxito, caso contrario como fracaso. Considerando este esquema se puede construir una base de datos histórica donde los proyectos de infraestructura ejecutados por la empresa forma una clase éxito con clasificación 1 y una clase fracaso con clasificación 0. Las salidas se determinaron según el signo de la diferencia entre el valor real y el valor estimado del índice EFU, en el caso de ser no nulo o positivo se califica el valor como 1 (éxito), en caso de ser negativo (si realmente se está por debajo del promedio) se califica como fracaso.

## 6.4 Cálculo de la probabilidad de éxito o fracaso de un proyecto

Una vez construida la base de datos que contiene todos los proyectos ejecutados por la empresa, con sus indicadores de los factores de riesgo y su respectiva clasificación como éxito (1) o fracaso (0), se procedió a implementar el modelo que prediga la probabilidad de riesgo de un nuevo proyecto, indicando su tendencia de éxito o fracaso. Esta metodología implicó el uso de una segunda red neuronal artificial “feed forward” donde las entradas son los indicadores de los factores de riesgo que afectan los objetivos del proyecto y la salida que se obtuvo es un valor entre uno y cero que representa la probabilidad de riesgo de un nuevo proyecto. Por ejemplo, un valor de salida 1 indicara que el proyecto será un éxito, y un valor cero de que el proyecto será un fracaso, pero si la salida es un valor fraccionario como 0,3 significa que existe un 30% de probabilidad de éxito del proyecto y un 70% de probabilidad que los riesgos se produzca y si la salida es un valor de 0,9 indicará que existe una probabilidad del 90% de éxito y un 10% de probabilidad que los riesgos se produzcan en el proyecto.

Se optó por crear 16 arquitecturas de redes siguiendo los mismos patrones que en la primera red. Al igual que en la etapa anterior, se busca analizar el performance de la red y la medida del error porcentual (Mean) para la elección de la mejor arquitectura y representación de los patrones. Se puede observar los índices del aprendizaje en la tabla 4.

**Tabla 4. Errores medio y desviación estándar**

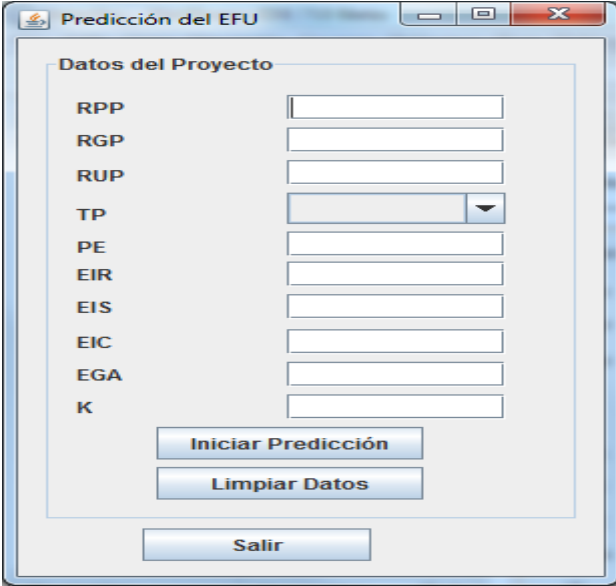
	Entrenamiento	Total		Validación		Test	
	MSE	Mean	StDev	Mean	StDev	Mean	StDev
<b>5x5</b>	0.0702	<b>30.36%</b>	31.20%	17.37%	25.54%	42.42%	32.59%
<b>5x9</b>	0.0867	<b>16.96%</b>	19.40%	14.31%	21.04%	20.25%	18.02%
<b>5x10</b>	0.0132	<b>21.06%</b>	41.16%	13.04%	26.99%	29.65%	51.31%
<b>5x20</b>	0.186	<b>45.74%</b>	20.35%	34.84%	20.17%	55.08%	15.39%
<b>9x5</b>	0.0723	<b>23.16%</b>	34.45%	11.70%	23.76%	34.58%	40.39%
<b>9x9</b>	0.209	<b>45.78%</b>	25.39%	34.05%	24.88%	56.19%	21.87%
<b>9x10</b>	0.19	<b>47.12%</b>	17.71%	36.91%	18.82%	56.25%	10.59%
<b>9x20</b>	0.189	<b>52.86%</b>	35.54%	37.91%	36.42%	64.13%	28.60%
<b>10x5</b>	0.0875	<b>40.12%</b>	36.31%	24.22%	34.53%	54.84%	33.16%
<b>10x9</b>	0.185	<b>37.96%</b>	20.78%	34.79%	17.92%	41.62%	23.48%
<b>10x10</b>	<b>0.0606</b>	<b>11.76%</b>	<b>23.68%</b>	<b>10.29%</b>	<b>23.45%</b>	<b>13.62%</b>	<b>24.96%</b>
<b>10x20</b>	0.201	<b>51.90%</b>	15.98%	45.58%	14.72%	57.12%	15.48%
<b>20x5</b>	0.204	<b>54.52%</b>	18.55%	44.84%	19.64%	62.89%	12.74%
<b>20x9</b>	0.224	<b>54.25%</b>	15.80%	46.41%	16.21%	61.06%	12.11%
<b>20x10</b>	0.219	<b>45.65%</b>	28.53%	32.68%	28.44%	57.25%	24.28%
<b>20x20</b>	0.139	<b>52.99%</b>	26.65%	41.18%	27.34%	63.53%	22.12%

