

Sistema Evolutivo-Neuronal para Clasificar Unidades de Llanto Infantil para Identificar Patologías en Bebés Recién Nacidos

Orion Fausto Reyes-Galaviz¹, Carlos Alberto Reyes-García² y Sergio Daniel Cano-Ortiz³

¹Universidad Autónoma de Tlaxcala,
Apizaco, Tlaxcala, México.
orionfrg@ingenieria.uatx.mx

²Instituto Nacional de Astrofísica, Óptica Electrónica,
Tonantzintla, Puebla, México.
kargaxxi@inaoep.mx

³Universidad de Oriente de Cuba,
Santiago de Cuba, Cuba.
scano@fie.uo.edu.cu

Paper received on 11/08/08, accepted on 07/09/08.

Resumen. Este trabajo presenta el desarrollo de un identificador automático de llanto infantil, el cual tiene como objetivo clasificar dos tipos de llantos de bebés recién nacidos; normales y patológicos. Se utiliza la extracción de características acústicas por medio de MFCC (Coeficientes Cepstrales de Frecuencia Mel, por sus siglas en inglés), los cuales se obtienen del sonido de las ondas de Unidades de Llanto, y para la clasificación se utiliza un sistema genético para la selección de características combinado con una red neuronal de alimentación hacia adelante (Feed-Forward) con retraso en el tiempo, entrenada por medio de un algoritmo de aprendizaje adaptable por retro propagación del error. Para los experimentos, se utilizan grabaciones de llantos Cubanos y Mexicanos, tratando de clasificar los llantos patológicos y normales en tres experimentos diferentes: Bebés Cubanos, Bebés Mexicanos y Todas las muestras (Mixtos). También se muestra una comparación entre una red neuronal tradicional simple de alimentación hacia adelante y otra complementada con el sistema de selección genético de características, aplicado a la reducción de los vectores de entrada. En este artículo se describe parte del proceso; en el cual se incluye la extracción de características, implementación, entrenamiento y prueba. Los resultados de algunos experimentos también se muestran, en donde el rango de reconocimiento de llanto infantil, llega hasta un 100% al usar el sistema genético.

1 Introducción

El sonido de llanto producido por un infante es el resultado de su condición física y sicológico y/o de estimulaciones internas/externas. Se ha probado que el llanto producido por dolor, hambre, miedo, estrés, etc. muestran diferentes patrones en la onda de llanto. Una madre experimentada puede ser capaz de reconocer ciertas particularidades entre diferentes tipos de llanto, y con esto, reaccionar adecuadamente a

©M. G. Medina Barrera, J. F. Ramírez Cruz, J. H. Sossa Azuela. (Eds.).
Advances in Intelligent and Information Technologies.
Research in Computing Science 38, 2008, pp.3 -15.



las necesidades de su infante. Los expertos en neurolingüística consideran al llanto infantil como la primera manifestación del llanto. Es la primera experiencia de la producción de sonidos, el cual es seguido por movimientos dentro de la laringe y la cavidad oral. Todo esto, combinado con la retroalimentación de la capacidad auditiva, será usado en un futuro para la producción de fonemas. Este trabajo se enfoca en grabaciones de bebés normales y patológicos, nacidos en México y Cuba. Los casos patológicos son de bebés sordos y sufriendo algún tipo de asfixia. Los niños con pérdida auditiva, los cuales son identificados antes de los 6 meses de edad, han mostrado un mejoramiento significativo en el desarrollo del habla, comparándolos con aquellos cuya pérdida auditiva ha sido descubierta después de los 6 meses de edad. En el caso de los infantes que han sufrido un periodo de asfixia en su nacimiento, ellos están expuestos a cambios en un nivel neurológico, dependiendo del nivel y tiempo de asfixia que hayan pasado. De acuerdo con la Academia Americana de Pediatría (AAP, por sus siglas en inglés), de 2 a 6 de 1000 bebés recién nacidos presentan un caso de asfixia y el 60% de los bebés que nacen prematuramente y que presentan bajo peso, también sufren de un periodo de asfixia. De estos, 20 al 50% mueren durante los primeros días de vida. De los sobrevivientes, el 25% desarrolla secuelas neurológicas permanentes.

