

Aplicación del algoritmo Backpropagation de redes neuronales para determinar los niveles de morosidad en los alumnos de la Universidad Peruana Unión

Daniel Cornejo Ruiz, Giancarlo Quispe Gavino

Facultad de Ingeniería de sistemas, Universidad Peruana Unión, Ñaña, Perú.

Resumen

Este estudio tiene por objetivo, la construcción de un modelo de redes neuronales backpropagation para determinar los niveles de morosidad en los alumnos de la Universidad Peruana Unión (UPeU). El trabajo permitió realizar una clasificación de los alumnos, según su nivel de morosidad.

Para ello se usó dos tipos de herramientas de software: SQL Analysis Services 2008 y el SPSS 15.0, para la construcción del modelo y su respectiva validación. La metodología para este trabajo fue el CRISP-DM, es una de las metodologías más usadas en proyecto de minería de datos.

La construcción de las redes neuronales backpropagation nos ha permitido distinguir las variables que intervienen en la morosidad; y así pronosticar el nivel de morosidad del alumno de la UPeU.

Classification Tree Model for Identifying Student Profile according to Credit Risk in Universidad Peruana Union.

Abstract

This study aims, the construction of a backpropagation neural network model to determine the levels of delinquency in students of the Universidad Peruana Union (UPeU). The work allowed classification of students based on their level of delinquency.

This will use two types of software tools: SQL Analysis Services 2008 and SPSS 15.0, for the construction of the respective model and its validation. The methodology for this work was the CRISP-DM, is one of the methodologies used in data mining project.

The construction of backpropagation neural networks has allowed us to distinguish the variables involved in delinquency, and so predict the default rate of UPeU student.

1. Introducción

Las entidades financieras que otorgan créditos, tienen las siguientes características: Rango de ingresos, rango de egresos, destino del crédito, Las garantías o avales, si es cliente de la entidad financiera y la zona de

residencia. Según Orlando Sanhueza Puelles (Enero, 2011).

Las entidades del sistema financiero (bancos,

cajas municipales, rurales, edpymes y cooperativas) elaboran un cuestionario de crédito o 'scoring credit', mediante el cual un usuario pide un crédito donde obtiene una calificación.

El área de finanzas de la Universidad Peruana Unión; la asignación de crédito, es realizada por los analistas financieros, haciendo uso de su propia experiencia. Es por eso que se necesita contar con una herramienta que ayude clasificar a los alumnos según su nivel de morosidad, para luego poder analizar la asignación del crédito.

Para cumplir con el objetivo planteado, se debe seguir una metodología de minería de datos, desglosada en seis fases. En la primera fase de comprensión del negocio se comprende los objetivos y requisitos del proyecto desde una perspectiva empresarial. En la siguiente fase se comprenden los datos. Luego en la fase de preparación de los datos se seleccionan los datos que van a intervenir en la creación del modelo de redes neuronales backpropagation. En la fase de modelado se lleva a cabo la creación del modelo de redes neuronales, por tanto en la fase de evaluación se evalúa el modelo teniendo en cuenta el cumplimiento de los criterios de éxito del problema, finalmente en la última fase de implementación se implementa el modelo.

Con esta investigación, el área de finanzas de la universidad Peruana Unión podrá identificar y clasificar a los alumnos según su nivel de morosidad, y de esta manera poder tomar decisiones para otorgar beneficios al alumno. Así como tener un control eficiente sobre el riesgo al otorgar un crédito a los alumnos. correcta.

El presente trabajo tiene como objetivo general el desarrollo de un modelo de árboles de clasificación que sirva para la identificación del perfil de alumnos según el riesgo crediticio que éste pueda tener.

2. Construcción de la red neuronal Inspiración, Principio y Entrenamiento

2.1 Inspiración de la Red Neuronal Artificial.

Las Redes Neuronales surgen como un intento de desarrollar sistemas que compitan con las características del cerebro, para conseguir su sofisticada capacidad de procesamiento de información.

Las células llamadas neuronas son una unidad de procesamiento que recibe un estímulo eléctrico de otras neuronas principalmente a través de su árbol dendrítico.

El estímulo eléctrico recibido al pasar de un cierto umbral causa que la neurona a su vez imprima

una señal eléctrica a través de su axón a otras neuronas.

En la figura 1 se observa los impulsos eléctricos de la neurona Biológica. Desde el punto de vista funcional, las neuronas constituyen procesadores de información sencillos. Posee un canal de




Figura 1: Modelo biológico de una neurona

entrada de información (las dendritas), un órgano de cómputo (el soma), y un canal de salida (el axón).

