

PAQUETES DE ONDITAS EVOLUTIVAS PARA CLASIFICACIÓN DE SEÑALES

L. Gamero, L. Rufiner

CONICET – Universidad Nacional de Entre Ríos, Fac. de Ing. Bioingeniería, CC 57, Suc. 3, Paraná (CP 3100), ER, Argentina (E-mail: {lgamero, lrufiner}@alpha.arcrude.edu.ar)

RESUMEN:

Los paquetes de onditas (WP) son considerados una extensión al clásico análisis multiresolución (MRA) propuesto por Mallat. El MRA ha sido ampliamente utilizado en el procesamiento de señales no estacionarias. Si bien el análisis mediante WP es más flexible que el MRA, uno de los inconvenientes es la selección de la base de funciones para resolver algún problema en particular. Los algoritmos genéticos (GA) y la programación evolutiva (EP) han demostrado ser de gran utilidad en la solución de problemas complejos de optimización. En este trabajo se presenta un programa evolutivo, que permite encontrar la mejor base para la clasificación de señales. Resultados sobre señales artificiales y un conjunto reducido de fonemas, muestran las posibilidades de este método.

ALABRAS CLAVES:

análisis multiresolución, paquetes de onditas, algoritmos genéticos, clasificación, reconocimiento de patrones.

1. INTRODUCCIÓN

La transformada de Fourier de tiempo corto (STFT) ha sido una de las primeras alternativas orientada al análisis de señales no estacionarias. Sin embargo, la transformada de onditas (WT) es una herramienta con características especialmente aptas para el análisis de señales transitorias [1, 2]. El análisis multiresolución llevado a cabo por la WT, permite una descomposición jerárquica de la señal, proporcionando información en un plano tiempo-escala [2]. Este análisis puede ser implementado eficientemente mediante una estructura en bancos de filtros [3] y ha sido ampliamente utilizado en aplicaciones tales como: compresión, eliminación de ruido, caracterización de singularidades y detección de no estacionariedades en el análisis de señales e imágenes [2].

Recientemente, se ha desarrollado una nueva transformada: los paquetes de onditas [4]. Esta transformada puede ser vista como una extensión

al análisis multiresolución y permite mayor flexibilidad en la selección de las bandas de frecuencia. Sin embargo, queda abierta la pregunta de cual es la mejor base para determinadas aplicaciones. Para resolver este inconveniente, se han desarrollado varios algoritmos orientados principalmente al área de compresión de señales, como el algoritmo de la mejor base (BB) [4, 5]. Relativamente pocos son los trabajos orientados a la clasificación de señales [6], donde lo importante es obtener una base que permita “discriminar” mejor entre los diferentes patrones o señales.

Uno de los objetivos de este trabajo es extender los resultados obtenidos en problemas del reconocimiento del habla mediante el análisis multiresolución a los paquetes de onditas. El problema se reduce a encontrar una base adecuada a los efectos de maximizar algún criterio de clasificación. Este artículo se organiza de la siguiente forma. A continuación se presenta una breve descripción los fundamentos teóricos de los WP y de los GA. Luego se introduce el método propuesto para la selección de la base de funciones orientada a problemas de clasificación de señales. Posteriormente se presentan y se discuten los resultados obtenidos mediante simulación numérica de ejemplos de aplicación a señales artificiales y de voz. Finalmente, las conclusiones del trabajo.

2. FUNDAMENTOS

2.1. Paquetes de onditas

Los paquetes de onditas constituyen bases ortonormales en R^N y pueden verse como una generalización del análisis multiresolución [4, 5]. Esto se debe a que incluye las funciones base del MRA y las de la STFT. El análisis mediante paquetes de onditas permite generar particiones en el plano tiempo-escala con mayor flexibilidad, y a partir de un conocimiento a priori de la señal es posible aprovechar estas características para obtener

una representación eficiente en el dominio transformado.

2.2. Algoritmos genéticos

Los algoritmos genéticos y la programación evolutiva, constituyen un paradigma relativamente reciente y bastante poderoso [7, 8]. Holland [9] propuso los algoritmos genéticos como una técnica computacional que intenta imitar el proceso evolutivo de la naturaleza, para el diseño de sistemas artificiales adaptativos. Las aplicaciones más importantes de estos han sido en problemas de optimización, búsqueda y aprendizaje automático. Los algoritmos genéticos clásicos, manipulan una población de soluciones potenciales codificadas en cadenas binarias que representan las soluciones. El conjunto de cadenas representan el material genético de una población de individuos. Los operadores de selección, cruzamiento y mutación artificiales, son aplicados para buscar los mejores individuos o las mejores soluciones a través de la simulación del proceso evolutivo natural. Cada solución potencial se asocia con un valor de aptitud (fitness), que mide el desempeño de una solución comparada con las otras de la población. Este valor de aptitud es la simulación del papel que juega el ambiente en la evolución natural.

