

RECONOCIMIENTO DE PATRONES EN UN ARREGLO SENSORICO USANDO REDES NEURONALES

PATTERN RECOGNITION FROM A SENSOR ARRAY USING NEURAL NETWORKS

Julián Andrés, Ramos Rojas

Ing. Mecatrónico Joven Investigador Grupo de Investigación: Sistemas Particulados Complejos
Facultad de Ingeniería Universidad Militar Nueva Granada, Bogotá, Colombia.
e-mail:Ing.Julianr@gmail.com

Mauricio Aníbal, Sierra Sarmiento

Ing. Químico, MSc., Joven Investigador, Grupo de Investigación: Sistemas Particulados Complejos,
Facultad de Ingeniería Universidad Militar Nueva Granada, Bogotá, Colombia.
e-mail:msierras@yahoo.com

Watson Lawrence, Vargas Escobar

Ingeniero Químico, MSc, Ph.D. Research Scholar. School of engineering, Department
of Chemical Engineering, University of Pittsburgh, Pittsburgh, (E.U.),
e-mail:wwargas@etb.net.co

Fecha de recepción: Octubre 31 de 2006

Fecha de aprobación: Junio 2 de 2007

RESUMEN

En este trabajo se presenta el desarrollo de un sistema para el procesamiento de señales provenientes de un arreglo sensorico mediante la implementación de redes neuronales artificiales. Ejemplos simples de aplicación se presentan para demostrar la potencialidad del sistema y su adaptabilidad a diferentes entornos.

PALABRAS CLAVE: Redes neuronales, inteligencia artificial, reconocimiento de patrones, arreglos sensoricos.

ABSTRACT

In this work, the development of a system for the processing of signals from a sensor array, based on artificial neural networks is presented. Simple applications are presented to show the performance and the potential of the proposed system. The implementation was tested with a sensoric array of gas sensors intended to identify vapors of different compounds.

KEYWORDS: Neural Networks, artificial intelligence, pattern recognition, sensor array.

INTRODUCCIÓN

El reconocimiento de patrones es una actividad propia de los seres humanos y muchos animales, y se puede interpretar como: la capacidad de extraer información y luego relacionarla para establecer así una forma de clasificación de la información. Un patrón en general se refiere a los objetos o formas que percibimos [11] por medio de nuestros sentidos y que vinculamos para dar una representación general. De esta forma se identifican múltiples ejemplos en sucesos cotidianos que nos afectan, considérese por ejemplo un día cálido o frío; ambos definidos como un conjunto de condiciones atmosféricas, que incluyen: temperatura, humedad atmosférica, nubosidad, precipitación, presión atmosférica y vientos; todas ellas definen lo que sería un día cálido o frío dependiendo de su magnitud. Es importante notar que un patrón es multivariable, es decir no está compuesto por una sola variable sino por un conjunto de datos.

El reconocimiento de patrones es el proceso de categorización de muestras de mediciones o datos observados como miembros de una de muchas clases o categorías, a su vez es una ramificación de la inteligencia artificial [11], es un área Multidisciplinaria que concierne a Ingenieros, Economistas, Biólogos, y demás áreas en las que se pretenda realizar una clasificación y reconocimiento de datos. Para el reconocimiento de patrones se utilizan diversas técnicas que incluyen las redes neuronales y su combinación con técnicas más avanzadas como teoría del caos y técnicas avanzadas para reconocimiento de patrones como la implementación denominada modelo KIII [3]. Este último modelo es muy promisorio y actualmente se encuentra en desarrollo, sin embargo, la dificultad de este sistema para reconocimiento de patrones radica en la complejidad de su implementación. Dentro de los medios utilizados para el reconocimiento de patrones encontramos las RNA (Redes Neuronales Artificiales) como uno de los medios más efectivos para hacer reconocimiento de patrones en general, pero específicamente sobre arreglos sensoricos para detección de gases debido a la complejidad de este tipo de sistemas y al diseño biológicamente inspirado de las RNA [10] que las hace ideales para el reconocimiento de patrones en entornos ruidosos y cambiantes.

Un claro ejemplo de la aplicación de las RNA es el trabajo desarrollado por el *Centre for Development of Advanced Computing* en donde se desarrolla un sistema completo para el seguimiento del proceso de fermentación del té [6] basándose en un arreglo de sensores, utilizando para la interpretación de los datos adquiridos una red neuronal con la capacidad de predecir el “sabor” final del té, tal observación sirve como base para la determinación del tiempo necesario para el procesado del mismo. Otro ejemplo de aplicación de las redes neuronales para identificación de patrones es el trabajo realizado por Hashem [4] en el cual se expone el uso de las RNA para la detección en tiempo real de contaminantes en el aire. Loh *et al.* [2], destacan el uso de las RNA basadas en el algoritmo de *Back Propagation* para la identificación de patrones debido a su simplicidad respecto a otros algoritmos

como las redes Kohonen o las redes probabilísticas. Estos estudios indican que el algoritmo de *Back Propagation* es el más sencillo de implementar y es por tanto ampliamente usado para el análisis de sustancias químicas [1], mostrando por ejemplo, un muy buen desempeño para la predicción de concentraciones provenientes de un sensor de ácido salicílico [2]. Un aspecto importante de este trabajo es el uso de arreglos sensoricos y redes neuronales en conjunto, ya que este tipo de sistemas generan muy buenos resultados para el análisis de la composición de gases, detección de explosivos, aplicaciones médicas, monitoreo de gases en el medio ambiente y en la industria alimenticia [7]. Siguiendo este orden de ideas y debido a los excelentes resultados mostrados para la clasificación de patrones provenientes de arreglos sensoricos, en este trabajo se considera el método de identificación de patrones por redes neuronales multicapa basadas en el algoritmo de *Back Propagation* para la identificación de patrones generados en un arreglo de sensores de estado sólido para el sensado de vapores.