2.2 Principio de la red neuronal Backpropagation.

La BackPropagation es un tipo de red de aprendizaje supervisado, que emplea un ciclo de propagación – adaptación de dos fases. Una vez que se ha aplicado un patrón a la entrada de la red como estímulo, este se propaga desde la primera capa a través de las capas superiores de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas.

Las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta que contribuyen directamente a la salida. Sin embargo las neuronas de la capa oculta solo reciben una fracción de la señal total del error basándose aproximadamente en la contribución relativa que haya aportado cada neurona a la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución

relativa al error total. Basándose en la señal de error percibida, donde se actualizan los pesos de conexión de cada neurona, para hacer que la red converja hacia un estado que permita clasificar correctamente todos los patrones de entrenamiento. (García Martínez, Servente, & Pasquín, 2003)

La importancia de este proceso consiste en su capacidad de auto adaptar los pesos de las neuronas intermedias para aprender la relación que existe entre un conjunto de patrones dados como ejemplo y sus salidas correspondientes. Después del entrenamiento, cuando se les presente un patrón arbitrario de entrada que contenga ruido o que esté incompleto, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas individuales hayan aprendido a reconocer durante su entrenamiento. Y a la inversa, las unidades de las capas ocultas tienen una tendencia a inhibir su salida si el patrón de entrada no contiene la característica para reconocer, para la cual han sido entrenadas.

Varias investigaciones han demostrado que, durante el proceso de entrenamiento, la red Back Propagation tiende a desarrollar relaciones internas entre neuronas con el fin de organizar los datos de entrenamiento en clases. Esta tendencia se puede extrapolar, para llegar a la hipótesis consistente en que todas las unidades de la capa oculta de una Back Propagation son asociadas de alguna manera a características específicas del patrón de entrada como consecuencia del entrenamiento. Lo que sea o no exactamente la asociación puede no resultar evidente para el observador humano, lo importante es que la red ha encontrado una representación interna que le permite generar las salidas deseadas cuando se le dan las entradas, en el proceso de entrenamiento. Esta misma representación interna se puede aplicar a entradas que la red no haya visto antes, y la red clasificará estas entradas según las características que compartan con los ejemplos de entrenamiento según podemos ver en la figura 2.

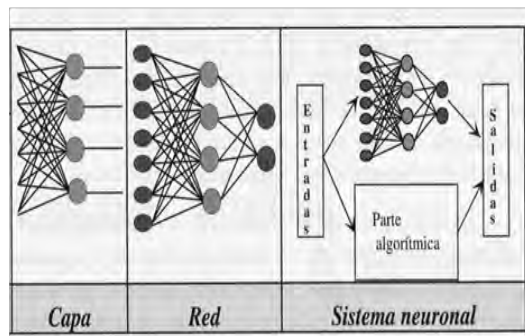


Figura 2: Modelo de Red Neuronal

2.3 Algoritmo de entrenamiento de la red.

Se denomina aprendizaje o entrenamiento de la red al ajuste de los pesos sinápticos, que determina el grado de conexión entre las neuronas de la red.

El proceso de aprendizaje es el proceso por el cual la red neuronal se adapta al estímulo modificando sus pesos y eventualmente produce un resultado esperado.

- Hay dos tipos de aprendizaje:

Supervisado

Sin supervisión

- Aprendizaje supervisado incluye un supervisor que le indica a la red cuán cerca está de aprender y va modificando los pesos neuronales.
- Sin supervisión solamente se forman grupos de clasificación de acuerdo a indicaciones o propiedades, no se calcula un error (E).

3. Construcción del modelo de redes neuronales con la metodología CRISP-DM (Cross Industry Standard Process for Data Mining).

La metodología CRISP-DM (Chapman, 2000) se encuentra definida en base a un modelo jerárquico de procesos.

Esta metodología define un ciclo de vida de los proyectos de explotación de información que distingue las principales fases de un proyecto de este tipo, junto con las relaciones entre las

mismas, como puede ser visto en la figura3, estas relaciones son las más comunes aunque pueden establecerse relaciones entre cualquiera de las fases.




Figura 3: Fases del modelo de referencia CRISP-DM. Extraído de [Chapman, 2000]

3.1 Fase de comprensión del problema

En esta fase se realizaron reuniones con la parte administrativa de finanzas, para poder entender el problema que presenta dicha área. Uno de los problemas encontrados fue la falta de clasificación de los alumnos según su morosidad. El poder clasificarlos ayudaría a tomar medidas respectivas respecto a cada nivel de morosidad.

Luego de identificar el problema, se realizaron reuniones semanales para determinar las variables de mayor influencia para el análisis de los datos.

3.2 Fase de comprensión de los datos

Se realizó un análisis de la importancia de los datos, se busco información sobre análisis de morosidad y finalmente se confeccionó una encuesta y se recogió la data entre los alumnos de la UPeU, la cual podemos encontrar en el anexo 1.

