

UNIVERSIDAD NACIONAL
AUTÓNOMA DE MEXICO

FACULTAD DE INGENIERÍA
DIVISIÓN DE ESTUDIOS DE
POSGRADO

“Evaluación del Desempeño de Algoritmos de
Identificación de Patrones Alternantes Cíclicos (CAPs)
en Señales EEG de Sueño”

Edgar Ulises Ledesma Rojas

Director de Tesis: Dr. Rogelio Alcántara Silva.

Mayo 2006.



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Dedicatoria

Dedico este trabajo a las tres personas más importantes en mi vida. Como un pequeño agradecimiento a su amor, esfuerzo, sacrificio, paciencia y ayuda: Dr. Luis Evaristo Ledesma Pavía, Sra. Ma. Magdalena Rojas Yépez e Ing. Ariana Moreno Bautista.

Agradecimientos

Agradezco:

A mi tutor y amigo el Dr. Rogelio Alcántara Silva quien ha sabido orientarme en todo momento y por ser un modelo a seguir.

A la Dra. Rosa María Campos Morales del laboratorio de trastornos del dormir por su amistad y apoyo en la realización de este trabajo.

A Todos mis profesores quienes a través de su experiencia y conocimientos adquirí las herramientas necesarias para enfrentar al mundo profesional.

A todos aquellos que de manera directa o indirecta participaron en este trabajo.

Y principalmente a la Universidad Nacional Autónoma de México por los conocimientos y valores que me inculcó.

Resumen

En este trabajo se abordó el problema de clasificación del sueño bajo el nuevo paradigma de clasificación conocido como: Patrón Alternante Cíclico, CAP (Cyclic Alternating Pattern). El paradigma CAP es una nueva estrategia de clasificación basada en la identificación de patrones conocidos de la señal de EEG (arousals) que se repiten de manera cíclica durante la noche. Para esta identificación, se implementaron algoritmos de análisis temporal como el análisis estadístico, el análisis de potencia y la función de autocorrelación; así mismo, se implementaron algoritmos de análisis frecuencial mediante el modelado autorregresivo de la señal eeg y la obtención de parámetros de un modelo RLS; por otro lado, se implementaron tres algoritmos tiempo - frecuencia: distribución Wigner Ville, distribución Choi - Williams, distribución Bessel; y finalmente se implementaron dos algoritmos tiempo - escala: la transformada Haar y la Transformada Daubechies 4. Todos estos algoritmos fueron comparados en su desempeño de acuerdo al tiempo de cálculo en una computadora con procesador Xeon© de 3 GHz con 1 GB de memoria y de acuerdo a dos parámetros propuestos por Lima y Rosa; [29]: La identificación correcta de la secuencias CAP y la concordancia entre la identificación automática y la identificación visual. Se destaca el hecho que no existe una diferencia significativa en el desempeño de los algoritmos en base a la identificación correcta de secuencias CAP y la concordancia de identificación visual y automática, siendo esta diferencia entre algoritmos del 1.99 % para la identificación correcta y de 0.68 % para la concordancia. Los resultados son los siguientes: El análisis mediante métodos estadísticos obtuvo un 84.4 % de identificación de secuencias CAP, con 92.2 % de concordancia, en 0.53 segundos por secuencia. Con el método de análisis de potencia logramos un 84.5 % de identificación con 92.3 % de concordancia, en 0.38 segundos por secuencia. En lo que se refiere al análisis de secuencias CAP mediante coeficientes de autocorrelación, obtuvimos el 83.5 % identificado con 91.8 % de concordancia en 0.51 segundos por secuencia. El análisis basado en el modelo autorregresivo fue dividido en 2 partes, en la primera se analizaron los coeficientes del modelo con ayuda de la distancia geométrica; en este punto se consiguió un 82.2 % de secuencias identificadas con 91.1 % de concordancia en 0.43 segundos por secuencia; el otro análisis se realizó mediante la distancia espectral, aquí obtuvimos un 83.1 % de secuencias identificadas y 91.6 % de concordancia en 0.5 segundos por secuencia. En lo que se refiere a la estimación de parámetros de la secuencia CAP mediante el uso del algoritmo RLS, se logró el 83.9 % de secuencias identificadas con el 90.7 % de concordancia en 0.24 segundos por secuencia. Pasando a los métodos tiempo - frecuencia reportamos que para la transformada corta de Fourier (SFT) el porcentaje de detección correcta fue del 88.0 % con 94.0 % de concordancia

en 0.56 segundos por secuencia. La distribución Wigner Ville arrojó un 85.0 % de secuencias identificadas y un 92.5 % de concordancia en 7.24 segundos por secuencia. Con la distribución Choi - Williams logramos el 84.6 % de secuencias identificadas con 92.3 % de concordancia en 277.45 segundos por secuencia. Finalmente, en lo referente a los algoritmos tiempo frecuencia, mediante el uso de la distribución Bessel conseguimos el 84.5 % de identificación correcta con 92.7 % de concordancia en 76.28 segundos por secuencia. Por último, los algoritmos tiempo - escala nos reportaron los siguientes resultados. La transformada Haar consiguió un 84.5 % de secuencias identificadas de manera correcta con 92.3 % de concordancia en 1.04 segundos por secuencia, mientras que la transformada Daubechies 4 consiguió un 84.2% identificado con 92.2 % de concordancia en 1.34 segundos por secuencia. En base a lo anterior concluimos que el algoritmo más adecuado en base a tiempo de cálculo y porcentaje de concordancia e identificación correcta es el espectrograma, aunque sacrificando un poco el desempeño en cuanto a porcentajes de secuencias correctas y concordancia, el algoritmo adecuado para un sistema reducido es el algoritmo de análisis de potencia.

Índice general

Resumen	IV
Glosario	XVI
Introducción	1
1. Generalidades del Encefalograma	4
1.1. Clasificación del EEG	4
1.1.1. Beta	4
1.1.2. Alfa	5
1.1.3. Teta	5
1.1.4. Delta	5
1.2. Técnicas de registro	6
1.3. Conclusiones	7
2. El Sueño, Clasificación Clásica y sus Nuevas Tendencias	8
2.1. Fases del sueño	9
2.2. Macro estructura del sueño	10
2.3. Micro estructura del sueño: El Patrón Alternante Cíclico (CAP)	11
2.4. Conclusiones	14
3. Algoritmos de Análisis e Interpretación de Secuencias CAP	15
3.1. Estimación de la respuesta de la corteza del encéfalo	16
3.2. Función de Correlación	16
3.2.1. Función de Autocorrelación	17
3.3. Modelo Autorregresivo de la señal EEG	17
3.4. Modelo de generación de la señal EEG	21
3.4.1. Estimación de Ganancias mediante Máxima Verosimilitud	22
3.4.2. Estimación de ganancias mediante el Error Cuadrático Medio	25
3.5. Estimación de parámetros del modelo de generación de EEG mediante algoritmo RLS	29
3.6. Representaciones tiempo - frecuencia (TFR)	32
3.6.1. Espectrograma	33