## 6.5 Construcción de la interfaz de predicción de éxito

Para poder culminar el caso de estudio, se procedió a construir una interfaz visual que acepte valores de los indicadores de los factores de riesgo del proyecto como datos de entrada para predecir la métrica de éxito que en el modelo es el indicador de efectividad (EFU) descrito en el ítem 5.1.1. A pesar de que se podría utilizar Matlab para la ejecución de la predicción, se descartó su uso por el grado de dificultad en el empleo del modelo escogido y el tiempo excesivo de ejecución que tarda en realizar toda la secuencia de simulación.

Se eligió por construir una interfaz, que se programó en el lenguaje de programación JAVA, y se empleo el IDE Netbeans 7.0 Beta para su desarrollo. La ejecución de esta interfaz, requiere JRE 6 (Java Runtime Environment) y un sistema operativo que soporte JRE6.

La interfaz visual es un formulario, el cual tiene como parámetros los diez índices especificados para el empleo del modelo. También tiene tres opciones para cerrar la ventana, limpiar los campos y predecir el resultado según los datos ingresados. Se puede apreciar esta interfaz en la figura 10.



**Figura 10. Interfaz visual.**

El código del formulario (interfaz) se encuentra en el anexo.

## **7. Conclusiones**

Este documento propone un modelo de ayuda al proceso de toma de decisiones en la selección de proyectos de ejecución de infraestructura, proponiendo un cálculo objetivo del indicador de efectividad y del cálculo de la probabilidad de éxito o fracaso del proyecto antes de ser iniciado, estableciendo un proceso que utilice los datos históricos de proyectos similares ejecutados por la organización, buscando identificar los factores de riesgo que afectan sus objetivos, evaluando los datos históricos de la organización, logrando generar un proceso inteligente y predictivo en el proceso de toma de decisiones de la empresa de la empresa en las fases de inteligencia y diseño. Se establece un mecanismo para el diseño de indicadores históricos de medición, determinando los factores del riesgo que impactan en los objetivos del proyecto. Los indicadores reales son obtenidos en base a las actuaciones reales de la organización. Ayuda a mejorar el grado de confiabilidad en la toma de decisiones con factores de riesgo en las empresas constructoras, que podría servir para confirmar las predicciones subjetivas, o realizar un replanteo de las mismas, proporcionando una manera de comparar los datos históricos sobre los riesgos identificados usando como herramienta las redes neuronales artificiales.