Cuando se aplican a problemas particulares, los GA, deben sufrir modificaciones para mejorar su desempeño y eficiencia. Se modifica la representación de las soluciones y los nuevos operadores se definen en función del problema. En este caso, en que el algoritmo se adapta al problema, hablamos de los EP.

3. IMPLEMENTACIÓN

Para resolver nuestro problema se utiliza un EP (WPEP), debido a la complejidad que implica codificar las soluciones de manera binaria.

Cada solución o individuo de la población, está dada por un árbol de filtros diádico (paquete de onditas), que se representa como un vector de números enteros (cromosoma). La longitud de cada cromosoma es variable, dependiendo del número de niveles de filtrado y con un máximo de niveles fijado de antemano.

Para generar la población inicial de individuos que requiere el EP, se ha empleado un método que permite crear un conjunto aleatorio de paquetes de

onditas válidos. Para ello, se parte de un conjunto de semillas a las cuales se las muta un número aleatorio de veces. De esta manera se asegura que el conjunto final corresponda a bases realizables debido a que el operador de mutación es cerrado. Las semillas iniciales son de tres tipos: dirac, cuasi-Gabor y cuasi-Fourier; esto asegura cierta uniformidad en la distribución de los árboles generados dentro del rango posible para el número de niveles dado.

Existen varias funciones que podrían utilizarse para evaluar la capacidad de discriminación de la base. Entre ellas pueden citarse la extensión de la entropía para problemas de clasificación, distintas medidas de distancia entre los centroides de las clases, o algún clasificador supervisado. En este trabajo se utiliza esta última opción debido a que refleja el comportamiento de la base en un caso cercano al de aplicación final. Esto implica un alto costo computacional debido a que se debe entrenar una red neuronal cada vez que se evalúa el desempeño de un individuo. La red utilizada fue un perceptrón multicapa de estructura fija. Los pesos y sesgos de cada red no se guardan entre generaciones.

El algoritmo propuesto emplea como función de aptitud la función de evaluación del algoritmo de retropropagación, es decir la suma normalizada del cuadrado de los errores sobre el conjunto de entrenamiento (MSE). Otra alternativa sería el porcentaje de aciertos, sin embargo esta medida funciona bien solo en el caso de contar con muchos patrones.

El EP, utilizó el operador de selección proporcional, el cual se implementó con el método de la rueda de ruleta. El operador de cruzamiento y el de mutación se diseñaron para producir siempre soluciones posibles (cerrados), ya que los operadores tradicionales darían lugar, en la mayoría de los casos, a árboles imposibles. A continuación se describen los operadores empleados.

3.1. Operador de cruzamiento

Inicialmente se propone un punto de cruce en uno de los padres, y se busca la existencia del nivel y rama correspondiente en el otro. En el caso de no existir este punto en común se continua buscando durante un número determinado de veces. Si se encuentra coincidencia se intercambian las estructuras de los arboles a partir de este punto. De lo contrario la cruce no se lleva a cabo.

3.2. Operador de mutación

Para aplicar este operador se procede de la siguiente forma: se elige al azar un gen para mutar (que corresponde a un nodo terminal del árbol), y en forma aleatoria se procede a podar o crecer este nodo en forma repetida un número aleatorio de veces. Para ello se utiliza una función que determina si un individuo representa un árbol válido. Este tipo de mutación genera individuos cuyo grado de parecido con el inicial depende de la cantidad de veces que se itere el proceso.

4. RESULTADOS Y DISCUSIÓN

El tamaño de la población fue para todas las corridas de 16 individuos. La probabilidad de cruzamiento que permitió obtener los mejores resultados fue de 0.9, con una probabilidad de mutación de 0.1. El número de generaciones varió entre 400 y 1400 dependiendo de la aptitud lograda.

4.1. Señales simuladas

En este experimento se pretende clasificar 5 señales que consisten en tonos puros modulados mediante funciones gaussianas. En la figura 1 se muestran las señales y el plano tiempo frecuencia para el mejor individuo. En la tabla I se muestran los resultados promedio del MSE producido por un perceptrón entrenado para la clasificación de las señales analizadas por las bases de dirac, Fourier, Onditas (MRA) y la base óptima encontrada por el WPEP.

4.2. Señales de voz

Se presenta una aplicación en la clasificación de un conjunto reducido de fonemas de un mismo hablante. Los datos fueron frames individuales seleccionados de la base de datos TIMIT [10]. En la figura 2 se muestra la evolución del fitness para 500 generaciones y el árbol de filtros para el mejor individuo. En la tabla II se muestran otra vez los resultados promedio comparativos del MSE para distintas bases.

