

## Modelos de Redes Neuronales Perceptrón Multicapa y de Base Radial para la predicción del rendimiento académico de alumnos universitarios

María G. Longoni, Eduardo A. Porcel, María V. López, Gladys N. Dapozo

Facultad de Ciencias Exactas y Naturales y Agrimensura. Universidad Nacional del Nordeste.

magalo82@hotmail.com, {eporcel, mvlopez, gndapozo@exa.unne.edu.ar}

**Resumen.** En este trabajo se analiza la relación del rendimiento académico de los alumnos ingresantes a la FACENA – UNNE en Corrientes, Argentina, durante el primer año de carrera, con las características socioeducativas de los mismos. El rendimiento fue medido por la aprobación de los exámenes parciales de las asignaturas del primer cuatrimestre del primer año de estudios. Se ajustaron modelos de redes neuronales de tipo Perceptrón Multicapa (PM) y de Base Radial (FBR) a dos conjuntos de datos: a) alumnos ingresantes a las carreras cuyos planes de estudios incluyen dos asignaturas en el primer cuatrimestre del primer año, obteniéndose porcentajes de clasificación correcta total de 78,2 % ,y 70,7 % respectivamente; b) alumnos ingresantes a carreras cuyos planes de estudios incluyen tres asignaturas en el primer cuatrimestre del primer año, obteniéndose porcentajes de clasificación correcta total de 75,7 %, y 68,6 % respectivamente. Los resultados obtenidos contribuyen a orientar las políticas y estrategias institucionales para mejorar los preocupantes índices de desgranamiento, abandono y bajo rendimiento de los estudiantes en el primer año de universidad, de la FACENA-UNNE.

**Palabras clave:** Rendimiento académico. Ingresantes universitarios. Redes neuronales. Perceptrones multicapa. Función de Base Radial.

**Abstract.** This paper analyzes the relation between the academic performance of freshmen from FACENA – UNNE in Corrientes, Argentina and their social-educational characteristics. The performance was measured by the number of passed midterm exams of the subjects in the first semester of the first year of study, and the approval of the first subject of mathematics that students study. Multilayer Perceptron (MP) and Radial Basis Function (RBF) neural networks models were adjusted to two data sets: a) students entering careers whose curricula include two courses in the first semester of the first year, obtaining total correct classification rates of 78.2% and 70.7% respectively; b ) students entering careers whose curricula includes three courses in the first semester of the first year, obtaining total correct classification rates of 75.7% and 68.6% respectively. The obtained results contribute to lead policy and institutional strategies to improve the worrying levels of drop out and poor performance of university freshmen, particularly those from FACENA-UNNE.

**Keywords:** Academic Performance. University freshmen. Neural Networks. Multilayer Perceptrons. Radial Basis Function.

## 1 Introducción

A partir de la década del '80 surge en las universidades de todo el mundo la preocupación por la calidad del servicio educativo que prestan. Esto dio lugar a procesos de evaluación a fin de detectar las debilidades y fortalezas institucionales y generar acciones correctivas de las deficiencias encontradas.

En nuestro país, en la década del '90, el Estado Nacional incluye en su agenda de política educativa la evaluación de la calidad del accionar universitario, y la mayoría de las universidades nacionales inician procesos de evaluación institucional. En 1996, se conocieron los primeros resultados referidos al rendimiento académico de los estudiantes de las trece carreras que constituyen la oferta académica de la Facultad de Ciencias Exactas y Naturales y Agrimensura de la Universidad Nacional del Nordeste (FACENA – UNNE). Dicha información hace referencia a elevados índices de desgranamiento en todos los años de estudios pero, fundamentalmente, al término del primer cuatrimestre del primer año. Asimismo, da cuentas de que el retraso promedio en el egreso de todas las carreras alcanza al 50% de la duración teórica de las mismas, llegando en algunas a superarlo [1].

Según diversos estudios, el rendimiento académico de los estudiantes se ve influenciado por la interacción de varios factores, que están ligados a características socioeducativas y culturales, los cuales afectan de manera importante el desempeño de los mismos, ya que son determinantes en la preparación del alumno desde antes de su entrada al sistema educativo y durante toda su trayectoria académica.