## **8. Fuentes bibliográficas**

Apaza Mario (2003). *Balanced Scorecard Gerencia estratégica y de valor*. Instituto de Investigaciones del Pacífico. Pacífico Editores, pp 281-404.

Aréchiga Hugo (2000). "Conceptos homeostasis". Centro de Investigaciones Interdisciplinarias en Ciencias y Humanidades. Universidad Autónoma de Mexico, Fondo Editorial.

AS/NZS 4360:2004 Junta de estándares de Australia y Nueva Zelanda (1999). "Estándar Australiano/Neozelandés AS/NZ 4360:1999 sobre administración de riesgos como una revisión de AS/NZ 4360:1995". [En línea] <<http://www.standards.org.au>>. [Consulta: 31 de marzo del 2010.]

Basili Victor; Caldiera Gianluigi y Rombach H. Dieter (1994). "The Goal Question Metric Approach". Institute for Advance Computer Studies. Department of Computer Science. University of Maryland. College Park Maryland.



Cantone Giovanni; Salvatore Alessandro Sarciá y Victor Basili (2007) "A Statistical Neural Network for Risk Management Process". Departamento de Ciencias de la Computación de la Universidad de Maryland.

Cruz Lezama, Osain (2007). "Componentes de un proyecto de inversión". [En línea] <<http://www.cadperu.com>>. [Consulta: 15 de Julio del 2010.]

Del Carpio Gallegos, Javier y Roberto Eyzaguirre Tejada ( Junio del 2007). "Análisis de riesgo en la evaluación de alternativas de inversión utilizando Crystal Ball. *Ind. data.*" ISSN 1810-9993. Vol. 10, núm. 1, p.55-58.

<[http://www.scielo.org.pe/scielo.php?script=sci\\_arttext&pid=S1810-9932007000100009 & lng = es&nrm=iso](http://www.scielo.org.pe/scielo.php?script=sci_arttext&pid=S1810-9932007000100009&lng=es&nrm=iso)>. [Consulta: 20 Octubre 2011.]

Galarce, Trujillo Yorcka; Pomier, Rivera Maria y Carolina Pastén Arce. (2006). Seminario Profesional para optar al Título Profesional: Contador Público – Contador Auditor". Universidad Arturo Prat. Departamento de Auditoría y Sistema de Información. Sede Arica.

Smith, J.C.(1990) "A Neural Network -- Could It Work for You?" *Financial Executive*, Vol. 6, No. 3, May/June 1990, pp. 26-30.

Isasi Viñuela, Pedro y Ines Galván León (2004), "Redes Neuronales Artificiales. Un Enfoque Práctico". Pearson education S.A. Madrid.

Berardinis, L.A. (1992). "Untangling the Mystery of Neural Networks," *Machine Design*, Vol. 65, No. 13, June 25, 1992, pp. 55-59.

Hopfield, J.J. (1982). "Neural Networks and Physical Systems with Emergent Collective Computational Abilities," *Proceedings of the National Academy of Science*, Vol. 79, 1982, pp. 2554-2558.

Michie, D., Spiegelhalter, D.J. y C.C. Taylor (1994). *Machine learning, neural and statistical classification*. Londres: Ellis Horwood.

Rumelhart, D.E., Hinton, G.E. y R.J. Williams (1986) "Learning Internal Representations by error Propagation", en Rumelhart, D.E., McClelland, J.L. and the PDP Research Group (1986) Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1, MIT Press.

Salgueiro, Amado (2001). Indicadores de gestión y cuadro de mando. Ediciones Diaz Santos S.A, Juan Bravo, 3-A, 28006. Madrid. España, pp 1-25.

Solis, Reiner (2012) "Redes Neuronales para la optimización del riesgo empresarial en las empresas del sector construcción". Memorias de la XLVII Asamblea Anual CLADEA 2012. <http://cladea.org/proceedings2012/visor/view/resumen.php?id=1&id0=17&id1=2>. [Consulta: 01 de octubre del 2013.]