2 Estado del Arte

Recientemente, se han hecho diversas investigaciones en análisis de llanto de bebés; los cuales muestran resultados prometedores, y acentúan la importancia de explorar este campo. En [1], Reyes & Orozco clasificaron muestras de bebés normales y sordos, ellos obtuvieron resultados que van desde 79.05% hasta 97.43%. Petroni usó redes neuronales para diferenciar llanto de dolor o sin dolor [2]. Tako Eekel trató de clasificar sonidos de llantos de bebés recién nacidos en dos categorías, normal y anormal o hipoxia, el cual es ocasionado por bajos niveles de oxígeno en la sangre, y reportó un resultado de clasificación correcta de 85%, basándose en una red neuronal de base radial [3]. También, usando algoritmos de mapas auto-organizados, Cano et al, en [4] reportó varios experimentos para clasificar unidades de llanto infantil de bebés normales y patológicos, en estos experimentos ellos extrajeron 12 características directamente de las frecuencias de la onda de sonido, en cada una de las muestras, obteniendo un porcentaje de reconocimiento del 85%.

3 Proceso de Reconocimiento Automático del Llanto

El proceso de reconocimiento automático de llanto (Fig. 1) es básicamente un problema de reconocimiento de patrones, y es similar al de reconocimiento del habla. En nuestro caso, la meta es tomar la onda de llanto de un bebé como entrada, y al final obtener el tipo de llanto o patología detectada. Generalmente, el proceso de reconocimiento de llanto se hace en dos pasos, el primer paso es el procesamiento acústico, o extracción de características, mientras que el segundo se conoce como el de procesamiento de patrones o clasificación de patrones. En el sistema propuesto, se ha añadido un paso extra entre ambos procesos, llamado la selección de carac-

terísticas. Para este caso, en el análisis acústico, la señal de llanto se procesa para primero eliminar los períodos de silencio de la onda de sonido original, para mantener solamente las unidades de llanto, y después de estas, extraer las características relevantes en función del tiempo. El conjunto de características obtenido de cada muestra de unidad de llanto es representado por un vector, cada vector se toma como un patrón.

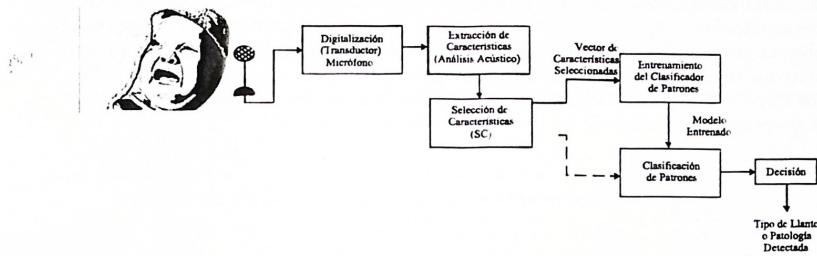


Fig. 1. Proceso de Reconocimiento de Llanto Infantil

Después, todos los vectores pasan por un módulo de selección de características acústicas, el cual nos ayudará a seleccionar las mejores características para el proceso de entrenamiento, y al mismo tiempo reducir eficientemente los vectores de entrada. La selección se hace por medio del uso de estrategias evolutivas. Mientras que para los métodos de reconocimiento de patrones, se han utilizado tradicionalmente cuatro métodos principales: comparación de patrones, modelos estadísticos, sistemas basados en conocimiento, y modelos conexionistas. Este trabajo se enfoca en el uso de este último.

4 Procesamiento Acústico

El análisis acústico implica la aplicación y selección de técnicas de filtrado, extracción de características, segmentación de señal y normalización. Con la aplicación de estas técnicas, se trata de describir la señal en términos de sus componentes fundamentales. Una señal de llanto es compleja y codifica más información de la necesaria para ser analizada y procesada en aplicaciones de tiempo real. Por esta razón, en el sistema de reconocimiento de llanto, usamos una función de extracción de características como un procesador de primer plano. La entrada es una señal de llanto, y en la salida se obtiene un vector de características que contienen elementos clave de la onda de sonido del llanto. Se han experimentado con diversos tipos de características acústicas [1], enfatizando por su utilidad a los coeficientes cepstrales de frecuencia Mel (MFCC).