Por lo tanto, identificar estos factores y analizar conjuntamente su influencia en el rendimiento académico de los alumnos resulta una estrategia interesante de llevar a cabo, para lograr la identificación temprana de elementos de riesgo, y permitir así la implementación oportuna de acciones correctivas en el proceso educativo.

Las redes neuronales artificiales (RNA) cuentan con el potencial para permitir este tipo de análisis, gracias a su excelente comportamiento en problemas de predicción y clasificación. De esta forma, se puede estimar el rendimiento futuro de los estudiantes teniendo información de diversos factores socioeducativos.

Una red neuronal artificial es un sistema informático reticular (de inspiración neuronal) que aprende de la experiencia mediante la auto-modificación de sus conexiones [2] [3] [4] [5] [6].

Las RNA son herramientas que permiten analizar los datos con el objeto de descubrir y modelar las relaciones funcionales existentes entre las variables. Permiten explorar relaciones o modelos que no podrían ser descubiertos usando procedimientos estadísticos más tradicionales [7]. Se encuentran dentro de los métodos inteligentes, y tienen ventajas sobre los métodos estadísticos cuando se las aplica a situaciones en donde los datos de entrada son incompletos o ambiguos por naturaleza. Tampoco dependen de relaciones funcionales particulares, y no requieren una comprensión a priori de las relaciones entre variables. Asimismo, se caracterizan por su buen rendimiento ante problemas no lineales o datos con mucho "ruido", y presentan la ventaja de poder utilizarse independientemente del cumplimiento de los supuestos teóricos relativos a las técnicas estadísticas, debido a que para su uso no es necesario formular previamente una hipótesis, ya que desentrañan la información implícita en los datos. Hoy en día, las RNA son aplicadas a problemas de índole estadística como lo son la predicción y clasificación [8].

Como antecedentes de aplicación de la técnica de redes neuronales en el ámbito de educación pueden mencionarse los trabajos de [9] [10] [11] [12] [13], entre otros.

El propósito de este trabajo es predecir el rendimiento académico de los alumnos de primer año de la FACENA (UNNE), en función de sus características socioeducativas, aplicando la técnica de RNA en dos de sus tipos más reconocidos, Perceptrón Multicapa y Función de Base Radial.

Este estudio tiene los siguientes objetivos:

- Diseñar e implementar modelos de RNA para predecir el rendimiento académico de los alumnos de primer año de la FACENA-UNNE, en base a los datos socioeducativos disponibles de los mismos.
- Contrastar la eficiencia de las RNA de base radial con las RNA de tipo perceptrón multicapa, en un problema de clasificación de una variable cualitativa de tres categorías (el rendimiento académico de los alumnos del primer año de universidad).

## 2 METODOLOGÍA

### 2.1. Datos

La población analizada consiste en 2239 alumnos ingresantes a la FACENA-UNNE en los años 2004 y 2005. Los datos de sus características socioeducativas se obtuvieron del formulario de ingreso a la universidad, mientras que los correspondientes a su desempeño académico, se obtuvieron del sistema informático de gestión de alumnos de la facultad.

Esta información se incorpora periódicamente en un único almacén de datos con un diseño orientado a las decisiones. Este proceso incluye la integración, depuración y formateo de los datos, siguiendo las técnicas usuales de preprocesado, constituyentes de las etapas previas al modelado y análisis de los datos [14] [15].

Dentro de la oferta académica de la FACENA-UNNE, existen:

- a) Tres carreras cuyos planes de estudios incluyen dos asignaturas en el primer cuatrimestre del primer año (Licenciatura en Matemática, Licenciatura en Ciencias Químicas y Bioquímica), a las cuales ingresaron 592 alumnos.
- b) Nueve carreras cuyos planes de estudios incluyen tres asignaturas en dicho cuatrimestre (Agrimensura, Ingeniería Eléctrica, Ingeniería en Electrónica, Licenciatura en Ciencias Biológicas, Profesorado en Biología, Profesorado en Ciencias Químicas y del Ambiente, Profesorado en Física y Tecnología, Profesorado en Matemática y Licenciatura en Sistemas de Información), a las cuales ingresaron 1647 alumnos.
- c) Una única carrera que posee cuatro asignaturas en el primer cuatrimestre (Licenciatura en Ciencias Físicas), a las cuales ingresaron 16 alumnos. Esta última no se incluyó en el presente análisis porque posee muy pocos alumnos ingresantes en el período estudiado, para poder aplicar las técnicas de RNA.