Para el recojo de esta información se entregó la encuesta a 220 alumnos del total de alumnos de la UPeU.

3.3 Fase de preparación de los datos

Una vez recogidas todas las encuestas se procedió a pasar todos los datos a un documento de Microsoft Excel para su posterior análisis con otras herramientas software.

Durante el proceso, se tuvo que seleccionar las encuestas mal realizadas para poder desecharlas, quedándonos finalmente con 200 encuestas.

Posteriormente las encuestas se dividieron de la siguiente manera: 140 encuestas para el entrenamiento de la red (70%) y 60 encuestas para el proceso de prueba (30%).

Las preguntas de la encuesta, apuntaron hacia la obtención de información básicamente de dos tipos, cualitativa y cuantitativa.

Todas las variables que se hallan medidas en intervalos, fueron llevadas a un número equivalente al valor promedio de cada intervalo.

Las variables modificadas fueron normalizadas (convertidas a un número proporcional, entre cero y uno), para facilitar la comprensión de datos de la red. Este procedimiento se produjo dividiendo cada uno de los valores que tiene cada variable en particular, por el mayor número de dicha variable. Con esto, se persigue homogeneizar las variables de la muestra.

3.4 Fase de modelado

Esta es una de las fases más importantes, pues es donde se centra el trabajo: es decir la construcción del modelo.

Para realizar el modelo se uso la herramienta Analysis Services de Microsoft SQL Server 2008. Los pasos para la construcción del modelo de redes neuronales se realizaron de la siguiente manera:

Importación de los datos al SQL Management Studio.

- * Creación del origen de datos.

- * Creación de una vista.

- * Creación de la estructura de minería de datos, utilizando el algoritmo de redes neuronales. (Microsoft SQL Server 2008 utiliza el algoritmo de backpropagation

para su análisis con redes neuronales).

En la figura 4 podemos visualizar según el modelo de red neuronal, el proceso que tienen los datos en esta red.

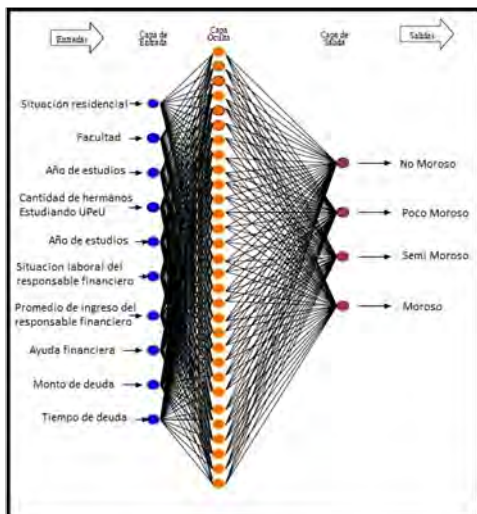


Figura 4: Modelo de red neuronal Backpropagation

3.5 Fase de evaluación

Se evalúa el modelo, teniendo en cuenta el cumplimiento de los criterios de éxito del problema. Debe considerarse además, que la fiabilidad calculada para el modelo, se aplica solamente para los datos sobre los que se realizó el análisis. Es preciso revisar el proceso, teniendo en cuenta los resultados obtenidos, para poder repetir algún paso anterior, en el que se haya posiblemente cometido algún error.

3.6 Fase de implantación

Para implementar los resultados del Proceso de Explotación de Datos en el Negocio, se debe analizar el resultado de la evaluación y generar una estrategia de implementación.

Pero generalmente un proyecto de Data Mining no concluye en la implantación del modelo, pues se deben documentar y presentar los resultados

de manera comprensible para el usuario, con el objetivo de lograr un incremento del conocimiento.

4. Análisis e interpretación de los resultados:

4.1 Estructura de minería de datos

En la pestaña que nos muestra el software podemos tener una vista preliminar de las variables que fueron utilizadas en el origen de datos, que fueron consideradas al momento de recolectar la información para realizar el análisis en los niveles de morosidad de los alumnos de la Universidad Peruana Unión.

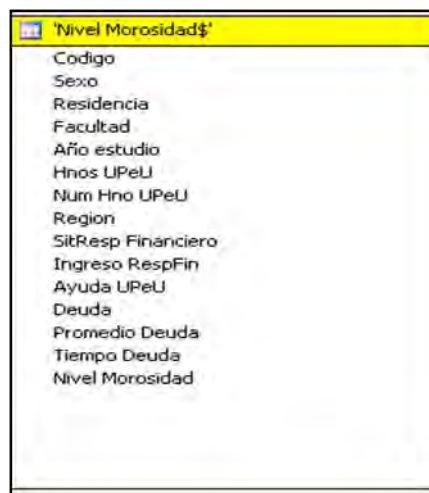


Figura 5: Vista del origen de datos

4.2 Modelo de minería de datos

En esta sección que presentamos a continuación, mostramos una lista con las variables que toman relevancia en la clasificación de los niveles de morosidad que hemos considerado como: No moroso, poco moroso, semi moroso y moroso; teniendo la oportunidad de reconsiderar alguna u otra variable que sea necesaria para el estudio.