4.1 Segmentación de Unidades de Llanto

Sergio Cano et al [4] propuso la Segmentación de Unidades de Llanto, la cual consiste de una unidad respiracional (o unidades) extraídas de una sola muestra de llanto (Fig. 2). Con este método, si una muestra tiene tres unidades de llanto, se pueden extraer estas tres muestras y excluir el silencio contenido en la grabación original. Estas unidades de llanto fueron extraídas manualmente una por una, en muestras de llanto seleccionadas por su claridad, duración y número de unidades de llanto contenidas. Una vez extraídas las unidades de llanto, y tomando en cuenta que para obtener vectores del mismo tamaño, las muestras deben tener la misma duración, se tuvo que dividir cada unidad de llanto en segmentos de 0.4 segundos, esta duración fue elegida al considerar el tamaño de duración de la unidad de llanto más pequeña, después de su extracción de las muestras originales.



Fig. 2. Proceso de Selección y Segmentación de las Unidades de Llanto

4.2 Coeficientes Cepstrales de Frecuencia Mel

Hay una amplia variedad de formas de representar las muestras de habla en su forma paramétrica. Una de las más comúnmente usadas en tareas de reconocimiento del habla son los MFCCs. El oído humano descompone las señales de sonido recibidas en sus frecuencias fundamentales. Localizado en el oído interno encontramos la cóclea la cual tiene una forma espiral cónica. Esta es una de las tres cavidades que forman la estructura física del oído [5]. La cóclea filtra las frecuencias en una forma natural. Las ondas de sonido se introducen dentro de esta estructura chocando en sus paredes y llegando dentro del espiral con frecuencia alta o baja, tomando en cuenta la longitud de onda de cada frecuencia [6]. Los MFCCs están basados en la respuesta de frecuencia que el oído humano percibe. Este método se comporta como un banco de filtros linealmente distribuidos en bajas frecuencias y con espaciado logarítmico en frecuencias altas. Esta es llamada la escala de frecuencia Mel, la cual es lineal por debajo de los 1000 Hz, y logarítmica sobre 1000 Hz (Fig. 3) [7].

5 Clasificación de Patrones de Llanto

El conjunto de características acústicas obtenido en la fase de extracción, generalmente se representa como un vector, y cada vector puede ser tomado como un patrón. Estos vectores son después usados para hacer la selección de las características acústicas y el proceso de clasificación. Para el presente trabajo, se usó un clasificador que corresponde al tipo de modelos conexionistas conocidos como Redes Neuronales. Estas están resforzadas con estrategias evolutivas para seleccionar las características y mejorar su proceso de aprendizaje. Obteniendo como resultado un sistema híbrido Genético-Neuronal.

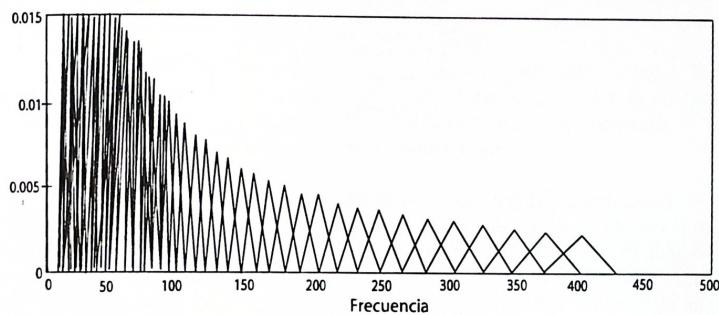


Fig. 3. Escala de Frecuencia Mel

5.1 Estrategias Evolutivas

Las estrategias evolutivas se proponen para resolver problemas continuos de una manera eficiente. Su nombre se deriva de la palabra alemana *Evolutionstrategien*, por lo que podemos verlas descritas como *ES*. Originalmente era un método escalado estocástico (en otras palabras, que siguen la gradiiente), esto al usar pasos adaptables. Pero con el tiempo se ha convertido en uno de los algoritmos evolutivos más poderosos, el cual da buenos resultados a problemas paramétricos en dominios reales. Las estrategias evolutivas realizan búsquedas mas exploratorias que los algoritmos genéticos [9].

El principal operador de reproducción en las estrategias evolutivas es la mutación, en donde un valor aleatorio es añadido a elementos aleatoriamente seleccionados de un individuo para crear un nuevo descendiente [10]. La selección de padres para formar descendientes es menos estricta que en los algoritmos genéticos y la programación genética.