Este artículo se encuentra organizado de la siguiente forma: En la sección II se explica la teoría básica de redes neuronales y las premisas de diseño de la red neuronal que se utilizaron para realizar el reconocimiento de patrones. En la sección III se explica el funcionamiento básico del software. En la sección IV se muestran los resultados obtenidos y en la sección V se presentan perspectivas y conclusiones de la investigación.

1. ARQUITECTURA DE REDES NEURONALES

Una red neuronal se construye a partir de un número de unidades individuales denominadas neuronas que están interconectadas con otras neuronas de capas diferentes a la propia. Cada Neurona de manera individual posee un número de entradas, un nodo de procesamiento y una única salida, cada conexión entre neuronas está asociada con un peso (ver Figura 1).




Figura 1. Estructura de una neurona. x denota la nomenclatura usada para denotar las entradas, w para los pesos y y para la salida generada por la neurona.




Figura 2. Estructura básica de una red neuronal. Nótese que en este gráfico se omitieron los pesos asociados a cada una de las entradas para facilitar su comprensión también se omitió en la nomenclatura la capa correspondiente, indicando únicamente el número de neurona.

El procesamiento en una red neuronal tiene lugar en paralelo para todas las neuronas. Cada neurona, constantemente (en un ciclo sin fin) evalúa (lee) sus entradas, calcula su valor de activación local y produce (escribe) un valor de salida, tal y como se ilustra en la Figura 2.

Las redes neuronales tienen básicamente dos ciclos de funcionamiento *Forward Propagation* y *Back Propagation*, en el primero la red establece la forma como responde a las entradas presentadas a esta y en el segundo paso se establece la modificación de los pesos de la red que finalmente se vera reflejado en el aprendizaje de la red neuronal.

En este trabajo se utilizó la arquitectura típica de una red neuronal multicapa utilizando “*Back Propagation*” como algoritmo de aprendizaje. En la implementación desarrollada se utiliza como función de activación la función tangente hiperbólica, esta función de activación se utiliza extensamente debido a que además de ser no lineal presenta una variación suave entre sus valores lo cual ayuda a la estabilización de la red, adicionalmente, esta función trigonométrica es anti-simétrica lo que acelera el proceso de aprendizaje [5]. Otro aspecto importante en el entrenamiento de la red neuronal es trabajar con la función de activación dentro de rangos que no saturan esta función [5], en este caso específicamente se trabajo con valores deseados para la red neuronal de 1 y -1 sin embargo la función de activación trabaja entre 1.7159 y -1.7159.

El algoritmo de *Back Propagation* es uno de los algoritmos más populares para el entrenamiento de redes neuronales; se aplica extensivamente y muestra un desempeño óptimo. En la práctica sin embargo, este algoritmo puede presentar dos dificultades: (1) velocidad de convergencia lenta y (2) no siempre se garantiza encontrar el mínimo global de la función de error, sin embargo, nuevos algoritmos pueden corregir estas dificultades [9]. El algoritmo de *back-propagation* funciona de la siguiente manera:

1. Inicializar la red con pesos aleatorios
2. Para todos los casos de entrenamiento:

- a. Presentar las entradas a la red y calcular las salidas.
- b. Para todas las capas (empezando con la capa de salida, hacia la capa de entrada:
 - i. Comparar la salida de la red con la respuesta correcta (función de error)
 - ii. Adaptar los pesos en la capa correspondiente
- c. Evaluación del nivel de error generado al presentar cada uno de los patrones a la red, si se cumple el criterio de parada se detiene el entrenamiento, si no es así se vuelve al paso 2a.

El ciclo de propagación reversa (*Back Propagation*) se caracteriza por la renovación de los valores de los pesos de la red en general y la retro-propagación del error desde la capa de salida hacia las demás capas ocultas de la red. Para esta aplicación se utilizó una tasa de aprendizaje de 0.03 y 0.05 con los cuales se obtuvieron los mejores resultados, si bien uno de los valores recomendados es 0.1 [12], este comportamiento no es inusual dado que cada caso de entrenamiento de una red neuronal es único, aun cuando existen ciertas generalidades en los parámetros de entrenamiento estos no siempre son aplicables o no generan los mejores resultados.