3.6.2.	Distribuciones de la Clase de Cohen	35
3.6.3.	Distribución Wigner - Ville	35
3.6.4.	Distribución Choi - Williams	36
3.6.5.	Distribución Bessel	38
3.7.	Transformadas tiempo - escala	39
3.7.1.	Haar	40
3.7.2.	Daubechies	40
3.8.	Análisis de secuencias CAP en el Plano tiempo - frecuencia	41
3.9.	Conclusiones	41
4.	Implementación de Algoritmos para la Identificación de Secuencias CAP (ISCAP)	43
4.1.	Método	44
4.2.	Señales Sintéticas de EEG	44
4.2.1.	Simulación de señales	47
4.2.2.	Estimación de la respuesta de la corteza cerebral	52
4.3.	Identificación de secuencias CAP mediante potencia	53
4.4.	Identificación de secuencias CAP mediante Estadísticas temporales	54
4.5.	Identificación de secuencias CAP mediante coeficientes de Correlación	57
4.6.	Identificación de secuencias CAP mediante el Modelo de generación de EEG	62
4.7.	Identificación de secuencias CAP mediante Modelo Autorregresivo	64
4.8.	Caracterización de secuencias CAP mediante cambio en coeficientes FIR usando RLS	69
4.9.	Identificación de secuencias CAP mediante métodos tiempo - frecuencia	74
4.9.1.	Espectrograma	74
4.9.2.	Wigner - Ville	75
4.9.3.	Choi - Williams	77
4.9.4.	Bessel	79
4.10.	Identificación de secuencias CAP mediante métodos tiempo - escala	82
4.10.1.	Haar	82
4.10.2.	Daubechies	86
4.11.	Binarización	88
4.12.	Índices para la evaluación de los resultados	96
4.13.	Conclusiones	98
5.	Evaluación de los Algoritmos ISCAP	99
5.1.	Identificación de secuencias CAP mediante análisis de potencia	100
5.2.	Identificación de secuencias CAP mediante Estadísticas temporales	103
5.3.	Identificación de secuencias CAP mediante coeficientes de Correlación y distancia de Chebyshev	106
5.4.	Identificación de secuencias CAP mediante Modelo Autorregresivo y distancia espectral	109

5.5. Identificación de secuencias CAP mediante Modelo Autorregresivo y distancia geométrica	112
5.6. Identificación de secuencias CAP mediante parámetros RLS	115
5.7. Identificación de secuencias CAP mediante espectrograma	118
5.8. Identificación de secuencias CAP mediante Distribución Wigner - Ville	123
5.9. Identificación de secuencias CAP mediante Distribución Choi William	128
5.10. Identificación de secuencias CAP mediante Distribución Bessel	133
5.11. Identificación de secuencias CAP mediante Transformada Haar	138
5.12. Identificación de secuencias CAP mediante transformada Daubechies 4	143
5.13. Resumen de Resultados	148
Conclusiones	149
Bibliografía	152

Índice de figuras

1.1. Señal Beta	5
1.2. Señal Alfa	5
1.3. Señal Teta	5
1.4. Señal Delta	6
1.5. Sistema internacional 10-20	7
2.1. Ejemplo de CAP	11
2.2. Jerarquía del paradigma CAP	13
3.1. Arriba: Señal EEG Cortical Estimada. Abajo: EEG registrado	16
3.2. Modelo EEG, [33]	21
3.3. Modelo para la extracción de características de la señal EEG , [40]	23
3.4. Modelo Inverso reordenado[40]	25
3.5. Teorema de proyección en 2 dimensiones	26
3.6. Identificación del modelo RLS del cerebro	30
3.7. Señal compuesta por senoidales a 20hz y 10hz	32
3.8. Espectro de la señal compuesta por senoidales a 20hz y 10hz	33
3.9. Espectrograma de una señal compuesta por frecuencias de 20hz y 10hz	34
3.10. Espectrograma 3D de una señal compuesta por frecuencias de 20hz y 10hz	35
3.11. Artefactos en Distribución Wigner - Ville para una señal compuesta por frecuencias de 20hz y 10hz	36
3.12. Distribución Wigner - Ville de señal compuesta por frecuencias de 20hz y 10hz	37
3.13. Distribución Choi - Williams de señal compuesta por frecuencias de 20hz y 10hz	37
3.14. Eliminación de los términos de cruce con la Distribución Choi - Williams	38
3.15. Distribución Bessel de señal compuesta por frecuencias de 20hz y 10hz	39
3.16. Distribución Bessel 3D de señal compuesta por frecuencias de 20hz y 10hz	39
4.1. Selección del Orden Modelo AR en nuestro trabajo	45
4.2. Respuesta en frecuencia. Izquierda: Alfa, Derecha: Beta	46
4.3. Respuesta en frecuencia. Izquierda: Delta, Derecha: Teta	47
4.4. Señal Alfa Sintética	48
4.5. Señal Beta Sintética	49
4.6. Señal Teta Sintética	50

4.7. Señal Delta Sintética	51
4.8. Espectro señal MOR	52
4.9. Detección CAP por potencia	53
4.10. Señal EEG original y Señal EEG filtrada 7Hz a 25Hz	55
4.11. Procesamiento CAP mediante estadísticas temporales	55
4.12. Resultado de la detección CAP mediante estadísticas temporales	56
4.13. Señal EEG	57
4.14. Secuencia Alfa real extraída de 4.13	58
4.15. Secuencia Alfa Sintética	58
4.16. Secuencia de autocorrelación de la señal alfa real y alfa sintética. Distancia = 0.4467	59
4.17. Secuencia de autocorrelación de la señal alfa real y beta sintética. Distancia = 0.8731	59
4.18. Distancias de Chebyshev entre CA de los segmentos de EEG y CA de ritmos Alfa, Beta, Delta, y Teta	60
4.19. Identificación de la secuencia CAP utilizando CA con distancia de Chebyshev	61
4.20. Modelo Extracción de características EEG , [40]	62
4.21. k_i obtenidos mediante el modelo de la figura(4.20)	63
4.22. Detección de CAP mediante k_i mostrados en la figura(4.21)	63
4.23. Señal EEG filtrada en cada banda	64
4.24. Identificación de secuencias CAP en cada banda de la señal mediante Modelo Autorregresivo usando distancia geométrica.	67
4.25. Identificación de secuencias CAP mediante Modelo Autorregresivo usando distancia geométrica.	67
4.26. Identificación de secuencias CAP en cada banda de la señal mediante Modelo Autorregresivo usando distancia espectral.	68
4.27. Identificación de secuencias CAP mediante Modelo Autorregresivo usando distancia espectral.	68
4.28. Espectrograma mediante coeficientes RLS	70
4.29. Distancia geométrica entre coeficientes RLS	71
4.30. Distancia de Chebyshev entre coeficientes RLS	71
4.31. Distancia media cuadrática entre coeficientes RLS	72
4.32. Identificación de la secuencia CAP mediante los coeficientes RLS	72
4.33. Identificación de la secuencia CAP mediante los coeficientes RLS	73
4.34. Espectrograma Ventana=50 Traslape=45	75
4.35. Representación de una señal EEG en tiempo, frecuencia y su Distribución Wigner - Ville N=1024; NPF=1024	76
4.36. Distribución Wigner - Ville N=1024; NPF=1024	77
4.37. Representación de una señal EEG en tiempo, frecuencia y su Distribución Choi - Williams N=1024 M=1024 $\sigma=40$ NPF=1024	78
4.38. Distribución Choi - Williams N=1024 M=1024 $\sigma=40$ NPF=1024	79