Por otra parte, todas las carreras tienen en el primer cuatrimestre del primer año una materia con contenidos matemáticos (principalmente Álgebra). Para poder avanzar en las materias del segundo cuatrimestre del primer año, el esquema de correlatividades de los planes de estudios requiere, como mínimo, tener aprobados los

exámenes parciales de esta asignatura (situación que se denomina “regularizar” la asignatura), hecho que configura un fuerte condicionamiento de dicho avance.

En consecuencia, se han diseñado dos modelos diferentes para los casos a) y b) mencionados anteriormente:

- I. En el caso a (carreras cuyos planes de estudios incluyen dos asignaturas en el primer cuatrimestre del primer año), el rendimiento académico se midió mediante una variable  $y_i$  que toma los siguientes valores:
  - 0 (cero), si el alumno no regularizó ninguna asignatura en el primer cuatrimestre (rendimiento malo).
  - 1 (uno), si el alumno regularizó una asignatura diferente de Álgebra en el primer cuatrimestre (rendimiento regular).
  - 2 (dos), si el alumno regularizó Álgebra en el primer cuatrimestre ó si regularizó las dos asignaturas del primer cuatrimestre (rendimiento bueno).
- II. En el caso b (carreras cuyos planes de estudios incluyen tres asignaturas en el primer cuatrimestre del primer año), el rendimiento académico se midió mediante una variable  $y_i$  que toma los siguientes valores:
  - 0 (cero), si el alumno no regularizó ninguna asignatura en el primer cuatrimestre (rendimiento malo).
  - 1 (uno), si el alumno regularizó una asignatura en el primer cuatrimestre ó si regularizó dos asignaturas diferentes de Álgebra (rendimiento regular).
  - 2 (dos), si el alumno regularizó dos asignaturas siendo Álgebra una de ellas ó si regularizó las tres asignaturas del primer cuatrimestre (rendimiento bueno).

A continuación se enuncian las variables socioeducativas (independientes) que se incluyeron en ambos modelos, y las categorías que asumen.

- AÑO DE INGRESO: 2004, 2005
- CARRERA: En el modelo diseñado para el caso a) las carreras son: Licenciatura en Matemática; Licenciatura en Ciencias Químicas; Bioquímica. En el modelo descrito para el caso b) las carreras son: Agrimensura; Ingeniería Eléctrica; Ingeniería en Electrónica; Licenciatura en Ciencias Biológicas; Profesorado en Biología; Profesorado en Ciencias Químicas y del Ambiente; Profesorado en Física y Tecnología; Profesorado en Matemática; Licenciatura en Sistemas de Información.
- SEXO: Varón; Mujer.
- TIENE MAIL: No; Sí.
- TÍTULO SECUNDARIO: Economía y Gestión de las Organizaciones; Humanidades y Ciencias Sociales; Comunicación, Arte y Diseño; Producción de bienes y servicios; Bachiller común; Peritos Mercantiles; Técnicos; Otros títulos; Ciencias Naturales.
- DEPENDENCIA DEL ESTABLECIMIENTO: Nacional, Provincial; Dependiente de la Universidad; Privados religiosos; Privados particulares; Institutos militares.
- COBERTURA OBRA SOCIAL: De los padres; Del cónyuge; Propia; Ninguna
- ESTUDIO DE LOS PADRES: Se consideró el mayor nivel educativo alcanzado por el padre o la madre. Las categorías son: No hizo

estudios/Escuela Primaria Incompleta; Escuela Primaria Completa/ Escuela Secundaria Incompleta; Escuela Secundaria Completa/Estudio Superior No Universitario Incompleto; Estudio Superior No Universitario Completo/Estudio Universitario Incompleto; Estudio Universitario Completo/Estudios de Posgrado.

Las variables relacionadas a la actividad laboral del alumno y de los padres no pudieron ser incluidas en el modelo debido a la notable falta de respuesta registrada en los formularios.

