

Propuesta de Proceso para Selección de Arquitectura de un Modelo Predictivo Inteligente

Cinthia Vegega^{1,2}, Luciano Straccia^{1,2}, Pablo Pytel^{1,2} & María Florencia Pollo-Cattaneo^{1,2}

¹ Grupo de Estudio en Metodologías de Ingeniería en Software (GEMIS). Universidad Tecnológica Nacional. Facultad Regional Buenos Aires. Argentina.

² Programa de Maestría en Ingeniería en Sistemas de Información. Facultad Regional Buenos Aires. Universidad Tecnológica Nacional. Argentina

cinthiavg@yahoo.com.ar; {pppytel, flo.pollo}@gmail.com

Resumen. Diariamente, los gerentes deben tomar decisiones sobre cómo asignar sus recursos. Estas decisiones deben basarse en predicciones sobre el tiempo, el esfuerzo y/o los riesgos de llevar a cabo sus actividades. Actualmente esta situación se encuentra acentuada por el entorno complejo que rodea a las organizaciones lo cual provoca que deban actuar más allá de los sistemas tradicionales de gestión incorporando nuevos mecanismos, como los provistos por la Inteligencia Artificial. En este caso, se estaría desarrollando un Modelo Predictivo Inteligente. Se ha observado una dificultad asociada a la construcción de estos modelos al tratar de determinar el tipo de arquitectura a aplicar. Por lo tanto, el presente trabajo tiene como objetivo proponer un proceso para llevar a cabo la selección de la arquitectura más apropiada de acuerdo a las características asociadas al proyecto y su contexto, a los datos disponibles y a los resultados esperados que se generen.

Palabras Claves: Modelo Predictivo. Red Neuronal Artificial. Red Bayesiana. Toma de Decisiones. Organización.

1. Introducción

La toma de decisiones es un proceso esencial en la vida de las organizaciones. Aunque cada miembro dentro de una organización toma decisiones, este proceso es particularmente importante para los roles gerenciales. Es por esto, que a los gerentes se los conoce como 'tomadores de decisiones' en sus actividades de planear, organizar, dirigir y controlar [1]. Diariamente deben decidir cómo asignar sus valiosos recursos basados en predicciones [2] sobre el tiempo, el esfuerzo y/o los riesgos que implica llevar a cabo sus actividades. Esta situación se encuentra acentuada debido al entorno altamente complejo y de difícil predicción del siglo XXI [3], lo cual genera que las organizaciones deban actuar más allá de los sistemas tradicionales de gestión e incorporar nuevos mecanismos para la "creación y potenciación del conocimiento organizativo", tales como los provistos por la Inteligencia Artificial [4, 5].

Un caso de estos nuevos mecanismos se puede encontrar en el ámbito de los Modelos Predictivos. A pesar de que tradicionalmente se han aplicado Técnicas Estadísticas y Modelos Paramétricos para generar predicciones [6], en las dos últimas décadas se

han incorporado diversos métodos asociados al Aprendizaje Automático [2, 7]. Estos métodos son considerados normalmente como ‘cajas negras’ o modelos basados en datos [8, 9, 10], debido a que aplican procedimientos (totalmente) automáticos para generar modelos no-lineales que describen la relación entre diferentes atributos de un conjunto de datos. De esta manera, es posible construir modelos que permitan encontrar la relación entre situaciones pasadas y futuras usando los datos históricos disponibles. En este sentido, se pueden destacar las Redes Neuronales Artificiales o RNA [11, 12] y, las Redes Bayesianas o RB [13, 14] como las principales arquitecturas de Sistemas Inteligentes a ser utilizadas para este tipo de problema [15-18]. Estos Modelos Predictivos, basados en Sistemas Inteligentes, presentan características muy útiles, tales como son la capacidad de generalización, robustez y auto-organización [3, 19]. Sin embargo, una dificultad asociada a la construcción de los Modelos Predictivos Inteligentes tiene que ver con determinar el tipo de arquitectura a aplicar. De acuerdo al Teorema de ‘No Free Lunch’ [20, 21], no existe ningún algoritmo de aprendizaje automático que pueda ser aplicado para cualquier problema, por lo que se debería siempre llevar a cabo una selección, teniendo en cuenta los objetivos planteados, las características del dominio y de los datos disponibles [22]. Por consiguiente, todo ésto debe ser definido al comienzo del proyecto.