2. IMPLEMENTACIÓN DEL SOFTWARE

2.1. ENTRENAMIENTO DE LA RED

Para el entrenamiento de la red y teniendo en cuenta los requerimientos del método de *Back-Propagation*, el software toma cada uno de los patrones previamente especificados y los presenta a la red de forma ordenada, cada uno de los patrones provoca la activación de cada una de las neuronas en la red generando una salida para luego con base en esta determinar un error. Este error generado es entonces repropagado a las capas anteriores para la respectiva modificación de los pesos y de esta manera termina un ciclo de aprendizaje para un patrón dado. Al presentar cada uno de los patrones necesarios para el entrenamiento de la red se completa una época. De esta forma la red se entrena hasta cumplirse el criterio de parada, dicho criterio se basa en el aprendizaje de la red y se evalúa mediante uno de dos métodos; por medio del error generado por época o mediante la cantidad de iteraciones siendo este último criterio el menos aconsejable debido a que no se asegura el aprendizaje. El error puede ser determinado por medio del error promedio, mínimos cuadrados y error RMS (Root Mean Square, por sus siglas en inglés), en nuestro caso utilizamos el RMS [12] debido a que permite tener un mejor control del error sin que se presenten casos en los que existan patrones para los cuales la red no está en capacidad de reconocer un patrón dado incluso para valores bajos de

error. La Figura 3 muestra de manera esquemática un resumen del comportamiento del algoritmo de *Back Propagation*.

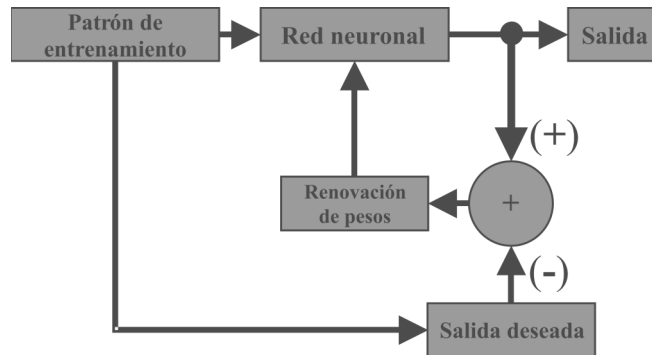


Figura 3. Esquema de visualización del entrenamiento de la red para un patrón dado aplicando el algoritmo de *back propagation*.

2.2. SISTEMA DE ADQUISICIÓN

El software está diseñado para utilizarse con arreglos sensoricos, para tal fin se diseñó e implementó una tarjeta de adquisición con capacidad para 8 canales de entrada, cada uno con una velocidad de captura de 128 muestras por segundo. La estructura básica de la tarjeta está basada en la utilización de un PIC16F877A para la conversión análogo a digital de la información de cada canal y para la transmisión de los datos usando comunicación serial. En la Figura 4 se muestra el esquema básico de funcionamiento de la tarjeta de adquisición.

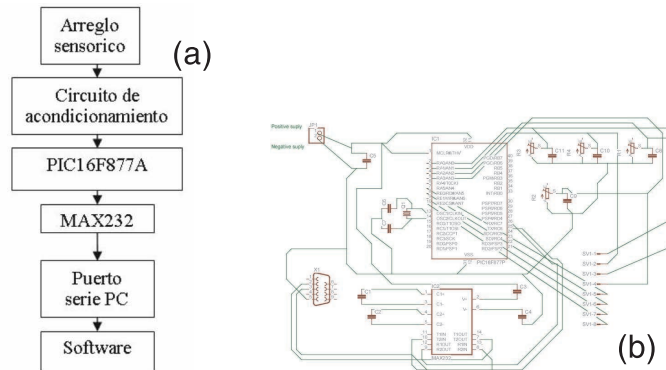


Figura 4. Sistema de adquisición de datos (a) Diagrama de funcionamiento del montaje. (b) Esquema del Montaje experimental del sistema de adquisición y el arreglo sensorico.

Además de la tarjeta se elaboró un software especial denominado “DaqS” (Data acquisition System) para la lectura de los datos enviados por la tarjeta. En el DaqS se pueden visualizar los datos recibidos por la tarjeta tanto numérica como gráficamente como se puede observar en la Figura 5.

Los gráficos del aplicativo permiten visualizar el número de la muestra, el valor y canal de entrada, de forma similar a como se observarían los datos en un osciloscopio. El DaqS además de recibir los datos puede almacenarlos para su posterior uso, en nuestro caso específico, para el entrenamiento de la red neuronal.




Figura 5. Screen-shot tomado del DaqS. Se observan los 8 canales de entrada cada uno identificado con un color característico. La señal ilustra la variación de cada canal en función del tiempo.

2.3. ICARUS

Icarus es el programa principal donde se crea la red neuronal, se entrena y evalúa de manera manual o por medio de la tarjeta de adquisición. Este programa se implementó de forma que fuera multipropósito, de esta forma se puede evaluar cualquier tipo de arreglo sensorico sin importar la cantidad de sensores a utilizar, ya que el programa crea redes neuronales de forma dinámica, es decir no hay restricción para la creación de redes neuronales, su tamaño puede ser completamente especificado por el usuario. Sin embargo, en nuestra aplicación específicamente se utilizaron dos capas para la red neuronal ya que éstas son más que suficientes para la resolución de la mayoría de problemas de reconocimiento de patrones, sin embargo dependiendo de la complejidad del problema se deben aumentar la cantidad de neuronas para obtener una mejor aproximación para el reconocimiento de patrones [8], lo cual es fácilmente resuelto por el Icarus ya que en éste se pueden especificar la cantidad de neuronas con las que se desea trabajar. El programa para crear la red neuronal solicita al usuario las especificaciones de la red las cuales incluyen: entradas, patrones, muestras y capas. Luego de ello se especifica la cantidad de muestras de cada patrón y la neurona de activación específica de cada caso. Por último el programa entrena la red neuronal y para ello solicita al usuario el error deseado como criterio de parada y la velocidad de aprendizaje.