4.39. Representación de una señal EEG en tiempo, frecuencia y su Distribución Bessel $N=1024$ $\alpha=0.5$ $NPF=1024$	80
4.40. Bessel $N=1024$ $\alpha=0.5$ $NPF=1024$	81
4.41. Escalograma Transformada Haar	83
4.42. Escalograma Transformada Haar	84
4.43. Descomposición mediante Transformada Haar	85
4.44. Función Onduleta Madre Daubechies; [11]	86
4.45. Escalograma Transformada Daubechies 4	86
4.46. Descomposición de la señal EEG mediante trasformada Daubechies 4	87
4.47. Identificación CAP mediante trasformada Daubechies 4	87
4.48. Función escalamiento a 256 niveles de gris	88
4.49. Izquierda: Espectrograma 256 niveles de gris secuencia CAP, Derecha: Histograma	89
4.50. Izquierda: Distribución Wigner - Ville 256 niveles de gris secuencia CAP, Derecha: Histograma	89
4.51. Izquierda: Distribución Choi - Williams 256 niveles de gris secuencia CAP, Derecha: Histograma	90
4.52. Izquierda: Distribución Bessel 256 niveles de gris secuencia CAP, Derecha: Histograma	90
4.53. Izquierda: Escalograma con haar 256 niveles de gris secuencia CAP, Derecha: Histograma	91
4.54. Izquierda: Escalograma con Daubechies 4 256 niveles de gris secuencia CAP, Derecha: Histograma	91
4.55. Espectrograma binarizado con un umbral de 187	92
4.56. Distribución Wigner - Ville binarizada con un umbral de 114	92
4.57. Distribución Choi - Williams binarizada con un umbral de 70	93
4.58. Distribución Bessel binarizada con un umbral de 53	93
4.59. Contorno del espectrograma binarizado	94
4.60. Contorno de la distribución Wigner - Ville binarizada	95
4.61. Contorno de la distribución Choi - Williams binarizada	95
4.62. Contorno de la distribución Bessel binarizada	96
4.63. Definición de parámetros de evaluación de algoritmos	97
5.1. Izquierda: Identificación análisis potencia secuencia CAP 1, Derecha: Identificación análisis potencia secuencia CAP 2	100
5.2. Izquierda: Identificación análisis potencia secuencia CAP 5, Derecha: Identificación análisis potencia secuencia CAP 6	100
5.3. Izquierda: Identificación análisis potencia secuencia CAP 7, Derecha: Identificación análisis potencia secuencia CAP 9	101
5.4. Izquierda: Identificación análisis potencia secuencia CAP 12, Derecha: Identificación análisis potencia secuencia CAP 13	101

5.5. Izquierda: Identificación análisis potencia secuencia CAP 14, Derecha: Identificación análisis potencia secuencia CAP 15	102
5.6. Izquierda: Identificación Est. temporales secuencia CAP 1, Derecha: Identificación Est. temporales secuencia CAP 2	103
5.7. Izquierda: Identificación Est. temporales secuencia CAP 5, Derecha: Identificación Est. temporales secuencia CAP 6	103
5.8. Izquierda: Identificación Est. temporales secuencia CAP 7, Derecha: Identificación Est. temporales secuencia CAP 9	104
5.9. Izquierda: Identificación Est. temporales secuencia CAP 12, Derecha: Identificación Est. temporales secuencia CAP 13	104
5.10. Izquierda: Identificación Est. temporales secuencia CAP 14, Derecha: Identificación Est. temporales secuencia CAP 15	105
5.11. Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 1, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 2	106
5.12. Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 5, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 6	106
5.13. Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 7, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 9	107
5.14. Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 12, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 13	107
5.15. Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 14, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 15	108
5.16. Izquierda: Identificación AR-Dist. Espectral secuencia CAP 1, Derecha: Identificación AR-Dist. Espectral secuencia CAP 2	109
5.17. Izquierda: Identificación AR-Dist. Espectral secuencia CAP 5, Derecha: Identificación AR-Dist. Espectral secuencia CAP 6	109
5.18. Izquierda: Identificación AR-Dist. Espectral secuencia CAP 7, Derecha: Identificación AR-Dist. Espectral secuencia CAP 9	110
5.19. Izquierda: Identificación AR-Dist. Espectral secuencia CAP 12, Derecha: Identificación AR-Dist. Espectral secuencia CAP 13	110
5.20. Izquierda: Identificación AR-Dist. Espectral secuencia CAP 14, Derecha: Identificación AR-Dist. Espectral secuencia CAP 15	111
5.21. Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 1, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 2	112
5.22. Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 5, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 6	112
5.23. Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 7, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 9	113
5.24. Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 12, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 13	113
5.25. Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 14, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 15	114

5.26. Izquierda: Identificación RLS secuencia CAP 1, Derecha: Identificación RLS secuencia CAP 2	115
5.27. Izquierda: Identificación RLS secuencia CAP 5, Derecha: Identificación RLS secuencia CAP 6	115
5.28. Izquierda: Identificación RLS secuencia CAP 7, Derecha: Identificación RLS secuencia CAP 9	116
5.29. Izquierda: Identificación RLS secuencia CAP 12, Derecha: Identificación RLS secuencia CAP 13	116
5.30. Izquierda: Identificación RLS secuencia CAP14, Derecha: Identificación RLS secuencia CAP 15	117
5.31. Izquierda:Espectrograma secuencia 1 NPF=256; ventana=50. Derecha: Identificación CAP umbral=170	118
5.32. Izquierda:Espectrograma secuencia 2 NPF=256; ventana=50. Derecha: Identificación CAP umbral=220	118
5.33. Izquierda:Espectrograma secuencia 5 NPF=256; ventana=50. Derecha: Identificación CAP umbral=178	119
5.34. Izquierda:Espectrograma secuencia 6 NPF=256; ventana=50. Derecha: Identificación CAP umbral=178	119
5.35. Izquierda:Espectrograma secuencia 7 NPF=256; ventana=50. Derecha: Identificación CAP umbral=160	120
5.36. Izquierda:Espectrograma secuencia 9 NPF=256; ventana=50. Derecha: Identificación CAP umbral=230	120
5.37. Izquierda:Espectrograma secuencia 12 NPF=256; ventana=50. Derecha: Identificación CAP umbral=160	121
5.38. Izquierda:Espectrograma secuencia 13 NPF=256; ventana=50. Derecha: Identificación CAP umbral=180	121
5.39. Izquierda:Espectrograma secuencia 14 NPF=256; ventana=50. Derecha: Identificación CAP umbral=230	122
5.40. Izquierda:Espectrograma secuencia 15 NPF=256; ventana=50. Derecha: Identificación CAP umbral=230	122
5.41. Izquierda:Distribución Wigner - Ville secuencia 1 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=114	123
5.42. Izquierda:Distribución Wigner - Ville secuencia 2 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=141	123
5.43. Izquierda:Distribución Wigner - Ville secuencia 5 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=160	124
5.44. Izquierda:Distribución Wigner - Ville secuencia 6 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=135	124
5.45. Izquierda:Distribución Wigner - Ville secuencia 7 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=100	125
5.46. Izquierda:Distribución Wigner - Ville secuencia 9 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=160	125