En este contexto, el presente trabajo tiene como objetivo proponer un proceso para llevar a cabo la selección de la arquitectura que permita evaluar la adecuación de cada una de ellas y así determinar cuál es la más apropiada. Aunque en esta propuesta se ha decidido acotar el alcance a dos tipos de Sistemas Inteligentes, las RNA y las RB, ninguna de ellas es la panacea [17, 18]. Cada una tiene sus puntos fuertes y débiles que deberán ser contrastadas contra los elementos del problema para determinar cuál es la mejor solución a aplicar. Para ello, primero se detallan las condiciones a considerar para evaluar cada arquitectura, este caso RNA y RB (sección 2). Luego se presenta el proceso propuesto (sección 3), realizando dos pruebas de concepto para su validación (sección 4). Finalmente se indican las conclusiones obtenidas y futuras líneas de trabajo (sección 5).

2. Condiciones a considerar al Evaluar una Arquitectura

Para poder proponer un modelo que permita la evaluación de una arquitectura, primero es necesario identificar las principales condiciones que una tecnología debe cumplir en un proyecto para ser considerada como adecuada para la construcción de un Modelo Predictivo. A partir de la investigación documental realizada en [2, 6, 17, 22-33], se determinan los conceptos de interés para evaluar las arquitecturas a fin de construir el Modelo Predictivo y así seleccionar la que resulte más apropiada de acuerdo a las particularidades del proyecto. A continuación, se presentan dichas condiciones para cada una de las arquitecturas consideradas:

- Se considera apropiado **utilizar una RNA o una RB** para la implementación del Modelo Predictivo si se cumplen las siguientes condiciones:
 - Los datos disponibles son representativos del problema que se quiere resolver.
 - Los datos disponibles son suficientemente complejos con una relación no lineal entre sus atributos, por lo que las técnicas estadísticas tradicionales no permitirían encontrar una buena solución al problema.

- El problema a ser resuelto mediante el Modelo Predictivo no va a cambiar en el corto plazo por lo que se considera como estable.
- Además de las condiciones anteriores, se considera apropiado **utilizar una RNA** si se cumplen las siguientes condiciones:
 - Los datos disponibles incluyen gran cantidad de ejemplos para realizar el entrenamiento y validación de la red, y además poseen todos sus valores en forma numérica (continuos o discretos).
 - La precisión de los resultados es muy importante y se puede considerar como crítica para asegurar el éxito del modelo.
 - No se necesita conocer cómo se obtuvieron los resultados generados, en otras palabras, no es necesario que la red explique o justifique los resultados obtenidos.
 - No se requiere que la red represente las relaciones entre los datos para poder realizar ajustes manuales, por lo que no necesario contar con la asistencia de expertos del dominio para participar en el desarrollo.
- En cambio, es apropiado **utilizar una RB** si a las condiciones iniciales se agregan las siguientes:
 - Los datos disponibles incluyen una cantidad suficiente de ejemplos para realizar el entrenamiento y validación de la red y, poseen sus valores como valores alfanuméricos, numéricos discretos, o numéricos continuos para los cuales es posible definir rangos.
 - En el caso que los datos disponibles son poco representativos o no incluyen una cantidad suficiente de ejemplos, se dispone de expertos del dominio que pueden aportar su conocimiento para participar en el desarrollo (especialmente en el modelado de la red).
 - La precisión de los resultados no es tan importante porque se valoran también otras cuestiones tales como: poder comparar las predicciones para diferentes posibilidades o escenarios; conocer cómo se obtuvieron los resultados generados, es decir que, la red explique o justifique los resultados; poder realizar ajustes en la red en base al conocimiento disponible sobre el problema y las relaciones entre los atributos de los datos.

3. Proceso Propuesto

Para definir el proceso propuesto se consideran las características del proyecto, las cuales se han organizado en tres grupos: las asociadas al problema detectado y su contexto, las asociadas a los datos disponibles para el entrenamiento y, las correspondientes a los resultados esperados que genere el modelo. Por lo tanto, el proceso necesita que se responda a un conjunto de preguntas cuyas respuestas permitan caracterizar al proyecto. Sin embargo, al comienzo de un proyecto no resulta sencillo contestar estas preguntas con un adecuado grado de certeza (proporcionando respuestas del tipo 'sí' / 'no' o, con un valor numérico). En virtud de estas consideraciones, el proceso propuesto se basa en el principio de los Sistemas Expertos Difusos [34], permitiendo de esta manera, manejar un rango de cinco valores lingüísticos (entre 'nada' y 'todo') y, de esta manera dar respuesta a cada una de las preguntas a considerar. Al hacer uso de un procedimiento sencillo es posible transformar estos valores lingüísticos, indicados por el ingeniero, en intervalos difusos que luego serán utilizados para obtener una valoración sobre la adecuación de cada arquitectura. A continuación, se describen los cinco pasos que se deben realizar (los cuales han sido implementados en la planilla disponible en [35]):