Adicionalmente Icarus tiene la opción de guardar la red creada para su posterior uso sin requerir de un nuevo entrenamiento lo cual lo hace un sistema portable y de fácil uso.

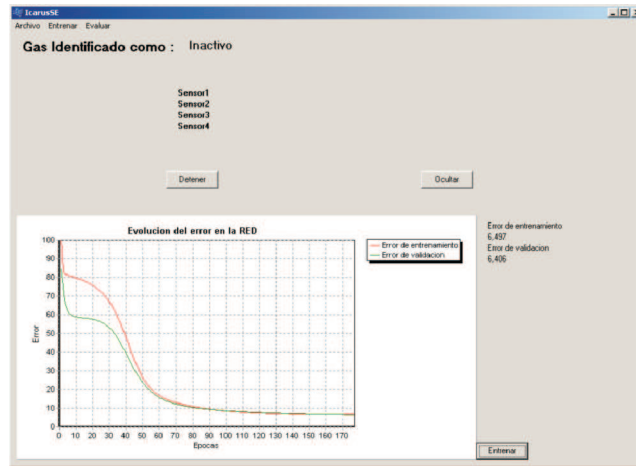


Figura 6. Interfaz del Icarus. La interfaz muestra el valor de activación de cada una de las neuronas de la capa de salida, el grafico de error vs iteraciones y el tipo de gas identificado.

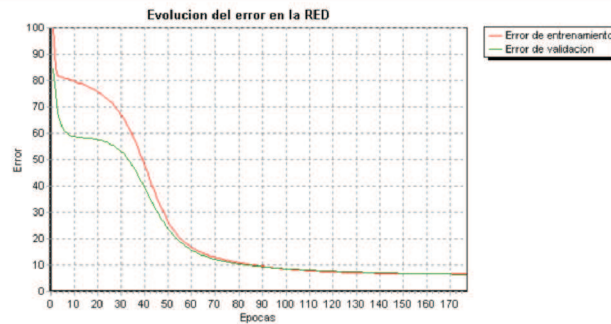


Figura 7. Evolución del error. Se puede observar como la red neuronal converge rápidamente a un error menor al 10%, en rojo se observa el error de entrenamiento y en verde el error de validación, el último nos indica el grado de generalización de la red.

En la Figura 7 se observa la evolución del error vs las iteraciones para la red neuronal creada para el reconocimiento de gases. Se observa claramente que como la cantidad de iteraciones es baja, el sistema es por tanto muy sencillo de entrenar y de “reconfigurar” si es necesario. Se observa también en la Figura 7 que el criterio de parada asignado en este caso fue del 1%, esto con el objetivo de que la red neuronal sea capaz de generalizar y no de especializarse únicamente en las muestras para las que fue entrenada para reconocer, mejorando así la posibilidad de reconocimiento de muestras de vapor para las cuales el sistema no fue entrenado [8]. También se puede observar en la figura 7 el error de validación que no es mas que un indicador de la respuesta de la red neuronal a nuevos patrones no utilizados en el set de entrenamiento, de la grafica fácilmente se

puede concluir que la red neuronal tiene una buena generalización ya que para este nuevo patrón responde con un error RMS del 10% y comparados con los errores reportados por la literatura que este es un error aceptable [5].

3. RESULTADOS

Icarus fue diseñado para ser utilizado en el reconocimiento de patrones generados por un arreglo conformado por cuatro sensores cada uno con la capacidad de reconocer de forma individual un tipo diferente de gas: Amoniaco, Metanol, solventes y solventes orgánicos volátiles (VOC).