5.2 Redes Neuronales

En un estudio de DARPA [11] las redes neuronales son definidas como sistemas compuestos de muchos elementos de procesamiento simple, que operan en paralelo

y cuya función es determinada por la estructura de la red, la fuerza de sus conexiones, y el procesamiento llevado a cabo por los elementos de procesamiento o nodos. Se puede entrenar una red neuronal para que ejecute una función en particular, ajustando los valores de las conexiones (pesos) entre los elementos (nodos). Generalmente, las redes neuronales se ajustan o se entrena para que una entrada en particular lleve a una salida específica o deseada. Como se muestra en la Figura 4, la red es ajustada basada en la comparación entre la salida actual y la deseada, hasta que la salida de la red iguale la salida deseada [12].

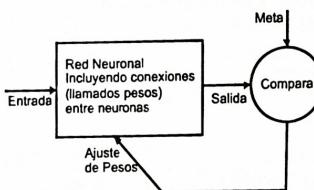


Fig. 4. Entrenamiento de una Red Neuronal.

Generalmente, el entrenamiento de una red neuronal puede ser supervisado o no supervisado. Los métodos de un entrenamiento supervisado son aquellos usados cuando existen muestras etiquetadas. Entre los modelos más populares están las redes Feed-Forward (de alimentación hacia adelante), entrenadas bajo supervisión con un algoritmo de retro-propagación. Para el presente trabajo, se usa una variación de estos modelos básicos, el cual se describe más adelante.

5.3 Red Neuronal Feed-Forward con Retraso en el Tiempo

Los datos del llanto no son estáticos, y cualquier muestra de llanto, en cualquier instante del tiempo, es dependiente de los patrones de llanto que existan antes y después de aquel instante en el tiempo. Una falla común en el algoritmo tradicional de retro propagación es que no toma esto en cuenta. Weibel et al idealizó una solución a este problema [15] al proponer una nueva arquitectura de red llamada la *Red Neuronal con Retraso en el Tiempo* o TDNN (por sus siglas en inglés). La principal característica de las TDNN es los retrasos en el tiempo de los nodos. Cada retraso en el tiempo se conecta con un nodo a través de su propio peso, y representa valores de entrada en instantes anteriores en el tiempo. Las TDNN también se conocen como *Redes Neuronales con Entrada Retrasada* ya que las entradas de la red neuronal son las que se retrasan en el tiempo. Si se retrasa la señal de entrada una unidad de tiempo, y dejamos que la red reciba ambas señales, la original y la retrasada, se obtiene una red neuronal con retraso en el tiempo simple. Por supuesto, se puede construir una más compleja al retrasar la señal en distintos instantes. Si la señal de entrada es de n bits y se retrasa en m diferentes instantes, entonces debe haber nm unidades de entrada que codificarán la entrada total [12].

5.4 Gradiente Descendiente con Retro-Propagación por Rango de Aprendizaje Adaptable

El entrenamiento por gradiente descendiente con retro-propagación por rango de aprendizaje adaptable, propuesto para este proyecto, puede ser aplicado a cualquier red siempre y cuando sus pesos, la entrada de la red, y las funciones de transferencia tengan funciones derivables. La retro-propagación se usa para calcular derivadas de desempeño, con respecto a las variables de los pesos y del bias. Cada variable es ajustada de acuerdo a la descendiente en gradiente. En cada época de entrenamiento, si el desempeño se reduce hacia la meta, entonces el rango de aprendizaje se incrementa. Si el desempeño incrementa, el rango de aprendizaje se ajusta por medio de un factor de reducción y el cambio, el cual incrementó el desempeño, no se hace [13].

El entrenamiento termina cuando ocurren cualquiera de estas condiciones: *i*) El número máximo de épocas (ciclos) es alcanzado, *ii*) La cantidad máxima de tiempo ha sido excedida o *iii*) El error de desempeño ha sido minimizado al establecido.

5.5 Sistema Híbrido

El sistema híbrido fue diseñado para entrenar la red neuronal con retraso en el tiempo con las mejores características seleccionadas de los vectores de entrada. Para realizar esta selección, se aplicó Estrategias Evolutivas, las cuales usan números reales para codificar a los individuos.