Paso 1: Determinar el valor correspondiente para las características del proyecto

Para caracterizar un proyecto de construcción de un Modelo Predictivo, y evaluar la arquitectura más adecuada, se utilizan las características definidas en la Tabla 1, las cuales están basadas en las condiciones indicadas en la sección 2. El ingeniero debe responder las preguntas asociadas a cada característica a partir del resultado de las entrevistas realizadas en la organización. Los valores lingüísticos permitidos para las respuestas son: *'nada'*, *'poco'*, *'regular'*, *'mucho'* y *'todo'*, donde cuanto más verdadera parezca una característica, mayor valor se le debe asignar; y, cuanto más falsa parezca, menor valor. Nótese que por cada característica, el método tiene asignado un valor de umbral mínimo que el proyecto debe igualar o superar. En caso que el valor asignado a la característica no supere el umbral, se puede considerar que ninguna de las arquitecturas es apropiada para ser aplicada y, por lo tanto, no es necesario continuar con los pasos siguientes.

Tabla 1. Características del Proyecto a ser Evaluadas por el Proceso Propuesto.

Categoría	ID	Pregunta Asociada a la Característica	Umbral	Peso RNA	Peso RB
Datos Disponibles	D1	¿Cuánta confianza se tiene que los datos son representativos?	regular	10	10
	D2	¿En qué medida se pueden considerar a los datos como complejos y con una relación no lineal entre sus atributos?	poco	9	6
	D3	¿Cuánta cantidad de ejemplos incluyen los datos?	poco	15	7
	D4	¿Cuál es la proporción de datos con valores numéricos continuos (con respecto a valores no numéricos o numéricos discretos)?	nada	10	-7
Resultados Esperados	R1	¿Cuán crítica se considera la precisión de la predicción?	nada	12	-3
	R2	¿En qué medida se desea conocer comparar las predicciones para diferentes posibilidades o escenarios?	nada	-4	12
	R3	¿Con qué grado de importancia se desea que se puedan explicar cómo se obtuvieron los resultados generados?	nada	-13	15
Dominio del Problema	P1	¿Qué tan estable es el problema a resolver?	regular	10	10
	P2	¿Cuánta disponibilidad tienen los expertos del dominio para participar en el desarrollo?	nada	-6	14
	P3	¿Qué tan deseable es poder ajustar manualmente la red a partir de los conocimientos sobre los datos?	nada	-11	16

Donde, por cada característica, se definen los siguientes atributos:

- *Categoría*, que es utilizado únicamente para poder agrupar las características de acuerdo a qué o quién se refiere.
- *ID*, que indica el código para identificar unívocamente a la característica.
- *Pregunta Asociada a la Característica*, que describe la condición que debe responder el ingeniero con el valor lingüístico correspondiente.
- *Umbral*, que define el valor que la característica debe igualar o superar.
- *Peso RNA*, que indica la importancia relativa a cada característica en la evaluación de la adecuación de las *Redes Neuronales Artificiales*.
- *Peso RB*, que indica la importancia relativa a cada característica en la evaluación de la adecuación de las *Redes Bayesianas*.

Asimismo, se puede observar en la Tabla 1 que existen diferentes valores de pesos por cada característica y tipo de arquitectura (*'Peso RNA'* y *'Peso RB'*). Dichos valores han sido asignados mediante la evaluación de las condiciones antes indicadas junto con la experiencia de ingenieros en la construcción de Sistemas Inteligentes. Como se puede notar, si los valores de los pesos son mayores a cero, significa que la característica es favorable para la arquitectura, por lo que cuanto mayor valor tenga

dicha característica más debería aumentar la adecuación de dicha arquitectura. Sin embargo, si el peso es menor a cero, significa que la característica es desfavorable, por lo que su aumento disminuirá su adecuación. Por último, cabe aclarar que esta diferencia entre los valores de los pesos son soportados por los siguientes pasos del proceso (siempre que la suma de los valores absolutos por cada arquitectura sea igual a 100).