5.47. Izquierda:Distribución Wigner - Ville secuencia 12 NPF=1024; N=32; NPT=1024.	
Derecha: Identificación CAP umbral=160	126
5.48. Izquierda:Distribución Wigner - Ville secuencia 13 NPF=1024; N=32; NPT=1024.	
Derecha: Identificación CAP umbral=165	126
5.49. Izquierda:Distribución Wigner - Ville secuencia 14 NPF=1024; N=32; NPT=1024.	
Derecha: Identificación CAP umbral=145	127
5.50. Izquierda:Distribución Wigner - Ville secuencia 15 NPF=1024; N=32; NPT=1024.	
Derecha: Identificación CAP umbral=145	127
5.51. Izquierda:Distribución Choi - Williams secuencia 1 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=114	128
5.52. Izquierda:Distribución Choi - Williams secuencia 2 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=100	128
5.53. Izquierda:Distribución Choi - Williams secuencia 5 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=140	129
5.54. Izquierda:Distribución Choi - Williams secuencia 6 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=100	129
5.55. Izquierda:Distribución Choi - Williams secuencia 7 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=70	130
5.56. Izquierda:Distribución Choi - Williams secuencia 9 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=90	130
5.57. Izquierda:Distribución Choi - Williams secuencia 12 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=110	131
5.58. Izquierda:Distribución Choi - Williams secuencia 13 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=130	131
5.59. Izquierda:Distribución Choi - Williams secuencia 14 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=110	132
5.60. Izquierda:Distribución Choi - Williams secuencia 15 M=1024; N=1024; NPF=1024; $\sigma=40$. Derecha: Identificación CAP umbral=100	132
5.61. Izquierda:Distribución Bessel secuencia 1 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=53	133
5.62. Izquierda:Distribución Bessel secuencia 2 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=125	133
5.63. Izquierda:Distribución Bessel secuencia 5 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=165	134
5.64. Izquierda:Distribución Bessel secuencia 6 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=115	134
5.65. Izquierda:Distribución Bessel secuencia 7 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=90	135
5.66. Izquierda:Distribución Bessel secuencia 9 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=110	135
5.67. Izquierda:Distribución Bessel secuencia 12 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=140	136

5.68. Izquierda:Distribución Bessel secuencia 13 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=160	136
5.69. Izquierda:Distribución Bessel secuencia 14 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=130	137
5.70. Izquierda:Distribución Bessel secuencia 15 M=1024; N=1024; NPF=1024; NPT=1024; $\alpha=0.5$. Derecha: Identificación CAP umbral=100	137
5.71. Izquierda: Escalograma Haar secuencia 1 , Derecha: Identificación CAP . . .	138
5.72. Izquierda: Escalograma Haar secuencia 2 , Derecha: Identificación CAP . . .	138
5.73. Izquierda: Escalograma Haar secuencia 5 , Derecha: Identificación CAP . . .	139
5.74. Izquierda: Escalograma Haar secuencia 6 , Derecha: Identificación CAP . . .	139
5.75. Izquierda: Escalograma Haar secuencia 7 , Derecha: Identificación CAP . . .	140
5.76. Izquierda: Escalograma Haar secuencia 9 , Derecha: Identificación CAP . . .	140
5.77. Izquierda: Escalograma Haar secuencia 12 , Derecha: Identificación CAP . .	141
5.78. Izquierda: Escalograma Haar secuencia 13 , Derecha: Identificación CAP . .	141
5.79. Izquierda: Escalograma Haar secuencia 14 , Derecha: Identificación CAP . .	142
5.80. Izquierda: Escalograma Haar secuencia 15 , Derecha: Identificación CAP . .	142
5.81. Izquierda: Escalograma Daubechies 4 secuencia 1 , Derecha: Identificación CAP	143
5.82. Izquierda: Escalograma Daubechies 4 secuencia 2 , Derecha: Identificación CAP	143
5.83. Izquierda: Escalograma Daubechies 4 secuencia 5 , Derecha: Identificación CAP	144
5.84. Izquierda: Escalograma Daubechies 4 secuencia 6 , Derecha: Identificación CAP	144
5.85. Izquierda: Escalograma Daubechies 4 secuencia 7 , Derecha: Identificación CAP	145
5.86. Izquierda: Escalograma Daubechies 4 secuencia 9 , Derecha: Identificación CAP	145
5.87. Izquierda: Escalograma Daubechies 4 secuencia 12 , Derecha: Identificación CAP	146
5.88. Izquierda: Escalograma Daubechies 4 secuencia 13 , Derecha: Identificación CAP	146
5.89. Izquierda: Escalograma Daubechies 4 secuencia 14 , Derecha: Identificación CAP	147
5.90. Izquierda: Escalograma Daubechies 4 secuencia 15 , Derecha: Identificación CAP	147

Índice de cuadros

1.1. Resumen de características de la actividad EEG	6
1.2. Abreviaturas de los electrodos de acuerdo a la región craneal	7
2.1. Arousal típicos	12
2.2. Paradigma CAP	14
4.1. Coeficientes AR Obtenidos para cada ritmo (alfa, beta, delta, y teta)	46
4.2. Características de la señal EEG [37] utilizadas para la simulación	47
4.3. Umbrales utilizados para la binarización	94
5.1. Identificación de secuencias CAP mediante análisis de potencia	102
5.2. Identificación de secuencias CAP mediante estadísticas temporales	105
5.3. Identificación de secuencias CAP mediante coeficientes de Correlación y distancia de Chebyshev	108
5.4. Identificación de secuencias CAP mediante Modelo Autorregresivo y distancia espectral	111
5.5. Identificación de secuencias CAP mediante Modelo Autorregresivo y distancia geométrica	114
5.6. Identificación de secuencias CAP mediante parámetros RLS	117
5.7. Identificación de secuencias CAP mediante espectrograma	122
5.8. Identificación de secuencias CAP mediante distribución Wigner - Ville	127
5.9. Identificación de secuencias CAP mediante distribución Choi Williams	132
5.10. Identificación de secuencias CAP mediante distribución Bessel	137
5.11. Identificación de secuencias CAP mediante transformada Haar	142
5.12. Identificación de secuencias CAP mediante Transformada Daubechies 4	147
5.13. Resumen de Resultados de la primera clasificación	148
5.14. Resumen de Resultados de la segunda clasificación	148
5.15. Resumen de Resultados de la tercera clasificación	149
5.16. Resumen de resultados promedio de la 3 clasificaciones y tiempo promedio de cada algoritmo en segundos por secuencia	149