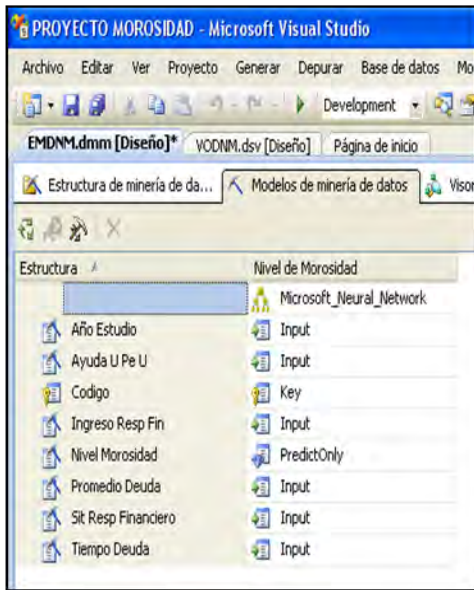


Figura 6: Vista del origen de datos

4.3 Muestra poblacional general

Se ha tomado en consideración todos los valores de predicción que están siendo analizados (no moroso, poco moroso, semi moroso, moroso), donde la gráfica nos dice que el modelo del nivel de morosidad se ajusta perfectamente a lo largo de la comparación según se observa en la figura 7.



Figura 7: Gráfico de elevación de minería de datos con la población general

Con una probabilidad de predicción del 99.03%. Como lo visualizamos en la Figura 8.

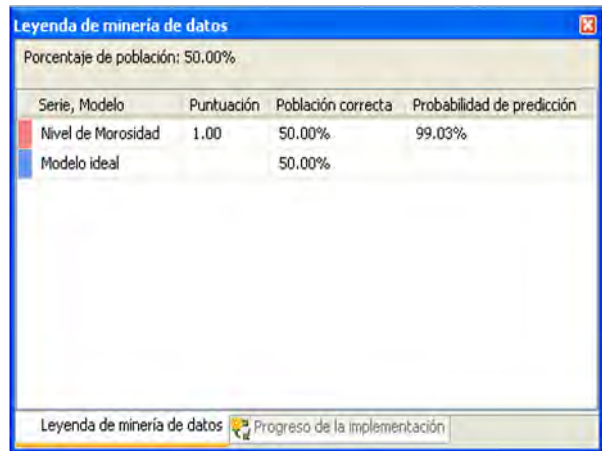


Figura 8: Leyenda de población de minería de datos

4.4 Muestra poblacional No Moroso

Se ha tomado en consideración la muestra poblacional de no morosos como valor de predicción, donde la gráfica nos dice que el modelo del nivel de morosidad se ajusta perfectamente tomando como referencia a un 50% de la población general encontrando el 90.91% de No morosos como se ve en la figura 9.



Figura 9: Gráfico de elevación de minería de datos con la población No Morosa

Ajustándose al modelo ideal del 90.91% con una probabilidad de predicción del 99.03%. Como lo visualizamos en la Figura 10.