## **2.2. Perceptrones Multicapa**

Las RNA de tipo Perceptrón Multicapa (PM) se encuentran entre las arquitecturas de red más poderosas y populares. Están formadas por una capa de entrada, un número arbitrario de capas ocultas, y una capa de salida. Cada una de las neuronas ocultas o de salida recibe una entrada de las neuronas de la capa previa (conexiones hacia atrás), pero no existen conexiones laterales entre las neuronas dentro de cada capa [16].

La capa de entrada contiene tantas neuronas como categorías correspondan a las variables independientes que se desean representar. La capa de salida corresponde a la variable respuesta, que en este caso es una variable categórica.

## **2.3. Redes neuronales de Base Radial**

Las RNA de Función de Base Radial (FBR) son aquellas cuyas funciones de activación en los nodos ocultos son radialmente simétricas. Se dice que una función es radialmente simétrica (o es una Función de Base Radial, FBR) si su salida depende de la distancia entre un vector que almacena los datos de entrada y un vector de pesos sinápticos, que recibe el nombre de centro o centroide [22]. Fueron usadas por primera vez por [23], y pueden encontrarse contribuciones a su teoría, diseño y aplicaciones en los trabajos de [24] y [25].

Las redes FBR presentan tres capas de conexión hacia adelante: la capa de entrada, la capa oculta o intermedia y la capa de salida. Las neuronas de la capa de entrada simplemente envían la información a la capa intermedia. Las neuronas de la capa oculta se activan en función de la distancia que separa cada patrón de entrada con respecto al centroide que cada neurona oculta almacena, a la que se le aplica una función radial con forma gaussiana. Las neuronas de la capa de salida son lineales, y simplemente calculan la suma ponderada de las salidas que proporciona la capa oculta.

## **2.4. Modelos PM y FBR para predecir el rendimiento académico**

Se aplicaron modelos de redes neuronales de tipo PM y FBR a los conjuntos de datos descriptos en la sección 2.1.

En el entrenamiento de las redes, se presentó un conjunto de patrones de entrada, constituido por las variables que definen el perfil socioeducativo enumeradas precedentemente, y su correspondiente valor de salida (rendimiento académico) esperado.

Para el entrenamiento de las redes PM, se emplearon los algoritmos de aprendizaje supervisado de Retropropagación (BackPropagation - BP) [17] [18] [19] y Gradiente descendente (Conjugate Gradient Descent - CG) [20] [21].


El entrenamiento de las redes FBR comprende dos fases: una no supervisada y otra supervisada. En la fase no supervisada se empleó el algoritmo K-medias para la determinación de centros, y el método del vecino más cercano para el cálculo de las amplitudes de las neuronas de la capa oculta [22] [26] [27]. La fase supervisada consiste en la determinación de los pesos y umbrales en la capa de salida. Para minimizar la diferencia entre las salidas de la red y las salidas deseadas, se utilizó el método de los mínimos cuadrados [22].

Para efectuar la validación, se utilizó en cada caso una lista de mediciones independientes de los datos para todas las variables a fin de determinar el grado de predicción de cada modelo (validación cruzada). Este conjunto constituyó el 25 % del total de los datos y fue seleccionado al azar.


Debido a que se trata de un problema de clasificación, el objetivo de la red es el de asignar a cada caso, una de tres clases (Bueno, Regular o Malo), estimando la probabilidad de pertenencia del caso a cada clase.

Con respecto a la determinación del nivel de corte o umbral de clasificación, en este trabajo se indicó que no se utilizarían umbrales, por lo que la red utilizó el algoritmo "winner takes all". En este algoritmo, la neurona de mayor activación determina la clase, y no hay "opción de duda".


La arquitectura de las redes que presentan los modelos PM y FBR entrenados tienen la forma I:N-N-N:O, donde I es el número de variables de entrada, O es el número de variables de salida, y N es el número de unidades en cada capa (Fig. 1 a 4).




