

7 Líneas futuras

En cuanto a los resultados obtenidos en la reconstrucción de señales sparse tanto en el dominio del tiempo como en el dominio de la frecuencia, es interesante comentar el tiempo de ejecución de los algoritmos MP y OMP programados en Matlab en este proyecto. A pesar de los buenos resultados obtenidos al reconstruir señales utilizando estos algoritmos y de que éstos no requieren de elevados recursos de cálculo, las simulaciones realizadas requieren de un elevado tiempo de ejecución, que aumenta en función de la longitud de la señal original y del nivel de escasez de la misma. Por lo que se propone para futuros estudios de la teoría del Compressive Sensing su implementación en otros lenguajes de programación tales como C o C++.

También es interesante comentar los resultados obtenidos en la reconstrucción de señales con ruido aleatorio gaussiano aditivo, tanto en el dominio del tiempo como en el dominio de la frecuencia, para los que se obtuvieron resultados similares. Hemos podido observar que las reconstrucciones de señales sparse con ruido aditivo producen un error bastante elevado que depende de la relación señal a ruido (disminuyendo el error a medida que disminuye la potencia del ruido, es decir a medida que aumenta la SNR). Se propone como estudio futuro una mejora de los algoritmos programados para la reconstrucción de señales con ruido aditivo en ambos dominios, tiempo y frecuencia.

Además de los algoritmos propuestos, Matching Pursuit y Orthogonal Matching Pursuit, existe otro algoritmo iterativo de reconstrucción de señales sparse que no se ha presentado en este proyecto y que también se podría desarrollar con el fin de compararlo con los algoritmos desarrollados, MP y OMP. El algoritmo en cuestión se denomina Regularized Orthogonal Matching Pursuit, ROMP. Este algoritmo es básicamente igual al OMP, la única diferencia entre ambos algoritmos es que en el ROMP se introduce un paso de regularización. En este paso se escogen los k átomos del diccionario holográfico que más parecido guardan con el residuo, luego este conjunto de átomos va a ser dividido en varios subconjuntos que cumplan una cierta condición. Al introducir esta condición lo que se busca es escoger un subconjunto de átomos en el cual cada átomo aporte una contribución a la definición del conjunto de mediciones parecida a la que aporta cada uno de los otros átomos del subconjunto. En cada iteración se introducirá más de un átomo a la nueva matriz de proyección, como consecuencia de esto en cada iteración se obtendrá una mejor estimación de la señal que la que se encontraba al utilizar OMP, reduciendo significativamente el número de iteraciones. Debido a que el OMP en cada iteración escoge el átomo del diccionario holográfico que más contribuya a la definición de la señal proyectada son necesarias k iteraciones para poder recuperar

la señal, sin embargo al introducir el paso de regularización se logra disminuir considerablemente el número de iteraciones.

En cuanto a las aplicaciones de la teoría del Compressive Sensing, se incluye como línea futura para la continuación de su estudio, la aplicación a la reconstrucción de imágenes, denominado en el apartado anterior como Compressive Imaging (CI) y desarrollado por Wakin y Baraniuk, entre otros [20]. Se propone el desarrollo del equipo para la realización del concepto de CI que consta de una cámara de un solo píxel que combina un gran espejo microcontrolador (que muestra una secuencia temporal de m bases pseudo aleatorias ϕ_m de la imagen), con un único sensor óptico para calcular las proyecciones $y(m)$ de la imagen. A continuación se emplearían estas proyecciones de la imagen como vector de mediciones y en la ejecución de los algoritmos de reconstrucción estudiados, MP y OMP, para obtener así un estimado de la imagen.