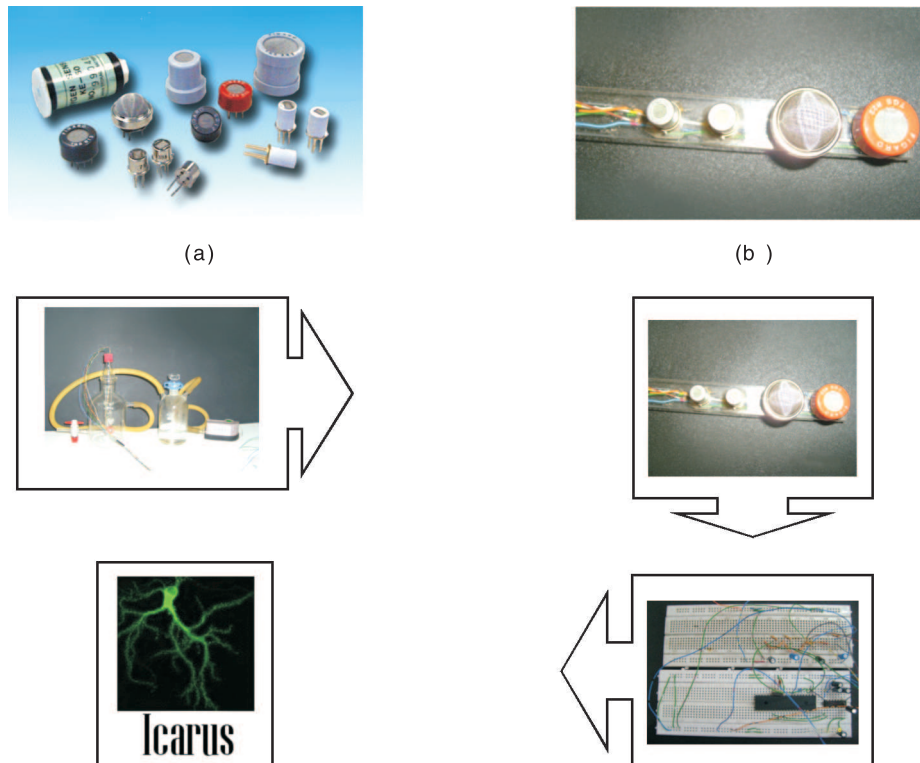


Figura 8. Montaje experimental del arreglo sensórico (a) Sensores utilizados para el desarrollo del arreglo (Fuente: Figaro sensors). (b) Imagen del arreglo sensórico implementado. (c) Sistema de sensado implementado. 1. Cámara de sensado, cámara de burbujeo y bomba de aire. 2. Arreglo sensórico, 3. Tarjeta de adquisición de datos, 4. Icarus "Reconocimiento de patrones".

Este arreglo de sensores se construyó sobre una lámina de acrílico la cual se aisló del medio ambiente por medio de un recipiente en vidrio, este a su vez permite la entrada y salida controlada del gas. El sistema completo opera de la siguiente manera: Inicialmente un flujo de aire suministrado por una bomba se introduce a un sistema de burbujeo, allí se "airea" la muestra que luego es introducida por medio de una manguera en la cámara de sensado donde el arreglo sensórico genera una señal por cada uno de los sensores dependiendo de la concentración y tipo de compuesto analizado, simultáneamente estas señales son adquiridas

por medio de un Microcontrolador que hace la respectiva conversión de análogo a digital para finalmente enviar los datos por medio del puerto serie a un PC. En esta etapa el Icarus evalúa los datos recibidos para la respectiva discriminación, generando una salida que indica el tipo de compuesto al que fue expuesto el arreglo sensorico. Todo el proceso se ilustra en la Figura 8 (c).

El objetivo principal de este sistema sensorico es la identificación de diferentes concentraciones de varios tipos de gases, de esta manera se planteo la evaluación de etanol y amoniaco en concentraciones de 100ppm² hasta 1000ppm, con el objetivo de identificar estas concentraciones se creó una red neuronal de cuatro entradas y dos capas (Figura 9), este arreglo es más que suficiente para garantizar una clasificación adecuada [8], sin embargo para determinar los parámetros óptimos de entrenamiento se realizo un diseño de experimentos factorial de 2³ con dos repeticiones por factor, teniendo en cuenta la concentración del gas, error de parada y taza de aprendizaje.




Figura 9. Esquema de la red neuronal implementada en Icarus.

Tabla 1. Diseño factorial de experimentos.

Red Neuronal	Concentración	Error de parada	Taza de aprendizaje
1	100-300ppm	5%	0.03
2	100-300ppm	5%	0.05
3	100-300ppm	10%	0.03
4	100-300ppm	10%	0.05
5	300-1000ppm	5%	0.03
6	300-1000ppm	5%	0.05
7	300-1000ppm	10%	0.03
8	300-1000ppm	10%	0.05

1) Ppm: Partes por millon.

En cada caso inicialmente fue necesaria la toma de 5 muestras para concentraciones de 100ppm, 300ppm y 1000ppm tanto para amoniaco como para etanol. Luego de tomadas las muestras se evaluó la correlación entre estas (Tabla 2), para establecer cual de todas las muestras contenía la mayor cantidad de información relevante para el entrenamiento, en cada caso se determino la correlación promedio y la de mayor valor nos dio la muestra a utilizar en el entrenamiento de la red neuronal para cada caso (Tabla 3).

Tabla 2. Correlación entre muestras de etanol.

	100ppm1	100ppm2	100ppm3	100ppm4	100ppm5
100ppm1	1	1,0000	0,9989	0,9996	0,9997
100ppm2	1,0000	1,0000	0,9992	0,9997	0,9997
100ppm3	0,9989	0,9992	1,0000	0,9994	0,9983
100ppm4	0,9996	0,9997	0,9994	1,0000	0,9988
100ppm5	0,9997	0,9997	0,9983	0,9988	1,0000

La evaluación de correlación entre muestras se realizo utilizando scatter plots los cuales proveen una visualización del grado de asociación o similitud entre variables, sin embargo los scatter plots son insuficientes en este caso ya que la cantidad de muestras por concentración es de 5, por lo cual se trabajo con una matriz de correlación. La matriz de correlación consiste en una combinatoria del grupo de muestras y la correlación entre cada una de estas, la cual es mucho mas apropiada que el uso de solo scatter plots, un ejemplo de esta matriz es la tabla II, en esta podemos observar la correlación entre cada una de las muestras correspondientes, este proceso se repitió para cada uno de los grupos de muestras es decir para 100ppm, 300ppm y 1000ppm de amoniaco y etanol.