Paso 2: Convertir los valores en intervalos difusos

Una vez que para cada característica de la Tabla 1 se han asignado los valores lingüísticos correspondientes, estos valores se deben traducir a los intervalos difusos correspondientes, dependiendo del valor del peso de la característica. En este sentido, a cada valor lingüístico se le define un intervalo difuso expresado por cuatro valores numéricos (entre cero y diez), que representan los puntos de ruptura (o puntos angulares) de su función de pertenencia correspondiente. Dichos intervalos, junto con la representación gráfica de la función de pertenencia, se indican en la Figura 1.

Cuando el valor de los pesos para las características es mayor o igual a cero, se asigna directamente el intervalo difuso al valor lingüístico asignado por el ingeniero. Pero, cuando el valor del peso de la característica es negativo, la asignación no es tan directa. En este caso, se debe asignar el intervalo difuso del valor opuesto al asignado por el ingeniero. Entonces, si el valor asignado es *'nada'* se debe utilizar el intervalo correspondiente a *'todo'*, si el valor asignado es *'poco'* se utiliza el intervalo de *'mucho'*, si es *'mucho'* se utiliza el de *'poco'*, y si es *'todo'* se usa el de *'nada'*. Nótese que para el valor *'regular'* no existe un valor opuesto, por lo que se usa su intervalo difuso directamente (es decir, el opuesto de *'regular'* es *'regular'*).

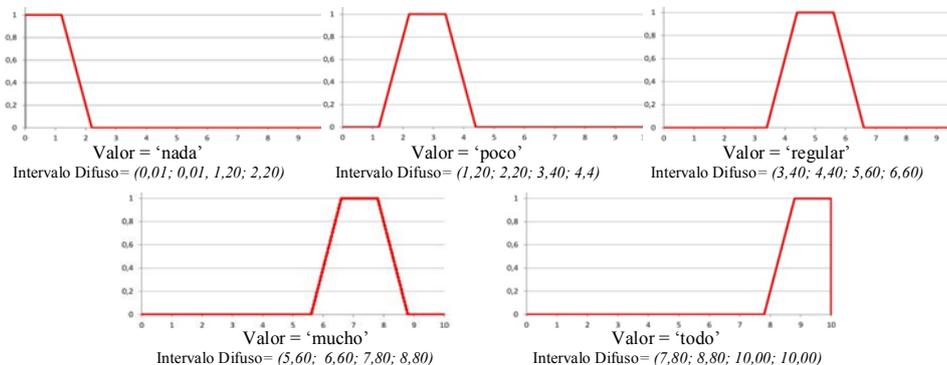


Fig. 1. Representación de los Intervalos Difusos para los Valores Lingüísticos.

Paso 3: Calcular la valoración de cada arquitectura

Una vez obtenidos los intervalos difusos para cada característica y arquitectura en el paso anterior, los mismos son utilizados para calcular la valoración de cada arquitectura teniendo en cuenta el valor del peso correspondiente (los cuales han sido indicados en la Tabla 1). Esto se realiza aplicando la fórmula #1 de la Tabla 2. Esta fórmula está compuesta por la combinación de la media armónica y la media aritmética del conjunto de intervalos. De esta forma, se busca reducir la influencia de valores bajos en el cálculo de la dimensión. Como resultado se obtiene un intervalo que representa la adecuación de cada arquitectura (A_R). Dado que el resultado de dicha fórmula es

otro intervalo difuso, para convertirlo en un único valor numérico (V_T) se utiliza la media aritmética de los valores del intervalo, como se indica en la fórmula #2 de la Tabla 2.

Tabla 2. Fórmulas Utilizadas para Calcular la Valoración de cada Arquitectura.