**Fig. 1.** Arquitectura del modelo de red PM para las carreras con dos asignaturas en el primer cuatrimestre de primer año (8:28-11-11-3:1)



**Fig. 2.** Arquitectura del modelo de red FBR para las carreras con dos asignaturas (8:29-53-3:1)



**Fig. 3.** Arquitectura del modelo de red PM para las carreras con tres asignaturas en el primer cuatrimestre de primer año (8:35-11-11-3:1)



**Fig. 4.** Arquitectura del modelo de red FBR para las carreras con tres asignaturas en el primer cuatrimestre de primer año (7:34-67-3:1)

### 3 Resultados y Discusión

Para los modelos PM y FBR entrenados con el conjunto de datos correspondiente a las carreras que poseen dos asignaturas en el primer cuatrimestre de primer año, se obtuvieron, en el caso del modelo PM un porcentaje de clasificación correcta total de 78,2 %, y para el modelo FBR de 70,7 % (Tablas 1 y 2).

Para los modelos PM y FBR entrenados con el conjunto de datos correspondiente a las carreras que poseen tres asignaturas en el primer cuatrimestre de primer año, se obtuvieron, en el caso del modelo PM un porcentaje de clasificación correcta total de 75,7 %, y para el modelo FBR de 68,6 % (Tablas 3 y 4).

Por otra parte, puede apreciarse que el modelo PM predice adecuadamente tanto el Rendimiento Malo (0) como el Rendimiento Regular (1) y el Bueno (2), situación que no ocurre con el modelo FBR.

Tabla 1: Modelo de red PM para las carreras con dos asignaturas en el primer cuatrimestre de primer año. Matriz de clasificación

| Clasificación         | Rendimiento académico |             |          | Total |
|-----------------------|-----------------------|-------------|----------|-------|
|                       | Bueno (2)             | Regular (1) | Malo (0) |       |
| Bueno (2)             | 78                    | 15          | 36       |       |
| Regular(1)            | 6                     | 45          | 21       |       |
| Malo (0)              | 30                    | 21          | 340      |       |
| Total                 | 114                   | 81          | 397      | 592   |
| % de clasif. correcto | 68,4                  | 55,5        | 85,6     | 78,2  |

Tabla 2: Modelo de red FBR para las carreras con dos asignaturas en el primer cuatrimestre de primer año. Matriz de clasificación

| Clasificación         | Rendimiento académico |             |          | Total |
|-----------------------|-----------------------|-------------|----------|-------|
|                       | Bueno (2)             | Regular (1) | Malo (0) |       |
| Bueno (2)             | 34                    | 10          | 23       |       |
| Regular(1)            | 4                     | 14          | 3        |       |
| Malo (0)              | 76                    | 57          | 371      |       |
| Total                 | 114                   | 81          | 397      | 592   |
| % de clasif. correcto | 29,8                  | 17,2        | 93,4     | 70,7  |

Tabla 3: Modelo de red PM para las carreras con tres asignaturas. Matriz de clasificación

| Clasificación         | Rendimiento académico |             |          | Total |
|-----------------------|-----------------------|-------------|----------|-------|
|                       | Bueno (2)             | Regular (1) | Malo (0) |       |
| Bueno (2)             | 206                   | 55          | 123      |       |
| Regular(1)            | 28                    | 90          | 35       |       |
| Malo (0)              | 78                    | 80          | 952      |       |
| Total                 | 312                   | 225         | 1110     | 1647  |
| % de clasif. correcto | 66,0                  | 40,0        | 85,7     | 75,7  |

Tabla 4: Modelo de red FBR para las carreras con tres asignaturas. Matriz de clasificación

| Clasificación         | Rendimiento académico |             |          | Total |
|-----------------------|-----------------------|-------------|----------|-------|
|                       | Bueno (2)             | Regular (1) | Malo (0) |       |
| Bueno (2)             | 99                    | 42          | 81       |       |
| Regular(1)            | 10                    | 24          | 22       |       |
| Malo (0)              | 203                   | 159         | 1007     |       |
| Total                 | 312                   | 225         | 1110     | 1647  |
| % de clasif. correcto | 31,7                  | 10,6        | 90,7     | 68,6  |

## 4 Conclusiones

Se concluye que la técnica de RNA ha mostrado en general una buena capacidad clasificatoria, mediante los modelos PM y FBR orientados a la predicción del rendimiento académico de los alumnos ingresantes a la FACENA-UNNE en función de sus características socio-educativas.

En relación a los tipos de RNA empleados, cabe destacar que los ajustes ofrecidos por las redes PM son superiores a los obtenidos con las redes FBR, aplicados a los mismos conjuntos de datos.