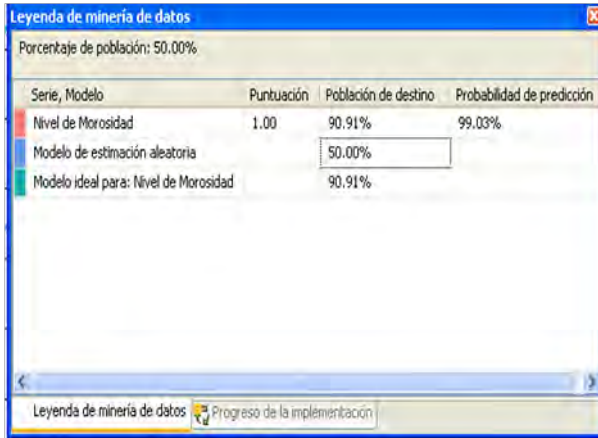


Figura 10: Leyenda de población No Morosa de minería de datos

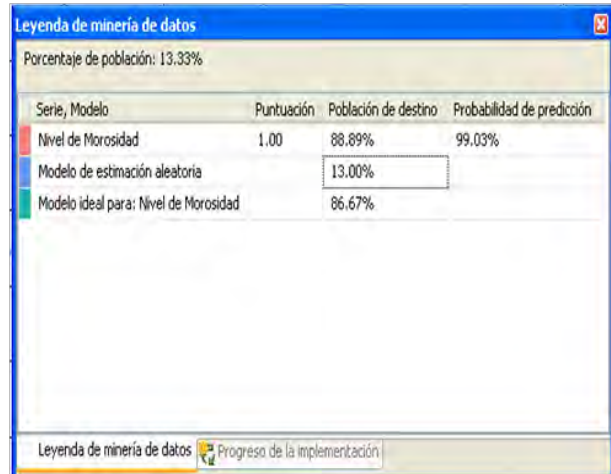


Figura 12: Leyenda de población Poco Morosa de minería de datos

4.5 Muestra poblacional Poco Moroso

Se ha tomado en consideración la muestra poblacional de poco morosos como valor de predicción, donde la gráfica nos dice que el modelo del nivel de morosidad se ajusta perfectamente tomando como referencia a un 13% de la población general encontrando el 88.89% según la figura 11.



Figura 11: Gráfico de elevación de minería de datos con la población Poco Morosa

Ajustándose al modelo ideal del 86.67% con una probabilidad de predicción del 99.03%. Según la Figura 12.

4.6 Muestra poblacional Semi Moroso

Se ha tomado en consideración la muestra poblacional de poco morosos como valor de predicción, donde la gráfica nos dice que el modelo del nivel de morosidad se ajusta perfectamente tomando como referencia a un 13% de la población general encontrando el 88.89% según figura 13.

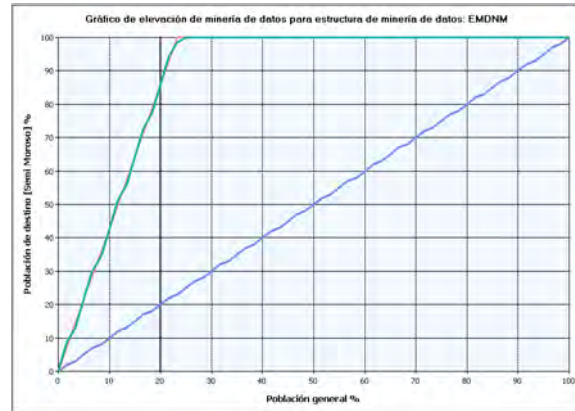


Figura 13: Gráfico de elevación de minería de datos con la población Semi Morosa

Ajustándose al modelo ideal del 86.67% con una probabilidad de predicción del 99.03%. Como lo visualizamos en la Figura 14.

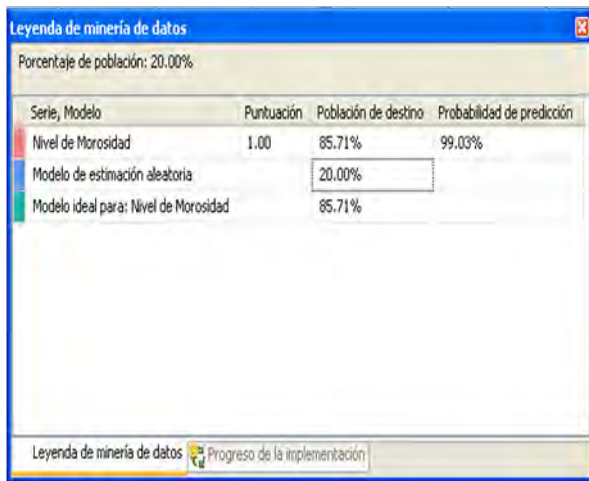
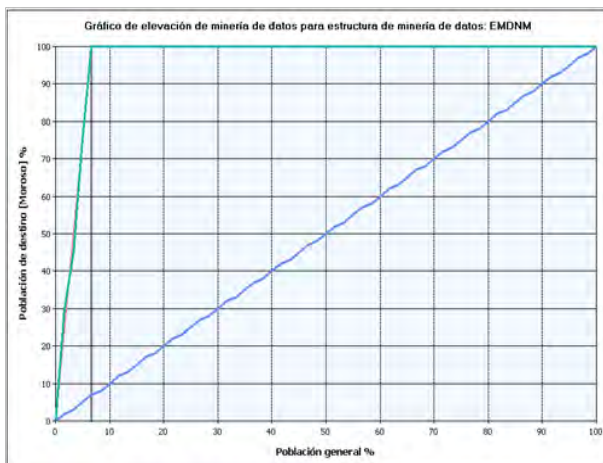


Figura 14: Leyenda de población Semi Morosa de minería de datos

4.7 Muestra poblacional Moroso

Se ha tomado en consideración la muestra poblacional de Moroso como valor de predicción, donde la gráfica nos dice que el modelo del nivel de morosidad se ajusta perfectamente tomando como referencia a un 7% de la población general



encontrando el 100.00% como se ve en la figura 15.