#	Fórmula	
1	$A_R = \left(\frac{1}{2} \cdot \frac{\sum_{i=1}^{n_R} P_{R_i} }{\sum_{i=1}^{n_R} \left(\frac{ P_{R_i} }{C_{R_i}} \right)} \right) + \left(\frac{1}{2} \cdot \frac{\sum_{i=1}^{n_R} (P_{R_i} \cdot C_{R_i})}{\sum_{i=1}^{n_R} P_{R_i} } \right)$	Donde: A_R : representa el intervalo difuso de la adecuación para la arquitectura R (usando como nomenclatura 'RNA' para Redes Neuronales Artificiales y 'RB' para Redes Bayesianas). $ P_{R_i} $: representa el valor absoluto del peso de la característica i perteneciente a la arquitectura R. C_{R_i} : representa el intervalo difuso asignado a la característica i perteneciente a la arquitectura R. n_R : representa la cantidad de características asociadas a la arquitectura R.
2	$V_R = \frac{\sum_{j=1}^4 (I_R \{j\})}{4}$	Donde: V_R representa el valor numérico calculado para la arquitectura R. $I_R \{j\}$: representa el valor correspondiente a la posición j del intervalo difuso calculado para la arquitectura R.

Paso 4: Interpretar los resultados obtenidos

Una vez obtenidos los valores correspondientes a cada arquitectura en el paso 3, éstos deben ser analizados e interpretados. Para ello, se recomienda graficar los intervalos correspondientes a cada arquitectura, utilizando la función de pertenencia correspondiente a su intervalo difuso (A_R). Se considera que, una dimensión está aceptada si el gráfico obtenido supera al intervalo del valor 'regular' (indicado en la Figura 1). En forma análoga, esto se puede determinar si se utiliza el valor numérico asociado a la arquitectura: una arquitectura será aceptable si su valor V_R es mayor a 5.

Paso 5: Seleccionar la mejor arquitectura

Finalmente, teniendo en cuenta la interpretación de los resultados obtenidos (paso 4), se procede a seleccionar la mejor tecnología para el proyecto aplicando el criterio definido en la tabla de decisión de la Tabla 3.

Tabla 3. Tabla de Decisión para Seleccionar la Mejor Arquitectura.

Selección de la Mejor Arquitectura		Valor numérico asociado a Redes Neuronales Artificiales (V_{RNA})			
		aceptable ($V_{RNA} > 5$)		no aceptable ($V_{RNA} \leq 5$)	
Valor numérico asociado a Redes Bayesianas (V_{RB})	aceptable ($V_{RB} > 5$)	$ V_{RNA} - V_{RB} < 0,25$	$ V_{RNA} - V_{RB} \geq 0,25$		selecciona RB
			$V_{RNA} > V_{RB}$	$V_{RNA} < V_{RB}$	
	selecciona AMBAS	selecciona RNA	selecciona RB		
	no aceptable ($V_{RB} \leq 5$)	selecciona RNA		selecciona NINGUNA	

Como se puede notar en la Tabla 3, se puede decidir que se seleccione:

- o a una de las arquitecturas, Redes Neuronales Artificiales (RNA) ó Redes Bayesianas (RB), si esa arquitectura tiene un valor de adecuación aceptable y es muy superior al de la otra arquitectura (con una diferencia absoluta mayor o igual a 0,25);
- o ambas arquitecturas, si ambos valores de adecuación son aceptables con una diferencia absoluta menor a 0,25 por lo que se consideran como equivalentes y cualquiera de las dos se podría utilizar para implementar el modelo; o

- *ninguna de las arquitecturas*, si ninguno de los valores de adecuación es aceptable, lo cual significa que se debería utilizar otro tipo de arquitectura.

4. Pruebas de Concepto

En esta sección, se presentan dos pruebas de concepto para ilustrar el funcionamiento del proceso propuesto. Se utiliza una prueba de concepto en la que se selecciona a una Red Neuronal Artificial (RNA) como mejor alternativa y, otra en la que se selecciona a una Red Bayesiana (RB). Todos los cálculos necesarios fueron realizados mediante la planilla creada ad-hoc [35] que implementa los pasos definidos anteriormente para cada una de las pruebas de concepto (los cuales están disponibles en [36]).

Como primera prueba de concepto se evalúa el caso presentado en [30], el cual tiene como objetivo realizar el pronóstico de las ventas de una empresa dedicada a la comercialización de productos alimenticios. Para llevar a cabo la evaluación, se aplica el proceso propuesto en la sección 3. A partir de la información indicada en la publicación se responden las preguntas requeridas con el valor lingüístico correspondiente (paso 1), tal como se muestran en la Tabla 4. Luego, los valores lingüísticos son convertidos en intervalos difusos (paso 2) y se calcula el intervalo de cada arquitectura (paso 3), la cual se representa en forma gráfica, como se muestra en la Tabla 5. A partir de esos intervalos, se calcula el valor numérico de cada arquitectura y se interpreta (paso 4). En este caso, se obtiene 7,94 para Redes Neuronales Artificiales, lo cual es superior a 5, por lo que se considera como aceptable. En cambio, para las Redes Bayesianas corresponde 4,83 que, aunque cercano, es inferior a 5 por lo que no es aceptable. Por consiguiente, se recomienda aplicar a las Redes Neuronales Artificiales como la arquitectura más apropiada, lo cual es consistente con las conclusiones de la publicación donde se indica que dicha tecnología es la que mejores resultados ha generado.