Con respecto a los diferentes modelos entrenados, se ha observado que los modelos diseñados para las carreras con dos asignaturas en el primer cuatrimestre del primer año han permitido obtener mejores porcentajes de clasificación que los modelos para las carreras con tres asignaturas en el mencionado cuatrimestre, probablemente debido a que la categoría de rendimiento regular en el segundo modelo resulta más compleja de definir respecto de la construida para el primero.

A futuro se profundizará este estudio con otros métodos inteligentes, tales como árboles de clasificación, y se realizarán comparaciones entre las diferentes técnicas.



A nivel de la gestión de la educación superior, los modelos de RNA desarrollados en este trabajo permiten obtener información acerca del rendimiento académico de los alumnos ingresantes a la FACENA-UNNE al finalizar el primer cuatrimestre del primer año de estudios, contribuyendo de este modo a orientar las políticas y estrategias institucionales para mejorar los preocupantes índices de desgranamiento, abandono y bajo rendimiento.

## 5 Referencias

1. Comisión de Autoevaluación. Informe de Avance Pre-diagnóstico 1996. Facultad de Ciencias Exactas y Naturales y Agrimensura. Universidad Nacional del Nordeste. (1996).
2. Heccht-Nielsen, R.: Neurocomputing. Addison-Wesley. Cal. (1990)
3. Hertz, J. Krogh, A. y Palmer, R.: Introduction to the Theory of Neural Computation. Addison-Wesley. Cal. (1991)
4. Wasserman, P.D.: Neural Computing: Theory and Practice. Van Nostrand Reinhold. N.Y. (1989)
5. Hilera, J.R., Martínez, V.J.: Redes Neuronales Artificiales: Fundamentos, Modelos y Aplicaciones. Ra-ma. Madrid. (1995)
6. Martín, B. y Sanz, A.: Redes Neuronales y Sistemas Borrosos. Ra-ma. Madrid. (1997)
7. Rzepoluck, E. J.: Neural Network Data Analysis Using Simulnet. Simon Fraser University. Burnaby. B.C. Canadá. ISBN: 0-387-98255-8. pp. 1-3, 13-75. (1997)
8. Pitarque A., Ruiz, J. C., Roy, J. F.: "Las Redes Neuronales como Herramientas Estadísticas No Paramétricas de Clasificación". Psicothema ISSN 0214 - 9915 CODEN PSOTEG. 2000. Vol. 12, Supl. n° 2, pp. 459-463. (2000) Disponible en: <http://www.psycothema.com/psycothema.asp?id=604>. Fecha de consulta: Mayo de 2010.
9. González, D.S.: Detección de Alumnos de Riesgo y Medición de la Eficiencia de Centros Escolares mediante Redes Neuronales. Biblioteca de Cs. Económicas y Empresariales. Servicios de Internet. Universidad Complutense de Madrid. (1999)
10. Salgueiro, F., Costa, G., Cánepa, S., Lage, F., Kraus, G., Figueroa, N., Cataldi, Z.: Redes Neuronales para Predecir la Aptitud del Alumno y Sugerir Acciones. VIII Workshop de Investigadores en Ciencias de la Computación (2006)
11. Borracci, R. A., Arribalzaga, E. B.: Aplicación de Análisis de Conglomerados y Redes Neuronales Artificiales para la Clasificación y Selección de Candidatos a Residencias Médicas. Educación Médica Vol 8 N° 1. ISSN 1575-1813. Barcelona. (2005)
12. Zamarripa Topete, J., Sánchez Rodríguez, J.: Perfiles de Calidad en Evaluación Institucional y Programa Académico, aplicando Redes Neuronales. Anales del VII Congreso internacional "Retos y expectativas de la Universidad". Universidad Autónoma de Nuevo León. México. (2007) Disponible en: [http://www.congresoretosyexpectativas.udg.mx/Congreso%201/Mesa%20E/ Mesa-e\\_6.pdf](http://www.congresoretosyexpectativas.udg.mx/Congreso%201/Mesa%20E/ Mesa-e_6.pdf). Fecha de consulta: Febrero de 2010.
13. Santín González, D.: Detección de Alumnos de Riesgo y Medición de la Eficiencia de Centros Escolares mediante Redes Neuronales. Disponible en: <http://eprints.ucm.es/6674/1/9902.pdf>. (1999)
14. Dapozo, G., Porcel, E.: Metodología de integración de datos para apoyar el seguimiento y análisis del rendimiento académico de los alumnos de la FACENA. Comunicaciones Científicas y Tecnológicas de la Universidad Nacional del Nordeste 2005. Corrientes. Argentina. (2005). Disponible en: <http://www.unne.edu.ar/Web/cyt/com2005/8-Exactas/E-032.pdf>.
15. Dapozo, G., Porcel, E., López, M. V.; Bogado, V.: Técnicas de preprocesamiento para mejorar la calidad de los datos en un estudio de caracterización de ingresantes