Tabla 3. Correlación promedio entre muestras de etanol.

	100ppm1	100ppm2	100ppm3	100ppm4	100ppm5
Cantidad	5	5	5	5	5
Media	0,999633	0,999713	0,999159	0,999501	0,999284
Mediana	0,999705	0,999701	0,999224	0,999625	0,999676
StDev	4,560E-04	3,105E-04	6,389E-04	4,642E-04	7,285E-04

Para la evaluación del error de validación de la red neuronal se eligió de cada una de las muestras la que mayor diferencia mostrara con respecto a las demás con el fin de obtener la mejor visualización de la generalización de la red, en este

caso se utilizo la correlación promedio de cada una de las muestras con respecto a las demás. Utilizando cada una de las muestras y los parámetros específicos para cada caso se crearon un total de 8 redes neuronales, cada una entrenada para reconocer dos patrones (amoníaco o etanol) con dos muestras por patrón (100 y 300ppm o 300 y 1000ppm), cada una de ellas luego fue evaluada para concentraciones de 100ppm, 300ppm y 1000ppm.

Los resultados se pueden ver en las tablas 4 a 7, en cada una de ellas se puede observar los errores promedio para dos muestras en cada uno de los casos, en estas tablas se puede observar claramente como responde la red neuronal a diferentes concentraciones y con diferentes parámetros de entrenamiento como el error de parada y la tasa de aprendizaje.

Tabla 4. Evaluación etanol para redes 1 a 4.

		100-300ppm			
Concentraciones		Error de parada			
Etanol		5%		10%	
		Taza de aprendizaje		Taza de aprendizaje	
		0,03	0,05	0,03	0,05
100ppm		0,366628911	0,334912391	0,408689939	0,96266386
		1,644925227	0,249483034	1,655561001	0,5732545
300ppm		0,83316665	0,477894731	2,171807256	2,44162534
		0,491792077	1,007157829	2,715204428	1,94857509
1000ppm		2,34245728	1,904233953	4,116503239	4,03252283
		1,479118056	2,222182941	3,864193033	3,66817094
Media		1,193	1,032644147	2,489	2,271
Mediana		1,156	0,742526	2,444	2,195
StDev		0,763075	0,846550	1,394	1,399

Tabla 5. Evaluación etanol para redes 5 a 8.

		100-300ppm			
Concentraciones		Error de parada			
Etanol		5%		10%	
		Taza de aprendizaje		Taza de aprendizaje	
		0,03	0,05	0,03	0,05
100ppm		3,4953199	1,85895547	4,52275349	3,337786
		2,73228444	0,83710104	5,14909137	3,23071312
300ppm		1,66474794	0,23789703	1,44761807	0,49393117
		3,14624388	0,51586578	2,19846131	0,09728716
1000ppm		0,65261935	0,54350647	1,54196349	0,92044082
		0,36593852	1,19738711	1,7104815	1,0511199
Media		2,010	0,865119	2,762	1,522
Mediana		2,199	0,690304	1,954	0,985780
StDev		1,318	0,586126	1,639	1,406

Tabla 6. Evaluación amoniaco para redes 1 a 4.

Concentraciones	100-300ppm			
	Error de parada			
	5%		10%	
	Taza de aprendizaje		Taza de aprendizaje	
Amoniaco	0,03	0,05	0,03	0,05
100ppm	0,754646034	1,143363518	3,363487499	2,72823288
	3,261686266	1,494443889	3,363487499	3,29478206
300ppm	0,880737341	0,784498107	3,436172741	1,34369844
	0,778475251	0,100176816	2,77096935	0,97651215
1000ppm	6,677985222	6,294141329	9,201511526	9,68951466
	6,655842249	5,888328448	11,56069677	10,279485
Media	3,168	2,617	5,616	4,719
Mediana	2,071	1,319	3,400	3,012
StDev	2,873	2,733	3,773	4,172

Tabla 7. Evaluación amoniaco para redes 5 a 8.

Concentraciones	100-300ppm			
	Error de parada			
	5%		10%	
	Taza de aprendizaje		Taza de aprendizaje	
Amoniaco	0,03	0,05	0,03	0,05
100ppm	1,93924371	1,89173239	5,59390893	7,53605855
	2,55659582	2,27128703	6,88458681	6,27535296
300ppm	0,6731395	4,27413162	4,87641876	6,07232025
	2,01954939	4,12285887	5,0322067	6,07397483
1000ppm	3,03078428	3,36101227	3,12130202	1,89893979
	2,25086863	3,22940041	4,01250123	3,26506593
Media	2,078	3,192	4,920	5,187
Mediana	2,135	3,295	4,954	6,073
StDev	0,795366	0,959779	1,295	2,134

De las tablas 4 a 7 se puede observar que en cada uno de los casos de la evaluación es claro que no solo se evaluó a la concentración para la que la red fue creada sino también para una muestra fuera del rango, en el caso de las redes entre 100 y 300ppm se evaluó con 1000ppm y en el caso de 300 y 1000ppm se evaluó con 100ppm, es notable que en cada uno de los casos la red neuronal tuvo un error menor al 10% y esto nos indica que la generalización de la red es buena.