Glosario

- AR** Abreviatura de Autorregresivo. Modelo AR; Modelo Autorregresivo. En la teoría de sistemas, un modelo autorregresivo puede ser asociado a un sistema con el objeto de analizarlo, identificarlo, estimarlo, etc..
- CA** Abreviatura de Coeficientes de Autocorrelación. Autocorrelación; Herramienta matemática utilizada en el procesamiento digital de señales. Ver sección 3.
- CAP** Patrón Alternante Cíclico, del inglés Cyclic Alternating Pattern.
- EEG** Abreviatura de electroencefalograma; estudio de la actividad eléctrica del cerebro. Señales de EEG; señales del cerebro obtenidas mediante un electroencefalograma.
- EMG** Electromiograma; estudio de la actividad eléctrica del músculo, a menudo este estudio se incluye en el análisis de sueño.
- EOG** Electrooculograma; estudio de la actividad eléctrica de los ojos
- MOR** Movimientos Oculares Rápidos. Etapa de sueño relacionada con la aparición de imágenes oníricas caracterizada por el movimiento rápido de ojos. Etapa en la que soñamos.
- NMOR** No MOR. Etapa del sueño dividida en 3 sub etapas cada una perfectamente diferenciada de la otra, con la característica común de la ausencia del movimiento ocular rápido
- ISCAP** Abreviatura de Identificación de Secuencias CAP. La Identificación de Secuencias CAP puede ser realizada mediante diferentes algoritmos, algunos de ellos se tratan en este documento.
- SFT** Del inglés Short Fourier Transform. La transformada corta de Fourier es una técnica tiempo - frecuencia que consiste en obtener la transformada de fourier segmento a segmento de una señal dividida en N segmentos
- TFR** Abreviatura de Representación tiempo - frecuencia, en inglés Time Frequency Representation. Familia de algoritmos con las que podemos representar el comportamiento frecuencial y temporal de una señal en un mismo espacio.

Introducción

Desde 1929 cuando H. Berger; [6], comienza el estudio de las señales del cerebro humano, no sólo se han desarrollado una gran cantidad de técnicas para su estudio, si no que también éstas han ayudado a resolver distintas patologías del cerebro. Un problema ligado al funcionamiento del cerebro y que constituye una parte importante en la vida de las personas es sin duda sufrir trastornos de sueño. El sueño es una actividad importante para el funcionamiento del organismo y su falta o algún desorden en él, produce trastornos físicos importantes en la persona que lo padece.

Los trabajos realizados sobre el sueño, en la década de los 50, condujeron a estándares en su clasificación y estudio, como por ejemplo, el estándar de colocación de electrodos conocido como Sistema 10 - 20; [24] y el manual de calificación de sueño realizado por Rechtschaffen y Kales; [37]. Estos estándares clásicos permanecieron vigentes durante más de 35 años, hasta finales de los 90's cuando un grupo de investigadores, como relata Terzano, [48] , comienza el desarrollo de un procedimiento nuevo para la calificación y evaluación de la calidad de sueño conocida como Patrón Alternate Cíclico, cambiando la idea de estudiar al sueño como un conjunto de cambios fisiológicos generalizados en el organismo y se centra en el estudio de la causa que da origen a esos cambios a través de la señal de EEG.

Este nuevo paradigma de clasificación del sueño requiere de nuevas estrategias de procesamiento para su automatización. En la actualidad, para el análisis de la señal de EEG se han utilizado técnicas como: Modelado de la señal EEG; [30], estudios en el dominio del tiempo; [14], técnicas de modelado autorregresivo; [39] y también técnicas más modernas como los métodos tiempo - frecuencia y wavelets; [19].

Algunas de las técnicas mencionadas ya se han empezado a utilizar en el problema de la identificación y clasificación del sueño mediante el paradigma CAP como en: [40]; [29];[42]; [14];[27]. El propósito de este trabajo se centra en la implementación y comparación de algoritmos de procesamiento digital aplicados al paradigma CAP con el fin de tener elementos de decisión para el desarrollo futuro de sistemas de calificación de sueño basada en CAPs. En este trabajo implementamos y comparamos los siguientes algoritmos:

- Identificación de secuencias CAP mediante análisis de potencia
- Identificación de secuencias CAP mediante Estadísticas temporales
- Identificación de secuencias CAP mediante análisis de coeficientes de Correlación
- Identificación de secuencias CAP mediante un modelo Autorregresivo
- Identificación de secuencias CAP mediante Parámetros RLS
- Identificación de secuencias CAP mediante métodos tiempo frecuencia: SFT, Wigner - Ville, Choi - Williams, Bessel
- Identificación de secuencias CAP mediante métodos tiempo escala: Transformada Haar y Transformada Daubechies 4

Dado que la variedad de algoritmos aplicables a la clasificación de sueño puede ser extensa, y habiendo escogido a los antes citados, como primer propósito tuvimos que acondicionarlos y adecuarlos a las necesidades de análisis del paradigma CAP, para ello tratamos de hacer analogías de problemas ya resueltos y aplicarlos a esta estrategia; de tal forma que intentamos incluir algoritmos simples, casi intuitivos como el análisis de potencia y de coeficientes de correlación, hasta algoritmos más complejos en análisis y cálculo como los métodos tiempo - frecuencia y tiempo - escala; no sin antes pasar por el análisis espectral mediante el modelado AR de la señal primeramente concebida como una señal cuasi estacionaria y posteriormente utilizando estrategias adaptables tomadas del problema de igualación de canal en telecomunicaciones con el empleo del algoritmo RLS; [3].

Capítulo 1

Generalidades del Encefalograma

En cada momento, las células nerviosas de nuestro cerebro generan impulsos nerviosos; estos impulsos dan como resultado lo que conocemos como ondas cerebrales. El registro de estas ondas se llama electroencefalograma o EEG.

Los encefalógrafos son equipos especializados capaces de medir y almacenar las ondas cerebrales. Los encefalógrafos registran las diferencias de potencial entre sus electrodos, por lo tanto, las señales obtenidas dependen de la posición de cada electrodo y de la forma en que éstos son apareados.

1.1. Clasificación del EEG

Desde el punto de vista de la teoría de señales y sistemas, el EEG es una señal real, aleatoria, con un ancho de banda comprendido entre los 0.5Hz y 32Hz. Para su estudio, la señal se ha dividido principalmente en 4 bandas de frecuencia. De acuerdo con [13] tenemos lo siguiente:

1.1.1. Beta

El ritmo beta, figura(1.1), es una actividad “rápida”, compuesta por frecuencias mayores a los 13 Hz. Generalmente se observa en ambos hemisferios del encéfalo; siendo más evidente en la parte frontal. En áreas de daño cortical la presencia de este ritmo puede ser nulo o reducido. La aparición del ritmo beta se asocia principalmente a estados de alerta, vigilia, ojos abiertos y concentración. Haciendo una analogía con las velocidades de un vehículo, el ritmo beta representaría la sobre marcha.