Figura 15: Gráfico de elevación de minería de datos con la población Morosa

Ajustándose al modelo ideal del 100.00% con una probabilidad de predicción del 99.01%. Como lo visualizamos en la Figura 16.

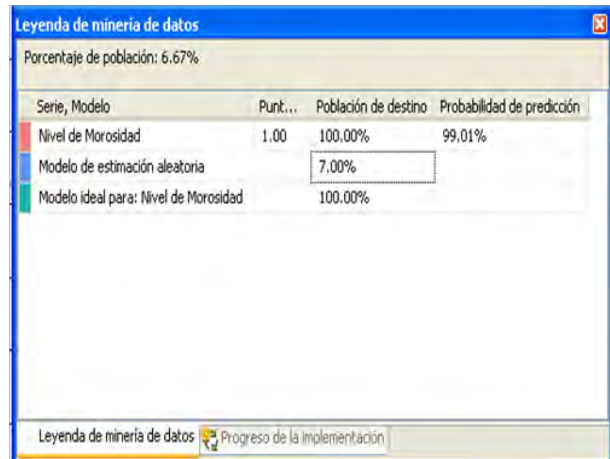


Figura 16: Leyenda de población Morosa de minería de datos

5. Predicción del modelo de minería de datos

En esta sección del análisis presentamos un recuento de los números de casos que han sido evaluados tomando un 30% para las pruebas y quedándonos con un 70% para el entrenamiento de la red como lo podemos observar en la figura 17.

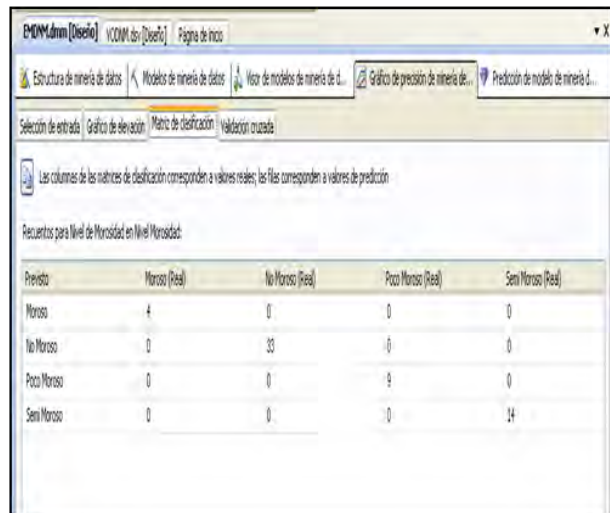


Figura 17: Matriz del recuento para el nivel de morosidad

En esta sección de análisis es en donde tenemos que especificar las entradas para que en SQL Server internamente los evalúe mediante algoritmos de retro propagación para poder estimar un nivel de acuerdo a las entradas especificadas como se muestra en la figura 18.

6. Conclusiones

Se logró construir un modelo de red neuronal Backpropagation, el cual nos permitió identificar los niveles de morosidad de los alumnos de la Universidad Peruana Unión. Las pruebas realizadas con la data recolectada se lograron satisfactoriamente.

Mediante los datos recolectados y utilizando el modelo de red neuronal Backpropagation se ha conseguido detectar las variables que más influyen sobre los niveles de morosidad del alumno de la Universidad Peruana Unión. Estas variables son: Tiempo de la deuda, Monto de la deuda Ingreso de los responsables financieros, Situación del responsable financiero.

Después de haber realizado la recolección de los datos, siendo estos tratados y analizados llegamos a concluir que los niveles de morosidad que presentan los alumnos de la Universidad Peruana Unión son bajos resultados que se ven reflejados en los resultados estadísticos en donde arrojaron que: el nivel no moroso de la población representa un 56%, el nivel poco un 16.50%, luego tomando un poco más de peso, el nivel Semi moroso representado por un 23.50% y finalmente bajando en el nivel más alto refiriéndonos al nivel Moroso representado por un 4% de la población. Los resultados de la investigación se producen bajo el alero de un modelo de red neuronal bastante simple y muy aconsejable según el experto Juan Bekios, lo que hace creer en que el modelo es aconsejable para la clasificación de morosidad en empresas como la UPeU, empresas afines y/o empresas en general debido a que la morosidad se presenta en varios y distintos giros de negocios.

El modelo de la RNA Backpropagation que se construyó con la herramienta SQL Server se validó con la herramienta SPSS 15.0, la cual tuvo resultados semejantes en lo que se refiere a la relación de las variables independientes con la variable dependiente.