- universitarios. IX Workshop de Investigadores en Ciencias de la Computación (WICC 2007). Trelew. Chubut. Argentina. (2007)
16. Castillo, E., Cobo, A., Gutiérrez, J.M., Pruneda, R.E.: Introducción a las Redes Funcionales con Aplicaciones. Un Nuevo Paradigma Neuronal. Editorial Paraninfo S.A. Madrid. España. pp.5-8; 8-16; 21-24, 30-34, 53-100. (1999)
  17. Patterson, D.: Artificial Neural Networks. Singapore: Prentice Hall. (1996). En: Lévy Mangin, J.; Varela Mallou, J. Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A. (2003)
  18. Fausett, L.: Fundamentals Of Neural Networks. New York: Prentice Hall. (1994). En: Lévy Mangin, J.; Varela Mallou, J. Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A. (2003)
  19. Haykin, S.: Neural Networks: A Comprehensive Foundation. New York: Macmillan Publishing. (1994). En: Lévy Mangin, J.; Varela Mallou, J. Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A. (2003)
  20. Bishop, C.: Neural Networks for Pattern Recognition. Oxford: University Press. (1995). En: Lévy Mangin, J.; Varela Mallou, J.. Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A. (2003)
  21. Shepherd, A. J.: Second-Order Methods For Neural Networks. New York: Springer. (1997). En: Lévy Mangin, J.; Varela Mallou, J.. Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A. (2003)
  22. Vélez-Langs, O., Staffetti, E.: Computación Neuronal y Evolutiva. Redes de Funciones de Base Radial. Asignatura "Computación Neuronal y Evolutiva". Escuela Superior de Ingeniería Informática. Universidad Rey Juan Carlos. (2007) Disponible en: <http://www.ia.urjc.es/~ovelez/docencia/cne/Redes%20de%20Funciones%20de%20Base%20Radial.pdf>. Fecha de consulta: Abril de 2010.
  23. Broomhead, D.S., Lowe, D.: Multivariable Functional Interpolation And Adaptive Network. *Complex Systems*, 2, 321–355. (1988)
  24. Moody, J.; Darken, C.: Fast Learning In Networks Of Locally Tuned Processing Units. *Neural Computation*, 1 (2), 281–294. (1989)
  25. Poggio, T.; Girosi, F.: Network for Approximation and Learning. *Proceedings of IEEE*, 78 (9), 1491–1497. (1990)
  26. Palacios Burgos, F. J.: Herramientas en GNU/Linux para estudiantes universitarios: Redes Neuronales con GNU/Linux. (2003). Disponible en: [http://softwarelibre.unsa.edu.ar/docs/descarga/2003/curso/htmls/redes\\_neuronales/x185.html](http://softwarelibre.unsa.edu.ar/docs/descarga/2003/curso/htmls/redes_neuronales/x185.html). Fecha de consulta: Abril de 2010.
  27. Lanzarini, L.: Redes Neuronales de Base Radial (Ejemplo K-Médias)". Material didáctico. Cátedra "Redes Neuronales y algoritmos evolutivos". Instituto de Investigación en Informática LIDI. Facultad de Informática. Universidad Nacional de La Plata. Buenos Aires. Argentina. (2003). Disponible en: [http://weblidi.info.unlp.edu.ar/catedras/neuronales/05\\_RBF.pdf](http://weblidi.info.unlp.edu.ar/catedras/neuronales/05_RBF.pdf). Fecha de consulta: Abril de 2010.