Los resultados del diseño factorial de experimentos nos indican (Figura 10) que trabajando con un error de parada del 5%, una velocidad de aprendizaje de 0.05 y muestras de entrenamiento de 300 y 1000ppm se obtienen los mejores resultados. Sin embargo cualquiera de las redes en realidad tiene respuestas muy buenas en cada caso y las diferencias entre si son menores al 1%. En la figura 10 se puede observar como la variación entre los errores generados en cada caso de evaluación son muy bajos además de que la variación entre estos es menor al 2% del error,

de lo cual podemos concluir que en general el comportamiento de una red neuronal para cualquiera de estas configuraciones es muy bueno y se ratifica la calidad de este tipo de sistemas para el reconocimiento de patrones.

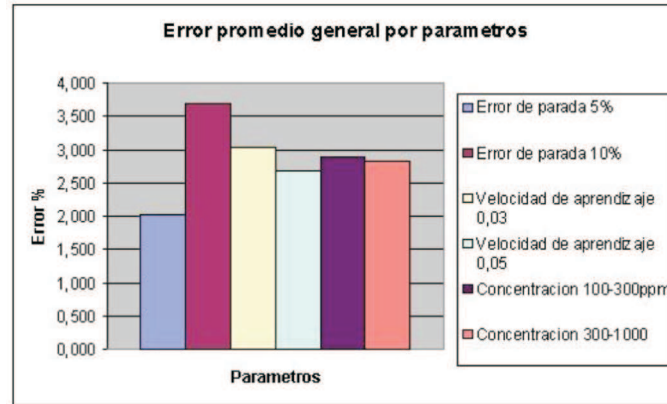


Figura 10. Desempeño promedio general por parámetros.

Con respecto al análisis de varianza del diseño de experimentos se pudo observar que en términos generales el factor concentración de solvente y error de parada afectan significativamente el valor del error de salida como se puede observar en el figura 11, lo cual es lógico para el error de parada.

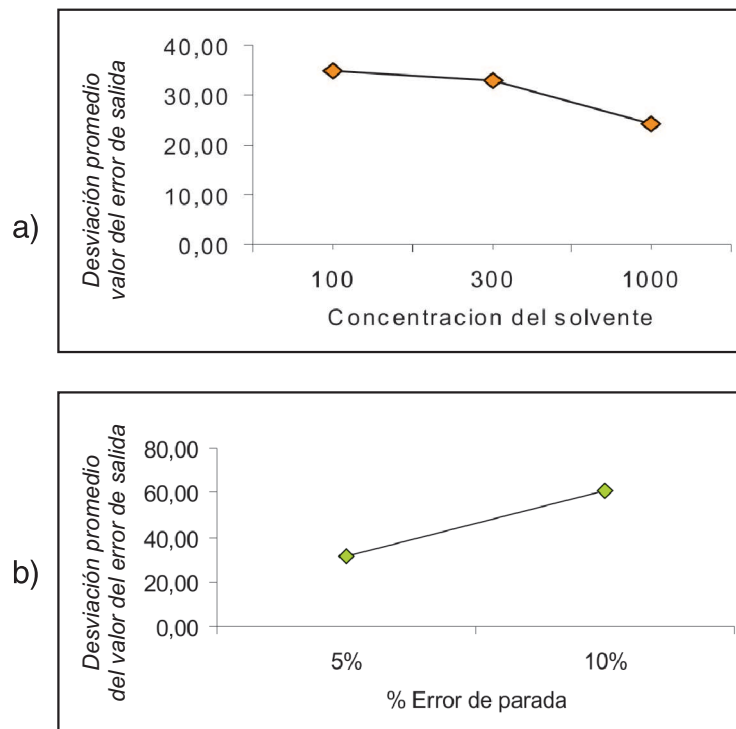


Figura 11. Análisis del valor del error de salida respecto a los factores a) concentración y b) error de parada.

Un punto importante y de consideración en este trabajo de investigación es no solo recalcar el buen desempeño de la red neuronal sino que esta además fue capaz de operar con sensores de estado sólido que normalmente no mantienen una señal completamente constante sino que es ruidosa como se puede observar en la Figura 12.




Figura 12. Inestabilidad de la señal generada por uno de los sensores.

Sin embargo, y aún cuando la variación es de ± 40 milivoltios el sistema logra identificar claramente cada uno de los gases a los que fue expuesto, sin requerir el uso de filtros y demás sistemas para el tratamiento de la señal, esto a su vez reduce costos y tiempo en la implementación de sistemas como los propuestos y mejora el tiempo de respuesta ya que la cantidad de elementos necesarios para la adquisición y reconocimiento de las señales generadas por el arreglo sensorico fue mínimo. Es importante recalcar que el funcionamiento de los sensores es no lineal tal y como se muestra en la figura 13, sin embargo las RNA no presentan problemas en la identificación de patrones de este tipo, lo cual es uno de los potenciales de usar este tipo de sistemas.