Tabla 4. Asignación de las Características de la Primera Prueba de Concepto.

Categoría	ID	Respuesta	Valor Asig.
Datos Disponibles	D1	Los datos se corresponden a históricos de la empresa para los años 2010 a 2013, por lo que se consideran totalmente representativos del problema a predecir.	todo
	D2	Según se indica, todos los datos disponibles para realizar el pronóstico de ventas presentan un comportamiento no lineal.	todo
	D3	Aunque la cantidad de ejemplos disponible no es muy grande (uno por cada mes de los cuatro años considerados, es decir, 48 registros en total) se consideran suficientes para el problema a resolver.	regular
	D4	Dado que se utiliza el monto total de ventas para cada mes, la mayoría los atributos tienen valores continuos.	mucho
Resultados Esperados	R1	Dado que el objetivo es comparar la precisión de una RNA para pronosticar la cantidad de ventas, se considera como totalmente crítica.	todo
	R2	No se ha solicitado poder realizar una comparación de diferentes situaciones o escenarios.	nada
	R3	No se ha solicitado que se expliquen los resultados generados por el modelo.	nada
Dominio del Problema	P1	El problema se considera muy estable para poder ser resuelto.	mucho
	P2	No se cuenta con expertos disponibles para solicitar información sobre los datos o el problema.	nada
	P3	No se ha solicitado ajustar manualmente la red a partir de los conocimientos sobre los datos.	nada

Tabla 5. Cálculo de Intervalos para las Arquitecturas de la Primera Prueba de Concepto.

Arq.	Intervalo de la Arquitectura (A_R)	Representación de la Función de Pertenencia de A_R
A_{RNA}	(6,41; 7,47; 8,71; 9,15) Intervalo sobrepasa al intervalo de 'regular' y por una pequeña diferencia al de 'mucho'.	
A_{RB}	(2,75; 3,82; 5,33; 7,43) Intervalo no sobrepasa al intervalo de 'regular' pero supera por una pequeña diferencia al de 'poco'.	

Para llevar a cabo el análisis de la segunda prueba de concepto se aplica el proceso para evaluar el caso presentado en [25]. En dicho trabajo, se combinan los conocimientos de expertos del dominio con los datos de cuestionarios realizados a pacientes para la construcción de una Red Bayesiana que permita asistir la toma de decisiones médicas. Nuevamente, a partir de la información indicada en la publicación se respondieron las preguntas requeridas como se muestra en la Tabla 6. Con estos valores, se vuelve a aplicar el resto de los pasos del proceso obteniéndose los resultados que se muestran en la Tabla 7.

Tabla 6. Asignación de las Características de la Segunda Prueba de Concepto.

Categoría	ID	Respuesta	Valor Asig.
Datos Disponibles	D1	Dado que los datos fueron obtenidos de cuestionarios a pacientes, no se consideran muy confiables pero sí lo suficientes para ser utilizados como base.	regular
	D2	Por su naturaleza, los datos a ser utilizados son muy complejos con una relación muy variable.	todo
	D3	Se cuenta con muchos datos obtenidos provenientes varios cuestionarios (la cantidad de variables es mayor a 900 atributos)	todo
	D4	Las respuestas a las preguntas de los cuestionarios son valores alfanuméricos (sí/no o uno de una lista de valores), por lo que no se cuenta con valores continuos.	nada
Resultados Esperados	R1	Aunque se considera importante tener una buena precisión en los resultados generados, la misma no se considera crítica.	regular
	R2	Se considera de interés poder comparar resultados para diferentes escenarios.	mucho
	R3	También es muy deseable que se justifiquen los resultados generados a partir de los resultados parciales generados por el modelo.	mucho
Dominio del Problema	P1	Dado que las preguntas tienen que ver con estudios realizados desde hace mucho tiempo, el problema se considera muy estable.	mucho
	P2	Se cuenta con varios expertos cooperativos para asistir en el desarrollo.	todo
	P3	Dado el objetivo de la publicación, se va a utilizar los conocimientos de los expertos disponibles para ajustar la red generada.	todo

Tabla 7. Cálculo de Intervalos para las Arquitecturas de la Segunda Prueba de Concepto.