Si cada vector, que representa una muestra de llanto, contiene 300 características y son 1000 muestras, se obtiene una matriz de entrada de 300×1000 . Si esto se quiere reducir a solo 50 características, la información contenida en cada individuo será de 50 números aleatorios del 1 al 300, sin repetirse, cada uno de estos números corresponde a la fila de una característica de todas las muestras. El sistema recibe las muestras originales como entrada, las reduce de acuerdo a cada individuo y busca, por medio de técnicas evolutivas, las filas que entrena mejor una red neuronal. Al final, se obtiene el individuo que indicará qué características específicas muestran el mejor resultado global, y se logra una reducción en las matrices de entrenamiento/prueba de 50×1000 . Se puede encontrar más información sobre el diseño y la implementación de este algoritmo en [17].

6 Implementación del Sistema para la Clasificación de Llanto

Como primer paso, los llantos de los bebés se obtienen por medio de grabaciones obtenida directamente de doctores del Instituto Nacional de la Comunicación Humana (INCH), el Instituto Mexicano de Seguro Social (IMSS) en Puebla, México, y el Grupo de Procesamiento de Voz (GPV) en la Universidad de Oriente (UO), con la ayuda del Hospital Materno Sur en Santiago de Cuba, Cuba. Las muestras de llanto son etiquetadas con el tipo de llanto que el recolector menciona al final de cada grabación de la misma. Después, se divide cada grabación de llanto en Unidades de Llanto, las cuales después son segmentadas en muestras de 0.4 segundos; estos

segmentos son después etiquetados con un código preestablecido previamente [16], y cada uno representa una muestra.

De esta forma, para los experimentos de este trabajo, se obtiene un corpus de 334 muestras de bebés normales; 180 de bebés mexicanos y 154 de bebés cubanos, y 549 de bebés patológicos; 410 de bebés mexicanos y 139 de bebés cubanos. Todos estos de muestras de 0.4 segundos. Ambos corpus fueron usados para experimentos separados, como se explica en breve. Después las muestras se procesan una por una, extrayendo las características acústicas MFCC. este proceso se hace automáticamente con la ayuda del programa de distribución libre Praat 4.2 [14]. La características acústicas se extraen de la siguiente manera: para cada muestra se extraen 16 coeficientes por cada ventana de 50 milisegundos, los cuales generan vectores de 112 características por cada muestra de 0.4 segundos, se pierde una ventana ya que existe una compensación cada 16 milisegundos. El algoritmo evolutivo fue diseñado y programado en Matlab 7.0 R14, la red neuronal y el algoritmo de entrenamiento fue implementado por medio de la caja de herramientas de redes neuronales de Matlab. [13]. Para este trabajo, se hicieron 3 experimentos diferentes:

- Solo bebés cubanos,
- Solo bebés mexicanos, y
- Bebés cubanos & Mexicanos.

Para poder comparar el comportamiento de sistema híbrido propuesto, se hicieron un conjunto de experimentos, donde los vectores originales son usados si ninguna reducción de dimensionalidad, y después se reducen a 50 componentes por medio de Análisis de Componente Principal (PCA, por sus siglas en inglés), para más resultados comparativos. Cuando se usan las estrategias evolutivas para la selección de características acústicas (reducción de dimensionalidad), se buscan las mejores 10, 12, 30, 40 y/o 50 características, estos diferentes experimentos mostrarán la robustez del sistema propuesto, y el experimento de 12 seleccionar características fue propuesto para comparar los resultados con trabajos previos [4]. Si n es el número de características seleccionadas (tamaño de cada individuo), Componentes Principales (PC, por sus siglas en inglés), o tamaño del vector original, entonces la arquitectura de la red neuronal se compone de n nodos en la capa de entrada, una capa oculta de 60% nodos menos que la capa de entrada, y una capa de salida de 2 nodos, que corresponden a las dos clases propuestas, llanto patológico o normal, esta arquitectura fue decidida de manera heurística. El sistema implementado se adapta interactivamente, permitiéndonos probar con cualquier dimensionalidad.

El entrenamiento se hace hasta 1000 épocas o hasta que se alcance un error de 1×10^{-6} . Una vez que la red es entrenada, la probamos con muestras que se separan previamente para este propósito, generalmente se separan 70% de las características para entrenar el sistema y 30% para probarlo. Posteriormente se muestra la precisión de reconocimiento.