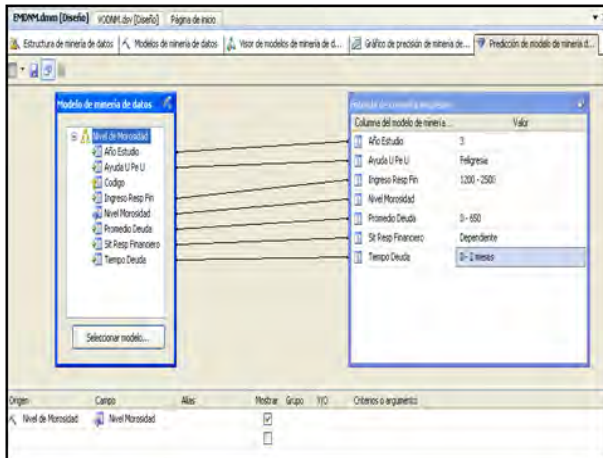


Figura 18: Modelo de minería de datos con entradas de consulta Singleton

En el resultado de la predicción según entradas, podemos visualizar el nivel de morosidad que la herramienta del SQL Server ha generado, dándole un valor de poco moroso, después del análisis de los datos de entradas que fueron proporcionados según se muestra en la figura 19.

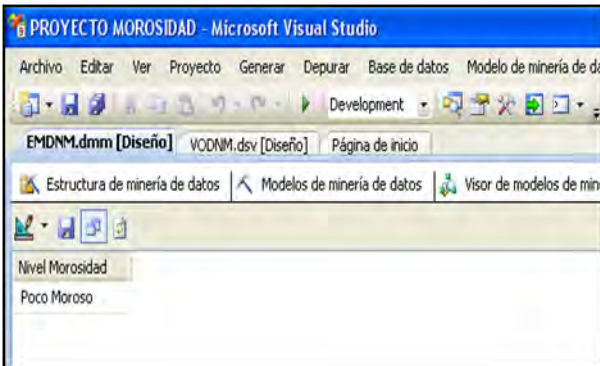


Figura 19. Resultado de predicción de la red neuronal Backpropagation

7. Recomendaciones

Se sugiere una serie de puntos de partida para línea de investigaciones futuras, las cuales son las siguientes:

Realizar modelos de RNA Backpropagation con distintas herramientas de minería de datos para poder hacer una validación y comparación de los distintos modelos que se pueda construir, de esta manera se puede hacer un mejor análisis y tomar el mejor modelo para el área de finanzas.

Se recomienda realizar un análisis de las posibles variables que intervendrían en el análisis de una investigación, establecer rangos si se necesita de acuerdo a la (as) variable (s) de análisis.

Se debe tener en cuenta para investigaciones futuras, que si los datos que serán analizados dependen de algún departamento o área, se recomienda tener una relación de compromiso y comunicación con esta para llevar a cabo la factibilidad del proyecto.

Se recomienda la encuesta como instrumento para la extracción de datos si es posible puesto que nos servirá de experiencia el poder observar cuán factible o fáciles de poder extraer la información de la población elegida y tomarlo en cuenta en investigaciones futuras.

Para la construcción del modelo se recomienda usar una mayor cantidad de datos, si es posible con los datos de todos los alumnos de la Universidad Peruana Unión en nuestro caso, en caso de otros giros de negocio la mayor cantidad de información de la empresa en donde se aplique. Mientras más sea la cantidad de alumnos (población) el modelo de Backpropagation más se ajustará a la realidad de la universidad o empresa.

Recordar siempre que un proyecto de Minería de Datos involucra, en general las siguientes fases:

* Comprensión del negocio y del problema que se quiere resolver.

* Determinación, obtención y limpieza de los datos necesarios.

* Ejecución de los modelos.

* Validación de los algoritmos.

* Comunicación de los resultados obtenidos.

Integración de los mismos, si procede.

AGRADECIMIENTO

Agradecer al equipo de trabajo, integrado por los alumnos del 5° año; por revisar y mejorar este artículo:

– Bartolo Estrella, Julia Alicia.

july_be5@hotmail.com

– Guillen López, Elmer.
guilop_061186@hotmail.com

– Roblero Pérez, Martha.
mroblero32@hotmail.com

– Sinforoso Chávez, Henry Renán.

henryking_333@hotmail.com.

De la Facultad de Ingeniería y Arquitectura, Escuela de Sistemas, Universidad Peruana Unión, Ñaña, Perú. Telf. 51 – 966795950.