Arq.	Intervalo de la Arquitectura (A_R)	Representación de la Función de Pertenencia de A_R
A_{RNA}	(3,65; 4,08; 5,00; 5,21) Intervalo no sobrepasa al intervalo de 'regular' pero supera por una pequeña diferencia al de 'poco'.	
A_{RB}	(6,18; 7,22; 8,45; 9,03) Intervalo sobrepasa al intervalo de 'regular' y por una pequeña diferencia al de 'mucho'.	

Finalmente, se calculan e interpretan los valores numéricos de cada arquitectura. En este caso, se obtiene 4,49 para Redes Neuronales Artificiales y 7,72 para Redes Bayesianas, por lo que la primera se considera como no aceptable pero la segunda sí lo es. Por consiguiente, y con una diferencia significativa, la tecnología recomendada como la más apropiada para este proyecto son las Redes Bayesianas, lo cual es también consistente con las conclusiones de la publicación analizada.

5. Conclusiones

Este trabajo presenta la propuesta de un proceso para la selección de la arquitectura más adecuada con el fin de construir un Modelo Predictivo Inteligente, dada que la dificultad asociada a la construcción de este tipo de modelos tiene que ver con determinar el tipo de arquitectura a aplicar, de acuerdo a las características del proyecto.

El proceso propuesto permite evaluar la adecuación de cada característica del proyecto, aplicando información difusa y de esta manera, determinar cuál se considera más recomendable a aplicar. Para facilitar su utilización, también se han implementado todos sus pasos en la planilla [35], la cual ha sido utilizada para validar exitosamente el proceso con dos pruebas de concepto, una para RNA y otra para RB.

Queda como futura línea de trabajo extender el proceso para que pueda evaluar la adecuación de otras tecnologías. Para ello, solo se necesitan definir los nuevos valores de los pesos correspondientes. Si fuera necesario también incorporar nuevas características, ello se puede realizar sin tener que modificar las fórmulas ni los pasos del proceso. Sólo se debe agregar la característica asignando un peso de cero para las arquitecturas actuales (de forma que no se modifique el comportamiento actual) y asignando los pesos correspondientes para la nueva arquitectura.

Referencias

1. Robbins, S. & Coulter, M. (2010). *Administración. Décima Edición*. Prentice Hall. ISBN: 978-607-442-388-4.
2. Mair, C., Kadoda, G., Lefley, M., Phalp, K., Schofield, C., Shepperd, M. & Webster, S. (2000). *An investigation of machine learning based prediction systems*. Journal of Systems and Software, 53(1), 23-29.
3. García Martínez, R., Servente, M. & Pasquini, D. (2003). *Sistemas Inteligentes*. Editorial Nueva Librería. Buenos Aires. ISBN 987-1104-05-7.
4. Nilsson, N. J. (2014). *Principles of Artificial Intelligence*. Morgan Kaufmann.
5. Russell, S. J., Norvig, P., Davis, E., Russell, S. J. & Russell, S. J. (2010). *Artificial Intelligence: a modern approach* (Vol. 2). Englewood Cliffs: Prentice Hall.
6. Shepperd, M. & Kadoda, G. (2001). *Comparing software prediction techniques using simulation*. IEEE Transactions on Software Engineering, 27(11), 1014-1022.
7. Bontempi, G., Taieb, S. B. & Le Borgne, Y. A. (2013). *Machine learning strategies for time series forecasting*. In Business Intelligence (pp. 62-77). Springer Berlin Heidelberg.
8. Alpaydin, E. (2014) *Introduction to machine learning*. MIT press.
9. Benítez, J. M., Castro, J. L. & Requena, I. (1997). *Are artificial neural networks black boxes?*. IEEE Transactions on neural networks, 8(5), 1156-1164.
10. Mitchell, T.M. (1997) *Machine Learning*. McGraw-Hill, New York.
11. Wang, S. C. (2003). *Artificial Neural Network*. In Interdisciplinary Computing in Java Programming (pp. 81-100). Springer US.

