CONCLUSIONES Y RECOMENDACIONES

1. Primeramente, podemos afirmar que lo que acabamos de hacer no puede generalizarse para cualquier caso ya que dependiendo de que datos se tenga y su relación real con el resultado esperado se esperará un mejor o peor entrenamiento y por ende una respuesta distinta de la red. Es obvio que en el fondo esto debe ser un juego de correlaciones.

   No podemos negar que aunque la red no emplea necesariamente métodos estadísticos conocidos para establecer el grado de cambio que deba dar a sus pesos no es menos cierto que ésta establece una relación intrínseca entre las variables de entrada y las de salida.

   Así, lo que queremos decir es que entre las seis variables de entrada y la variable de salida existe de hecho una matriz de correlaciones y que el grado de aportación que cada una de éstas hace al cambio o

variación de la variable de salida es ahí medido, y que ya que esto es verdad también es verdad que podríamos medir el grado de influencia sobre la variación de la variable de salida en un nuestro modelo de redes neuronales para así saber que variables de entrada son las más "importantes" en relación a su influencia sobre los resultados.

El asunto es aquí es saber que podemos saber a priori si una variable nos va a ser útil o solo será un relleno en el modelo. Lo que ha ocurrido entonces en nuestro caso tal vez no sea producto de la "bondad" de todas las seis variables, sino que muy probablemente la variable que domine la relación con respecto del resultado sea aquella que nos está sesgando la muestra: i_6 o "el cliente paga por débito de cuenta o tarjeta de crédito".

Entonces podemos recomendar para futuros trabajos e investigaciones el hacer un análisis de correlaciones antes de proseguir con el modelamiento de la red, claro está, esto no es estrictamente necesario ya que la red aprenderá más de las variables que más aporten sin importar el resto de las variables. Además no

podemos pedir que todo modelador de redes y peor que todo analista de crédito sea estadístico.

2. En este trabajo, lo más importante en la práctica será recomendar que la toma de datos sea seria. A nuestro parecer las hojas de administración de riesgo se llenan como una simple formalidad sin darle importancia alguna a la información que ahí debe incluirse. Campos vacíos, llenado ilegible, información incierta y no comprobada no pueden ser las variables que nos lleven a un análisis crediticio coherente.

   Recomendamos que se lleven registros digitalizados con la información tomada y que no se llenen papeles para abandonarlos en alguna bodega, por increíble que parezca esto es lo que ocurría y ya vemos cuál es el resultado de esto.

3. También es importante el afirmar que las variables que se usan en la hoja de administración de riesgo no son necesariamente las adecuadas. De hecho, según autores en análisis multivariante lo

recomendable en el caso crediticio será utilizar, tamaño de la familia, ingresos, avalúo de la casa, edad y años de trabajo. Vemos entonces que gran parte de este grupo de variables no es utilizado en Bellsouth.

4. En lo que respecta a la red mencionamos anteriormente que decidimos usar la regla de aprendizaje de Back-propagation para entrenar a la red. Existe sólo un justificativo matemático para utilizar esta regla: la capacidad de aproximar una relación funcional.

   Como por hipótesis las variables de entrada están relacionadas no linealmente con la variable de salida entonces tenemos aquí la razón por la que la propagación inversa da una respuesta al análisis.

5. Aunque encontramos deficiencias en los resultados debido al sesgo hemos encontrado que este proceso de análisis es casi ya una necesidad para un análisis crediticio, esta conclusión no se basa en los resultados necesariamente, se basa en la coherencia que el proceso de aprendizaje tiene. La red neuronal realmente aprende cual si fuera un ente inteligente, esa es la idea de la “inteligencia” artificial.