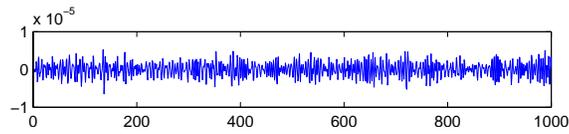


Figura 1.1: Señal Beta

1.1.2. Alfa

El ritmo alfa, figura(1.2), comprende el intervalo de frecuencias de 8 - 12 hz, está asociado con estados de relajación, ojos cerrados o fatiga y se considera un puente entre los estados de conciencia y subconsciencia. Su presencia predomina la zona occipital mayormente en adultos, en especial en mayores de 30. Se piensa que el ritmo alfa tiene su origen en la tejido que conecta todas las partes de el cerebro. En analogía con las velocidades de un vehículo, este ritmo representaría el neutral o punto muerto.

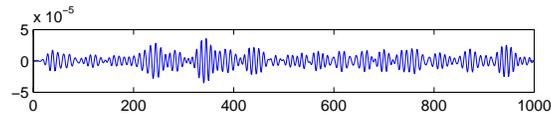


Figura 1.2: Señal Alfa

1.1.3. Teta

El ritmo Teta, figura(1.3), se compone por frecuencias de 4 a 7 Hz por lo que se clasifica como actividad “lenta”. Este tipo de ritmo se relaciona con la creatividad, la intuición y el “soñar despierto”. En niños despiertos es perfectamente normal, mientras que adultos su presencia es normal sólo durante el sueño. Esta actividad se presenta mayormente en todas las regiones laterales del encéfalo. Siguiendo con la analogía de la caja de velocidad este ritmo representaría la segunda velocidad.

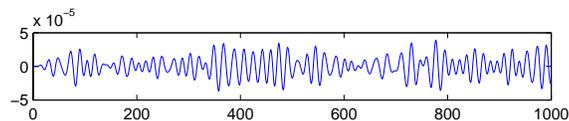


Figura 1.3: Señal Teta

1.1.4. Delta

El ritmo delta, figura(1.4), se refiere a la actividad más lenta de nuestro cerebro, se compone por frecuencias menores a los 3.5 Hz y su aparición es normal durante etapas de sueño profundo o en estados de empatía, aunque en infantes de hasta un año, es común su presencia durante la vigilia. Este ritmo representaría la primera velocidad en un vehículo.

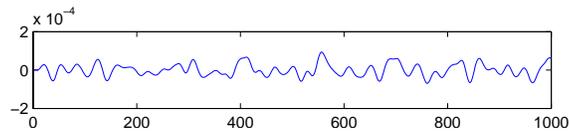


Figura 1.4: Señal Delta

Señal	Zona Craneal	Voltaje (μV)	Frecuencia (Hz)	Característica
Alfa	Occipital	20	8-12	Relajación
Beta	Central	5	13-30	Concentración
Delta	Todas	75-150	0.5-3.5	Sueño profundo
Teta	Temporal	50-75	4-7	Sueño etapa 3

Cuadro 1.1: Resumen de características de la actividad EEG

El Cuadro[1.1] muestra un resumen del tipo de actividad EEG, su amplitud promedio y su rango de frecuencias de acuerdo a la clasificación mostrada en [37].

1.2. Técnicas de registro

El primer registro de EEG fue hecho por Berger, un neurofisiólogo alemán, en 1929,[[6]]; desde entonces el número de investigadores fue en aumento y cada uno de ellos efectuaba sus propias mediciones como mejor le parecía y por ende, los registros obtenidos no coincidían. No fue sino hasta 1957 que se publica en “Report of the committee on methods of clinical examination in Encephalography” el sistema de colocación de electrodos 10-20, donde 10-20 describe la manera en que los electrodos son colocados;[37].

Tres de las ventajas más relevantes que proporciona el sistema de colocación 10 - 20 son las siguientes:

- Crea un método de identificación para las distintas ubicaciones de los electrodos, el cual es usado mundialmente.
- La ubicación de los electrodos permite la medición exacta de voltajes sin importar el tamaño y forma del cráneo.
- Los resultados obtenidos son exactamente los mismos sin importar el lugar o el equipo que se use.

En el sistema 10 - 20, cada electrodo tiene una abreviatura de acuerdo a la zona del cerebro donde se coloque, figura(1.5). El Cuadro [1.2] muestra las abreviaturas.

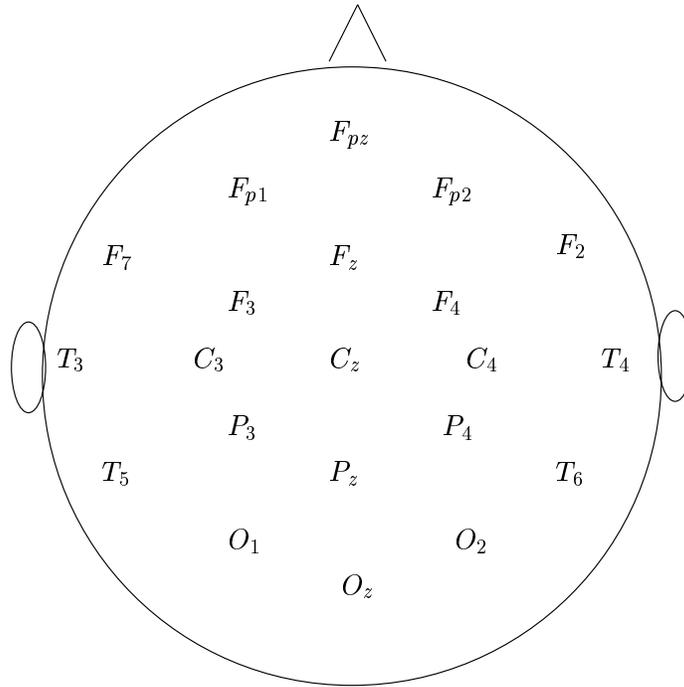


Figura 1.5: Sistema internacional 10-20

Cuadro 1.2: Abreviaturas de los electrodos de acuerdo a la región craneal

Abreviaturas	Región
C	Central
F	Frontal
O	Occipital
T	Temporal
P	Parietal
A	Auricular

1.3. Conclusiones

El estudio de las señales de EEG han conducido a la detección y tratamiento de numerosas enfermedades físicas y psíquicas. Las patologías del sueño son un ejemplo claro donde el estudio de las señales de EEG ha sido determinante. En un principio los investigadores de las señales de EEG realizaban sus investigaciones de manera aislada, por lo que la falta de un estándar en la forma de realizar sus mediciones hacía imposible que sus resultados fueran comparados y compartidos; fue así como la necesidad de crear un estándar en la forma de registrar las señales de EEG da lugar al estándar 10 - 20 de colocación de electrodos.

Capítulo 2

El Sueño, Clasificación Clásica y sus Nuevas Tendencias

El Sueño es un estado de reposo que se caracteriza por distintos cambios en la actividad fisiológica y por una respuesta menor ante estímulos externos. Se ha considerado siempre que el sueño es un estado relacionado con la conducta. Sin embargo, algunas características de la fisiología del cerebro, como las ondas cerebrales, corroboran que existe una estrecha relación, entre estos registros y el estado del sueño,[37].