12. Wang, L. & Fu, K. (2009). *Artificial Neural Networks*. Wiley Encyclopedia of Computer Science and Engineering. 181–188.
13. Barber, D. (2012). *Bayesian Reasoning and Machine Learning*. The MIT Press.
14. Premchaiswadi, W. (2012) *Bayesian Networks*. Ed. In-Tech.
15. Chatfield, C. (2016). *The analysis of time series: an introduction*. CRC press.
16. De Gooijer, J. G. & Hyndman, R. J. (2006). *25 years of time series forecasting*. International journal of forecasting, 22(3), 443-473.
17. Zhang, G. & Hu, M.Y. (1998). *Neural network forecasting of the British pound/US dollar exchange rate*. Omega, International Journal of Management Science, 26 (4) 495–506.
18. Zhang, G., Patuwo, B. E. & Hu, M. Y. (1998). *Forecasting with artificial neural networks: The state of the art*. International journal of forecasting, 14(1), 35-62.
19. Cohen, P. R. & Feigenbaum, E. A (2014). *The handbook of Artificial Intelligence*. Vol. 3. Butterworth-Heinemann.
20. Wolpert, D. H. (1996). *The lack of a priori distinctions between learning algorithms*. Neural computation, 8(7), 1341-1390.
21. Wolpert, D. H. & Macready, W. G. (1997). *No free lunch theorems for optimization*. IEEE transactions on evolutionary computation, 1(1), 67-82.
22. Domingos, P. (2012). *A few useful things to know about machine learning*. Communications of the ACM, 55(10), 78-87.
23. Adya, M. & Collopy, F. (1998). *How effective are neural networks at forecasting and prediction? A review and evaluation*. J. Forecasting, 17, 481-495.
24. Bontempi, G., Taieb, S. B. & Le Borgne, Y. A. (2013). *Machine learning strategies for time series forecasting*. In Business Intelligence (pp. 62-77). Springer Berlin Heidelberg.
25. Constantinou, A. C., Fenton, N., Marsh, W. & Radlinski, L. (2016). *From complex questionnaire and interviewing data to intelligent Bayesian network models for medical decision support*. Artificial intelligence in medicine, 67, 75-93.
26. Chen, S. H. & Pollino, C. A. (2012). *Good practice in Bayesian network modelling*. Environmental Modelling & Software, 37, 134-145.
27. Masegosa, A. R. & Moral, S. (2013). *An interactive approach for Bayesian network learning using domain/expert knowledge*. International Journal of Approximate Reasoning, 54(8), 1168-1181.
28. Mendes, E. (2011). *Knowledge representation using Bayesian networks - A case study in Web effort estimation*. In Information and Communication Technologies (WICT), 2011 World Congress on (pp. 612-617). IEEE.
29. Pitchforth, J. & Mengersen, K. (2013). *A proposed validation framework for expert elicited Bayesian Networks*. Expert Systems with Applications, 40(1), 162-167.
30. Ruelas-Santoyo, E. A. & Laguna-González, J. A. (2014) *Comparación de predicción basada en redes neuronales contra métodos estadísticos en pronósticos de ventas*. Ingeniería Industrial. Actualidad y Nuevas Tendencias, IV (Enero-Junio). ISSN 1856-8327.
31. Trujillano, J., March, J. & Sorribas, A. (2004). *Aproximación metodológica al uso de redes neuronales artificiales para la predicción de resultados en medicina*. Med Clin (Barc), 122(s1).
32. Woodberry, O., Nicholson, A. E., Korb, K. B. & Pollino, C. (2004). *Parameterising bayesian networks*. In Australasian Joint Conference on Artificial Intelligence (pp. 1101-1107). Springer Berlin Heidelberg.
33. Zhou, Y., Fenton, N. & Neil, M. (2014). *Bayesian network approach to multinomial parameter learning using data and expert judgments*. International Journal of Approximate Reasoning, 55(5), 1252-1268.
34. Jang, J.S.R. 1997. *Fuzzy inference systems*. Upper Saddle River, NJ: Prentice-Hall.
35. Vegega, C., Pytel, P. & Pollo-Cattaneo, M.F. (2018a). *Implementación del Método Evaluador de las Tecnologías*. Disponible en: <https://tinyurl.com/MetEvTecnol>
36. Vegega, C., Pytel, P. & Pollo-Cattaneo, M.F. (2018b). *Aplicación del Método Evaluador de las Tecnologías para las Pruebas de Concepto*. Disponible en: <https://tinyurl.com/pruebasConcMetEvTecnol>