7 Resultados Experimentales

Se experimentó primero con una red neuronal simple, a la cual le alimentamos los vectores originales, después los vectores reducidos a 50 PCs, ya que este número de PCs mostró buenos resultados en experimentos previos [1], [16], y finalmente con el sistema híbrido para comparar los resultados obtenidos. En todos los experimentos se usa 1 unidad de retraso en el tiempo.

En el caso del sistema simple de redes neuronales, se realizaron 3 experimentos y seleccionamos el mejor. Para el sistema híbrido, para buscar la mejor solución en un espacio de múltiples soluciones, solo se realizó un experimento. Esto se hace porque se inicializan 15 individuos en la población inicial, 20 generaciones para efectuar la búsqueda de características, y el tamaño de cada individuo fue de 10, 12, 30, 40 y 50 cromosomas. Con todos estos parámetros de entrada, se realizan 300 procesos de entrenamiento, y se elige el mejor resultado global, por lo cual se toma mucho más tiempo en realizar cada experimento. Los resultados se muestran en la Tabla 1, donde la segunda columna corresponde a los resultados obtenidos de llanto de bebés cubanos, la tercera a bebés mexicanos y la última columna muestra los resultados obtenidos al usar las muestras de ambos, mexicanos y cubanos.

Tabla 1. Resultados usando ambos corpus, entrenando una red neuronal simple y usando vectores originales y reducidos por PCA

Experimento	Bebés Cubanos	Bebés Mexicanos	Bebés Mixtos
Vectores Orig.	77.38%	100%	86.5%
Vect. de 50 PCs	75%	100%	86.5%

En la Tabla 2, se pueden ver los resultados al usar 10, 12, 30, 40 y 50 características seleccionadas con la ayuda del sistema híbrido. La única diferencia en los experimentos es que, en el primer caso, donde la reducción se hace con PCA, la reducción de los vectores se realiza antes del cualquier procesamiento con la red neuronal. Mientras que en el segundo caso, la selección de características se hace de manera concurrente con el entrenamiento de las redes neuronales. Debido a esto, se presenta al modelo propuesto como un sistema híbrido evolutivo-neuronal.

Tabla 2. Resultados obtenidos al usar ambos corpus, aplicando el sistema híbrido con diferente selección de características

Experimento	Bebés Cubanos	Bebés Mexicanos	Bebés Mixtos
10 Características	76.19%	96.29%	86%
12 Características	76.19%	98.14%	88.06%
30 Características	82.61%	100%	90.29%
40 Características	83.92%	100%	90.58%
50 Características	91.07%	100%	92%

8 Conclusiones y Trabajos Futuros

La aplicación de métodos de selección de características, en diferentes tipos de tareas de reconocimiento, se ha vuelto una herramienta alternativa viable. Particu-

larmente para aquellas tareas que tienen que enfrentarse con vectores de entrada de grandes dimensiones. Como se ha demostrado, el uso de estrategias evolutivas para la selección de características acústicas, en el problema de clasificación de llanto infantil, ha permitido no solo trabajar con vectores reducidos sin perder la precisión de clasificación, pero también ayuda a mejorar los resultados, comparando con aquellos obtenidos al aplicar PCA. Además, cuando se combinan los llantos de bebés cubanos con los mexicanos, los resultados también se mejoran, y las redes neuronales se mantienen consistentes con ambos corpus.

Para trabajos futuros, y para poder mejorar el desempeño del sistema evolutivo-neuronal descrito, se plantea realizar más experimentos utilizando otras configuraciones de redes neuronales, un número más grande de individuos, y más generaciones. También se sigue en busca de modelos más adecuados que puedan optimizar dinámicamente los parámetros del modelo híbrido, esto para poder adaptarlo a cualquier tipo de aplicaciones de reconocimiento de patrones.

En cuanto al problema de reconocimiento de unidades de llanto infantiles, se va a seguir experimentando con diferentes tipos de sistemas híbridos, tales como modelos híbridos que seleccionen instancias y características, ensamble de redes neuronales de impulso (boosting) y ensambles de máquinas de soporte vectorial. Y una vez que aseguremos que nuestro sistema es bastante robusto para identificar las patologías mencionadas, se incrementará el corpus de llanto infantil con el mismo tipo u otro tipo de patologías. Particularmente aquellas relacionadas con el sistema nervioso central (SNC). Esto se hace primeramente porque con más muestras de llanto de bebés patológicos de cualquier parte del mundo, se puede implementar un sistema más confiable para ese tipo de patologías, tales como asfixia y sordera. En segunda, porque al añadir llanto de bebés con otras patologías, podemos dirigir un diagnóstico temprano para identificar tales patologías.