Referencias:

[1]Altman, E.I.; Marco, G. y Varetto, F. (1994). Diagnostico de socorro Corporativo: comparación utilizando un análisis discriminante lineal y de redes neuronales (la experiencia italiana), Journal of Banking and Finance, vol. 18, pág. 505-529.

[2]Anderson, J. (2007). Redes Neuronales (Primera ed.). México: Alfa y Omega. ISBN: 978-970-15-1265-4

[3]Azevedo A. 2008. KDD, SEMMA AND CRISP-DM: A PARALLEL OVERVIEW. [Artículo en línea]. IADIS European Conference Data Mining 2008. 4 pp. ISBN: 978-972-89-24-63-8. [Consultado en 1 de octubre de 2010]. Formato pdf. Disponible en:

<http://www.iadis.net/dl/final_uploads/200812P033.pdf>.

[4]Bijit, J. (2008). Modelo de predicción de morosidad de la cartera de empresas de ENTEL S.A., usando Redes Neuronales. Santiago de Chile. Universidad de Chile. Escuela de Postgrado. pp. 40.

[5]Bonifacio Martín del Brío y Alfredo Sanz Molina. (2007). Redes Neuronales y sistemas Borrosos. 3ª Edición. ISSN: 1490-9345.

[6]Carpenter, G.A.; Grossberg. S.; Marzukon, N.; Reynolds, J.H. y Rossen, D.B. (1992). Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps", IEEE Transactions on Neural Networks, vol 3, pag 689-713.

[7]De Miguel, L.J.; Revilla, E.; Rodríguez, J.M. y Cano, J.M. (1993) "Una comparación entre métodos estadísticos y redes neuronales para la predicción de fracaso en bancos", Taller Internacional sobre Inteligencia Artificial en Economía y Gestión (USA).

[8]Deng, P.S. (1993). Automatic Knowledge Acquisition and Refinement for Decision Support: A Connectionist Inductive Inference Model, Decision Sciences, Vol 24, n. 2, pp 371-393

[9]Freeman, J. & Skapura, D. (1993). Redes neuronales: Algoritmos, aplicaciones y técnicas de programación. Primera Edición. Co publicación de Addison - Wesley Iberoamericana, S.A. y Ediciones Díaz de Santos, S.A. Wilmington, Delaware, USA. 431 pp.

[10]Gallardo J. (2009). Metodología para la Definición de Requisitos en Proyectos de Data Mining (ER-DM). [Tesis doctoral]. Asesor: Oscar Marbán Gallego. Departamento de Lenguajes y sistemas informáticos e ingeniería de software, Facultad de informática. 317 pp. [Consultado en 5 de octubre de 2010] Formato pdf. Disponible en: <http://oa.upm.es/1946/1/JOSE_ALBERTO_GALLARDO_ARANCIBIA.pdf>.

[11]García Martínez, R., Servente, M., & Pasquín, D. (2003). Sistemas Inteligentes,

Capítulo 1: "Aprendizaje automático", Capítulo 2: "redes Neuronales Artificiales". Buenos Aires, Argentina: Nueva Librería. ISBN: 987-1104-05-7

[12]Hilera Martínez, J. R. (2000). Redes Neuronales Artificiales, Fundamentos, Modelos y Aplicaciones. México: Alfa y Omega. ISBN: 9780201878950

[13]Isasi, P., & Galván, I. (2004). Redes Neuronales Artificiales Un Enfoque Práctico. España: Pearson Prentice Hall.

[14]Marose, R.A. (1990). A Financial Neural-Network Application, A. I. Expert, May 1990, pag 50-53 y publicado en Neural Networks in Finance and Investing. Ed Trippi y Turban. Probus Publishing Company, 1992, Chicago.

[15]Martín del Brío, B. y Serrano, C. (1993). Self-Organizing Neural Networks for the Analysis and Representation of Data: Some Financial Cases. Neural Computing & Applications, Springer Verlag, vol 1, pag 193-206.

[16]Odom M. D., Sharda R. (1990). A neural network model for bankruptcy prediction. Proceedings of the IEEE International Conference on Neural Networks, San Diego II, p.p. 163-168.

[17]Rahimian E., Singh S., Thammachote T., Virmani R. (1993). Predicción de quiebra mediante redes neuronales. Editorial: R. R. Trippi & E. Turban (eds.): redes Neuronales en Finanzas e Investigación. pp. 159-171.

[18]Salinas Flores, J.(2005) Reconocimiento de patrones de morosidad para un producto crediticio usando la técnica de árbol de clasificación CART. Revista Industrial Data. 8 (1): 29 – 36 pp. ISSN: 1560-9146.

[19]Schreiner, M. (1999) Un modelo de calificación del riesgo de morosidad para los créditos de una organización de micro finanzas en Bolivia. Disponible en: <<http://www.microfinance.com>>.