En los años 30 comienzan las primeras investigaciones sobre el sueño humano gracias al descubrimiento y desarrollo del encefalograma (EEG). En 1937, Loomis observó que el sueño no era un estado homogéneo durante toda la noche, describiendo diferentes etapas del sueño basadas en el EEG; [47]. En 1953, Aserinsky y Kleitman observaron el sueño MOR (Movimientos Oculares Rápidos); [47]. En 1968, a partir de las observaciones ya realizadas en las señales EEG de sueño y en diversos cambios físicos, A. Rechtschaffen y A. Kales publicaron un manual de clasificación de sueño, clasificación que hoy en día sigue aún vigente (A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects) [37].

De acuerdo con lo propuesto por Rechtschaffen y Kales en [37], para conseguir un registro apropiado del sueño se deben seguir ciertos lineamientos: Es necesario contar con un canal de EEG, dos canales de Electrooculografía (EOG) y un canal de Electromiografía (EMG). La derivación a utilizar, de acuerdo con el sistema de colocación de electrodos 10-20, es C4/A1 o C3/A2, lo que significa que los electrodos deberán ser colocados uno en la región central derecha (C4) y otro en la región central izquierda (C3) con sus respectivas referencias en el auricular derecho (A2) e izquierdo (A3). Los potenciales oculares deben ser registrados a 1 cm por arriba de la parte exterior del primer ojo y a 1 cm por abajo de la parte exterior del segundo. Los electrodos de referencia del EOG deben ser colocados en el mastoides o en algún lóbulo auricular. El EMG debe ser registrado debajo de la barbilla. El análisis y calificación del registro debe hacerse por intervalos, de 20-30, segundos llamados *épocas*.

2.1. Fases del sueño

De acuerdo a la clasificación, de Rechtschaffen y Kales, el sueño se subdivide en 2 grandes etapas: MOR y NMOR (con y sin movimientos oculares rápidos). La etapa NMOR se subdivide según la profundidad del sueño (de menor a mayor) en vigilia, fase 1, fase 2, fase 3 y fase 4; cada una de estas fases ¹ se caracteriza, entre otros parámetros (respiración ritmo cardíaco, sudoración, etc...), por la actividad EEG que presenta. Cualquier alteración en alguna de estas etapas podría significar algún desorden del sueño.

Vigilia Existe bajo voltaje (10-30 μV) y frecuencias mixtas (alfa, beta) en la actividad EEG. Alto tono muscular.

Fase 1 Se caracteriza por bajo voltaje, frecuencias mixtas (2-7 hz). Aparición de Ondas de vertex, señal de EEG fácilmente identificable por su forma de "V", cuya amplitud puede llegar a alcanzar los 200 μV . En esta etapa, pueden presentarse movimientos oculares. El tono muscular es más relajado que en la fase de vigilia. Se considera Etapa uno cuando la cantidad de actividad alfa es menor al 50 % de la época.

Fase 2 Se caracteriza por la aparición de formas de EEG conocidas como usos de sueño y complejos K (un tipo de señal EEG compuesto de una parte negativa seguida de una positiva de menor amplitud). Los usos de sueño se componen por una señal EEG de duración corta (0.5 s como mínimo) y frecuencias de 12-14 Hz. Si el tiempo de ocurrencia de los usos de sueño o complejos K es menor que 3 minutos, este intervalo se considera como etapa 2, a menos que exista incremento en el tono muscular, movimiento o arousals ².

Fase 3 Se define como fase 3 cuando del 20 % y hasta el 50 % de la época contiene ondas lentas (ondas de 2 Hz o menos) con amplitudes mayores a 75 μV .

Fase 4 Se define como fase 4 cuando la época contiene más del 50 % de ondas lentas y amplitudes mayores a 75 μV .

¹El termino fase es también comúnmente sustituido por etapa

²Arousal - Cambio abrupto de un estado de sueño a un estado de vigilia, o de una fase de sueño más profunda a una menos profunda en el sueño NMOR

Etapa MOR Las señales presentes son señales de bajo voltaje y frecuencias mixtas como en la fase 1, el tono muscular alcanza el nivel más relajado y existen episodios de movimientos oculares.

2.2. Macro estructura del sueño

Como se ha observado, durante el sueño, en nuestro organismo acontecen una serie de cambios fisiológicos: variaciones en el funcionamiento cerebral, en el sistema muscular, en la respiración, en el sistema genital, etc... Todos estos cambios fisiológicos constituyen la macro estructura del sueño; [48]. Los parámetros utilizados para la calificación del sueño de acuerdo a su macroestructura son; [37]:

Tiempo total de sueño (TST, Total Sleep Time); es el tiempo que se invierte en dormir.

Tiempo en cama (TIB, Time In Bed); es el tiempo que uno pasa en la cama.

Eficiencia del Sueño (ST, Sleep Time); es la relación entre el TST y TIB

Latencia de sueño (SL, Sleep Latency); es la cantidad de tiempo requerida para concebir el sueño

Despertares después de la concepción del sueño (WASO, Wake After Sleep Onset); es el tiempo que un individuo permanece despierto después de la concepción inicial del sueño (El primer episodio de sueño que experimenta el individuo).

Movimientos Oculares No Rápidos (NREM, No Rapid Eye Movement); es el conjunto de fases del sueño: Fase 1, Fase 2, Fase 3, Fase 4.

Movimientos Oculares Rápidos (REM, Rapid Eye Movement); es un estado de sueño caracterizado por el movimiento ocular rápido

Latencia Movimientos Oculares Rápidos (REM-L, Rapid Eye Movement Latency); es el tiempo transcurrido hasta la primera aparición de la etapa MOR del sueño.

Estos cambios, descritos por Rechtschaffen y Kales [37], han sido usados como estándar para la clasificación de sueño durante más de 35 años, pero existen ciertas desventajas,[47]:

- Se ignoran eventos menores a 30 segundos
- Si el intervalo analizado contiene características de otros intervalos, el intervalo es definido en función de las características de mayor duración.
- Se basan en características de adultos sanos.
- Algunos tipos de señal (usos de sueño, complejos K) no están bien caracterizados.

2.3. Micro estructura del sueño: El Patrón Alternante Cíclico (CAP)

La investigación de la macro estructura del sueño ha sido extensamente explorada y tomando en cuenta las deficiencias presentadas en el método de Rechtschaffen y Kales, surgió un creciente interés hacia la inclusión de nuevos parámetros de clasificación del sueño, adquiriendo un nivel relevante la organización micro estructural del sueño. El estudio de la densidad (apariciones por minuto) y periodicidad de los *complejos K*, un tipo de *arousal*, llevó al estudio del *Patrón alternante Cíclico CAP*. De acuerdo con Terzano[48] la densidad de los complejos K sufre fluctuaciones a lo largo de toda la noche, sin embargo existen picos en la densidad que observan una relación con los cambios de fase en el sueño NMOR. Terzano[48] concibe al patrón alternante cíclico como un marcador de la inestabilidad de los arousals.