Koprinarov, Bratoy (2005). "El riesgo empresarial y su gestión". [En línea] <<http://www.analitica.com/va/economia/opinion/5753437.asp>>. [Consulta: 31 de marzo del 2010.]

Cano, Pons Carlos; Valero Herrera y Maheut Julien (2013). Toma de decisiones en la empresa proceso y clasificación. Universidad Politécnica de Valencia. <<http://riunet.upv.es/bitstream/handle/10251/16502/TomaDecisiones.pdf?sequence=1>>. [Consulta: 05 de octubre del 2013.]

Claver, E.; Llopis, J.; , M.; Molina, H. (2000). "Manual de administración de empresas", 4ª edición, Civitas, Madrid.

Cyert, R.M.; March, J.G. (1965). Teoría de las decisiones económicas de la empresa. Herrero Hermanos, México, 1965.

Davis, D (2000). Investigación en administración para la toma de decisiones. Thomson, México.

Dixon, J.R. (1970). Diseño en ingeniería: inventiva, análisis y toma de decisiones. Limusa-Wiley, México.

González Ramírez, M.R.(2001). Sistemas de información para la empresa. Publicaciones de la Universidad de Alicante.

Greenwood, W. (1978). Teoría de decisiones y sistemas de información”, Trillas, México.

Herrera, F.; Herrera-Viedma, E.; Verdegay, J.L. (1996). Direct approach processes in group decision making using linguistic OWA operators”, Fuzzy Sets and Systems, 79, págs. 175-190.

Huber, G.P. (1984). Toma de decisiones en la gerencia, Trillas, México, 1984.

Keen, P.G.W. Scoot Morton, M.S. (1978). Decision Support Systems: Organizational perspective, Addison Wesley.

Menguzzato, M.; Renau, J.J.(1995). La dirección estratégica de la empresa. Un enfoque innovador del management, Ariel, Barcelona.

Moody, P.E.: “Toma de decisiones gerenciales (1991), Mc Graw Hill Latinoamericana, Bogotá.

Serra, D.: “Métodos cuantitativos para la toma de decisiones”, Gestión 2000, Madrid, 2004.

Simon, H.A. (1980). El comportamiento administrativo. Estudio de los procesos decisorios en la organización administrativa, Aguilar, Madrid, 1980.

Simon, H.A. (1977). The new science of management decision”, Prentice-Hall, Englewood Cliffs, New Jersey.

Zimmermann, H.J (1991). Fuzzy sets theory and its application”, Kluwer Academic Publishers, Boston.

## **9. Anexo**

### **Código del formulario (Interfaz)**

package RNA\_20x20;

```

import java.lang.StrictMath;
import javax.swing.JOptionPane;
import javax.swing.JPanel;
public class Red {
public static double TanSig (double a){
    double operacion;
    if (a<500 || a>-500)
        operacion=((Math.pow(Math.E, a)-Math.pow(Math.E, -1*a))/(Math.pow(Math.E, a)+Math.pow(Math.E, -
1*a)));
    else if (a>500)
        operacion=1;
    else
        operacion=-1;
    System.out.println(a+" respuesta "+ operacion+"\n");
return operacion;
}
public static double CalcularRed (double a []){
    for (int i=0; i<20;i++){
        for (int j=0;j<10;j++){
            double suma=0;
            for (int k=0;k<10;k++){
                if (i==0)suma+=capasEscondidas[i][i][j]*a[k];
                else suma+=capasEscondidas[i][j][k]*capaA[k];
            }
            capaB[j]=TanSig(suma+umbral[i][j]);
        }
        System.arraycopy(capaB, 0, capaA, 0, 10);
    }
    double respuesta=0;
    for(int i=0;i<10;i++){
        respuesta+=capaSalida[i]*capaA[i];
    }
return respuesta+1.23569;
}
}
}

```