Referencias

1. Orozco Garcia, J., Reyes Garcia, C.A. (2003), Mel-Frequency Cepstrum coefficients Extraction from Infant Cry for Classification of Normal and Pathological Cry with Feedforward Neural Networks, ESANN 2003, Bruges, Belgium.
2. Marco Petroni, Alfred S. Malowany, C. Celeste Johnston, Bonnie J. Stevens, (1995). Identification of pain from infant cry vocalizations using artificial neural networks (ANNs), The International Society for Optical Engineering. Volume 2492. Part two of two. Paper #: 2492-79.
3. Ekkel, T. (2002). "Neural Network-Based Classification of Cries from Infants Suffering from Hypoxia-Related CNS Damage", Master's Thesis. University of Twente, The Netherlands.
4. Sergio D. Cano, Daniel I. Escobedo y Eddy Coello, "El Uso de los Mapas Auto-Organizados de Kohonen en la Clasificación de Unidades de Llanto Infantil", Voice Processing Group, 1st Workshop AIRENE, Universidad Católica del Norte, Chile, 1999, pp 24-29.
5. Balagüe A. J. Diccionario Encyclopédico Baber. Editorial Baber, 1119 E. Broadway Street Glendale, California 91205. (1991).
6. Bernal J., Bobadilla J., Gómez P. Reconocimiento de voz y fonética acústica. Ed. Alfaomega Ra-Ma, Madrid, España. (2000).
7. Miramontes de León G., De la Rosa Vargas J. I. and Garcáa E. Application of an Annual/Sphere Search Algorithm for Speaker Recognition. Proceedings of the 15th Interna-

- tional Conference on Electronics, Communications and Computers. 0-7695-2283-1/05 IEEE. CONIELECOMP, (2005).
- 8. Gold, B., Morgan, N. (2000), Speech and Audio Signal Processing. Processing and perception of speech and music. John Wiley & Sons, Inc.
 - 9. Santo Orcero, David. Estrategias Evolutivas. <http://www.orcero.org/irbis/disertacion/node217.html>. 2004
 - 10. Hussain, Talib S., An Introduction to Evolutionary Computation, Department of Computing and Information Science Queens University, Kingston, Ont. K7L 3N6. 1998.
 - 11. DARPA Neural Network Study, AFCEA International Press, 1988, p. 60.
 - 12. Limin Fu., Neural Networks in Computer Intelligence. McGraw-Hill International Editions, Computer Science Series, 1994.
 - 13. Neural Network Toolbox Guide, Matlab V.6.0.8. Developed by MathWoks, Inc.
 - 14. Boersma, P., Weenink, D. Praat v. 4.0.8. A system for doing phonetics by computer. Institute of Phonetic Sciences of the University of Amsterdam. February, 2002.
 - 15. A. Weibel, T. Hanazawa, G. Hinton, K. Shikano, and K.J. Lang, "Phoneme Recognition Using Time Delay Neural Networks," IEEE Trans. Acoustics, Speech, Signal Proc., ASSP-37: 32'339, 1989.
 - 16. Orion F. Reyes Galaviz. "Clasificación de Llanto de Bebés para Identificación de Hipocúscia y Asfixia por medio de un Sistema Híbrido (Genético – Neuronal)" Master's Thesis on Computer Science, at the Apizaco Institute of Technology (ITA), March, 2005. <http://solar6.ingenieria.uatx.mx/~orionfrg/tesis.pdf>
 - 17. Orion F. Reyes Galaviz, Carlos A. Reyes Garcia "Infant Cry Classification to Identify Hypoacoustics and Aphyxia Comparing an Evolutionary-Neural System with a Simple Neural Network System" en MICAI 2005. Monterrey Mexico, noviembre14-18, 2005. Lecture Notes on Artificial Intelligence 3789. ISBN 3-540-29896-7 ISSN 302-9743.