Figura 13. Voltaje vs concentración para cada sensor. En este gráfico se observa claramente la no linealidad de los sensores utilizados en el arreglo sensorico expuestos a diferentes concentraciones de etanol.

Icarus además de mostrar al usuario los resultados generados individualmente para cada neurona también muestra por medio de un aviso el tipo de gas identificado, de esta forma cualquier usuario sin conocimiento alguno sobre redes neuronales o sistemas sabría que el sistema esta reconociendo un determinado tipo de gas.

4. CONCLUSIONES Y PERSPECTIVA

En este trabajo se ha demostrado de manera satisfactoria la operación de un sistema de discriminación e identificación de vapores químicos aplicando arreglos sensoricos y redes neuronales como medio para identificación de los patrones.

Icarus puede ser entrenado para reconocer cualquier tipo de patrón mientras que éste sea procesado a través de un sistema de adquisición apropiado. Esta característica hace que el software sea de uso genérico en cualquier aplicación de reconocimiento y predicción para la cual sea entrenado. El software desarrollado tiene posibilidades de ser extendido y mejorado en muchos aspectos, en primer lugar se puede efectuar el aumento en la cantidad de canales de recepción para ampliar así su espectro de uso. Igualmente, se puede mejorar y optimizar el tiempo y cantidad de iteraciones mediante la implementación de técnicas que permitan la variación dinámica de parámetros como la tasa de aprendizaje. Actualmente dichos parámetros se consideran como constantes y no se actualizan durante el aprendizaje.

Nótese que en este caso no se incluyeron las condiciones atmosféricas bajo las cuales se trabajó con los sensores, tales como: humedad y temperatura, lo cual afecta la respuesta de los sensores para un día lluvioso a un día seco, sin embargo la red neuronal fue capaz de reconocer los gases a pesar de no haber sido entrenada para reconocer los gases en estas condiciones. Los resultados muestran claramente el potencial de la red neuronal implementada para operar con sistemas sensoricos altamente ruidosos y cambiantes como todos aquellos que involucran la medición de magnitudes físicas y químicas que se ven afectadas por su interacción con el medio ambiente.

AGRADECIMIENTOS

Los autores expresan su agradecimiento al personal de los laboratorios de Ingeniería de la Universidad Militar Nueva Granada (UMNG) por su colaboración en el desarrollo de las medidas experimentales. Este trabajo es financiado mediante el proyecto ING-004 (2006) de la UMNG. El trabajo de J. A. Ramos, es apoyado financieramente mediante el programa de Jóvenes Investigadores de la UMNG.

REFERENCIAS BIBLIOGRÁFICAS

- [1] BAUGHMAN and LYU, Y.A.; Neural Networks in Bioprocessing and Chemical engineering, Academic Press, 1995. (8)
- [2] CHERN LOH, Han; Fabrication, Characterisation and Optimisation of Novel Salicylic Acid Sensors Using Different Reagents and Artificial Neural Networks, 2005 Asian conference on sensors and the International Conference on New techniques in pharmaceutical and biomedical research proceedings, Septiembre 2005. (7)
- [3] GUTIERREZ-GALVEZ, A.; GUTIERREZ OSUNA, R. and RAMAN, B.; Pattern recognition for chemosensor arrays with the KIll model Department of Computer Science, Texas A&M University. (3)
- [4] HASHEM, Sherif; Neural Network based data analysis for chemical sensor arrays, Neural Network Applications Studies Workshop, IEEE Northcon/ Technical Applications Conference, Octubre 1995. (6)
- [5] HAYKIN, Symon; *Neural Networks a comprehensive foundation*, Prentice Hall, 1998. (10)
- [6] KOLKATA CENTRE, Centre for Development of Advanced Computing Electronic Nose for the evaluation of tea flavor, www.kolkatacdac.in, Junio 2006. (5)
- [7] KELLER, Paul E. Electronic Noses and their applications, IEEE Northcon/ Technical applications conference, 12 Octubre 1995. (9)
- [8] LOONEY, Carl G.; Pattern Recognition using Neural Networks, Oxford University Press, 1997. (2)
- [9] MALKI, H. A. and MOGHADDAMJOO, A.; Using the Karhunen-Loe've Transformation in the back-propagation training algorithm. IEEE Transactions on Neural Networks transactions, Vol 2 No1 pp 162-165 (1991). (11)
- [10] MINSKY, M. L. and PAPERT S. A.; *Perceptrons*, Cambridge, MA: MIT Press) 1969. (4)
- [11] SING-TZE, Bow; Pattern Recognition Image Preprocessing (2nd Edition), Marcel Dekker Incorporated Editors, 2002. (1)
- [12] TABARES, H.; BRANCH, J.; VALENCIA, J.; Generación dinámica de la topología de una red neuronal artificial del tipo perceptron multicapa. Revista No 38 Facultad de Ingeniería Universidad de Antioquia. pp 146 – 162, Septiembre de 2006. (12)