5. CONCLUSIONES

En este trabajo se ha presentado un método que permite hallar la base óptima para la clasificación de un conjunto de señales. Como se puede apreciar, los resultados de los experimentos demuestran un mejor desempeño del clasificador luego de procesar las señales con la base elegida por el WPEP. Esto se debe a que esta base permite separar más fácilmente a las señales facilitando la tarea del clasificador. Debe tenerse en cuenta que la función

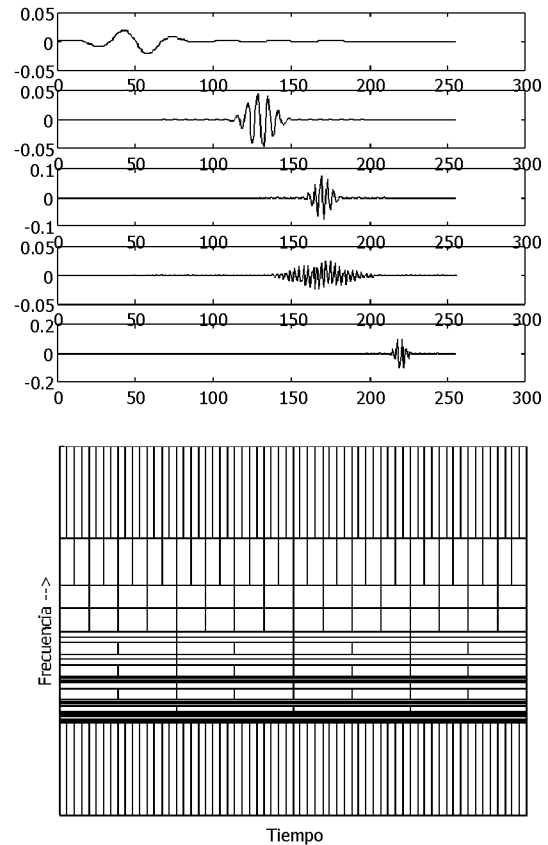


Figura 1: Señales Ejemplo 1 y partición generada por el algoritmo propuesto.





Figura 2: Evolución de la Aptitud y árbol generado para el ejemplo 2.

sinc(i) Research Center for Signals, Systems and Computational Intelligence (fich.unl.edu.ar/sinc)
 L. G. Gámero & H. L. Rufiner; "Paquetes de onditas evolutivas para clasificación de señales"
 Anales del I Congreso Latinoamericano de Ingeniería Biomédica Mazatlán 98, Vol. I, pp. 784-787, 1998.

Tabla I. MSE de los ejemplos estudiados, comparando con Dirac, Fourier y Wavelet (diádica).

<i>BASE</i>	<i>Ejemplo 1</i>	<i>Ejemplo 2</i>
<i>Dirac</i>	0.3893±0.0885	0.3132±0.1601
<i>Fourier</i>	0.3645±0.0655	0.5999±0.1381
<i>Wavelet</i>	0.3356±0.0684	0.2645±0.1299
<i>WPEP</i>	0.2377±0.0748	0.2285±0.1330

Valores expresados como valor medio ± desvío estándar.

de aptitud utilizada es estocástica por lo que se debe correr varias veces el algoritmo y seleccionar la mejor de todas las corridas. Un inconveniente del método presentado es el alto costo computacional que se requiere para encontrar la solución. Sin embargo es posible optimizar el rendimiento mediante la redefinición de los operadores o de la función de fitness. En trabajos futuros se abordarán problemas más complejos de clasificación y se explorará la extensión del algoritmo a problemas de compresión y filtrado.

Agradecimientos

Este trabajo fue realizado con el apoyo de la Universidad Nacional de Entre Ríos y CONICET (Argentina).

REFERENCIAS

- [1] C. K. Chui, An introduction to Wavelets. Volume 1 of "Wavelet Analysis and its Applications". Academic Press Inc., 1992.
- [2] S. G. Mallat, "A theory of multiresolution of signal decomposition: the wavelet representation", IEEE Trans. Pattern Anal. Machine Intell., vol. PAMI-11, no. 7, pp. 674-693, 1989.
- [3] O. Rioul, M. Vetterli, "Wavelets and Signal Processing", IEEE Signal Proc. Mag., Oct., 1991.
- [4] R. R. Coifman, M. V. Wickerhauser, "Entropy-based algorithms for best basis selection", IEEE Transactions on Information Theory, vol. 38, no. 2, pp. 713-718, 1992.
- [5] M. V. Wickerhauser, "Adapted Wavelet Analysis from Theory to Software". A K Peters, Ltd., Wellesley, Massachusetts, 1994.
- [6] R. E. Learned, A. S. Willsky, "A Wavelet Packet approach to transient signal clasification", Applied and Comp. Harmonic Anal., vol. 2, pp. 265-278, 1995.
- [7] D. E. Goldberg, "Genetic Algorithms in Search, Optimization, and Machine Learning". Addison-Wesley, 1989.
- [8] Z. Michalewicz, "Genetic Algorithms+Data Structures = Evolution Programs". Springer-Verlag, 1992.
- [9] J. H. Holland, "Adaptation in Natural and Artificial System". University of Michigan Press, Ann Arbor, 1975.
- [10] Garofolo, Lamel, Fisher, Fiscus, Pallett, Dahlgren, "DARPA TIMIT Acoustic-Phonetic Continuous Speech Corpus Documentation. National Institute of Standards and Technology, 1993.