A principios de los 90's;[49], Terzano y otros investigadores, comienzan a desarrollar una nueva herramienta para el diagnóstico de los trastornos de sueño. Este criterio se basa en el patrón alternante cíclico de la señal EEG. El patrón alternante está definido como la repetición sucesiva de algún tipo específico de actividad cerebral (Cuadro 2.1) que aparece en el sueño NREM con duración estricta de 2 a 60 segundos , y que puede significar un disturbio en el sueño originado por alguna fisiopatología;[50], por ejemplo: algún desorden respiratorio, movimiento de extremidades, etc.

Cada patrón alternante se compone de dos fases: Fase A y Fase B. La fase A se caracteriza por un cambio brusco en la forma, frecuencia y/o amplitud de la señal; aunque no existe un estereotipo para la fase A, esta puede incluir:

- Picos Delta
- Ondas del Vertex
- Complejos K
- Ritmo Alfa intermitente

La fase B pertenece a la actividad cerebral de fondo que separa las fases A.

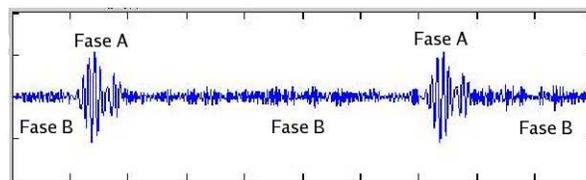


Figura 2.1: Ejemplo de CAP

Ritmo alfa intermitente	Típica fragmentación de ondas alfa que ocurre durante etapas tempranas de la fase 1, caracterizada por bajo voltaje en un rango de 2 - 7 Hz
Ondas del Vertex	Desde la perspectiva neurofisiológica son consideradas como potenciales evocados (EV); presentan similitudes con los EV auditivos y se relacionan con la disminución de la excitabilidad cortical
Complejos K	Fenómeno cortical espontáneo o evocado asociado con o seguido de vasoconstricción e incremento en la presión arterial
Picos Delta K	De origen cortical puede ser provocado mediante estímulos sensoriales (táctiles, auditivos, visuales etc..) Frecuentemente anuncia un movimiento del cuerpo durante el sueño

Cuadro 2.1: Arousals típicos

Todas las secuencias CAP comienzan con una fase A y terminan con una fase B. En el sueño NMOR, las señales EEG de la fase A se caracterizan por la aparición de eventos peculiares conocidos como eventos fásicos.

1. durante la etapa 1 del sueño:
 - ritmo Alfa intermitente
 - secuencias de ondas del vertex
2. durante la etapa 2 del sueño:
 - secuencias de dos o más complejos-K
 - seguidos por componentes similares al ritmo alfa

- ritmo beta 3
3. durante el sueño de ondas lentas:
 - picos delta que exceden al menos 1/3 de la amplitud de la actividad de fondo
 4. durante todas las etapas:
 - activación de eventos transitorios
 - arousals

El periodo entre 2 fases A sucesivas, separadas por un intervalo mayor a 60 segundos, se considera como no CAP (NCAP).

Este patrón es “fácilmente” reconocible y su cuantificación expresada en porcentaje respecto al tiempo total de sueño, es un índice de la calidad de sueño,[51]. En la figura(2.1) podemos apreciar la diferencia entre fases. La fase B pertenece a la señal de fondo, mientras que la fase A representa los cambios bruscos que se observan.

El paradigma CAP tiene una organización jerárquica de las señales EEG de sueño. Usa sólo un canal de EEG, generalmente C4-A1 del sistema de colocación de electrodos 10-20 [24], y la clasificación se hace segundo a segundo.

El paradigma CAP divide en dos tipos de secuencias a las señales de EEG. Secuencias CAPS, y secuencias NCAPS. Las secuencias CAPS se componen por al menos dos CAP; cada secuencia CAP está compuesta por una fase A seguida de una fase B. La figura(2.2) muestra la estructura jerárquica del paradigma CAP.

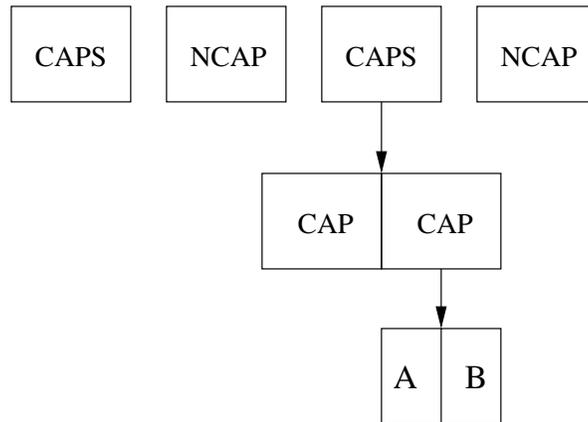


Figura 2.2: Jerarquía del paradigma CAP

Fases	Descripción
CAPS	Constituido por al menos 2 secuencias CAP
CAP	Secuencia de una fase A seguida de una fase B
Fase A	EEG con varias oscilaciones. Duración de 2 a 60 segundos
Fase B	EEG con alguna estacionareidad. Duración de 2 a 60 segundos
NCAP	Fase no CAP

Cuadro 2.2: Paradigma CAP

2.4. Conclusiones

La tercera parte de nuestra vida la pasamos durmiendo, por ello, el sueño es una actividad de suma importancia en la vida del ser humano. Existen diferentes enfermedades físicas y psicológicas que trastornan el sueño, lo que provoca desequilibrios en la conducta y desórdenes físicos importantes en la vida de quien los padece. Desde el descubrimiento de las señales de EEG en los años 30, los investigadores se han enfocado al problema de diagnosticar y tratar los trastornos del sueño. En 1953 Rechtschaffen crea un estándar de clasificación apoyado en distintas variables como el tipo de señal EEG, el ritmo cardíaco, tono muscular, respiración, etc. Todas estas variables constituyen un esquema macro estructural del sueño. Este estándar fue utilizado por más de 30 años, sin embargo, estudios más profundos conducidos por Lima y Rosa realizados en las señales de EEG de sueño demuestran la existencia de patrones que se repiten en periodos de 2 a 60 segundos durante el sueño NREM. Este nuevo descubrimiento da pie a la creación de un método para la clasificación del sueño, alternativo al de Rechtschaffen, conocido como paradigma CAP de clasificación de sueño.

Capítulo 3

Algoritmos de Análisis e Interpretación de Secuencias CAP

Este capítulo no pretende ser exhaustivo en cuanto a la descripción de las técnicas de procesamiento digital de señales utilizadas en el análisis de las señales cerebrales; pretendemos dar a conocer algunos métodos que posteriormente retomaremos para su implementación y comparación. Hemos dividido estos métodos en 3 grupos: los que analizan la señal en el dominio del tiempo, los que analizan la señal en el dominio de la frecuencia y finalmente los que hacen un análisis tanto en tiempo como en frecuencia. A continuación se presentan varios métodos con el fin de obtener características útiles en la detección de secuencias CAP de la señal EEG.

Comenzamos con la obtención de la respuesta de la corteza del encéfalo, donde se pretende estimar la señal de EEG que se generó a nivel cortical; es decir, tratar de eliminar la degradación que sufre la señal desde su origen hasta su registro. A la señal EEG cortical le aplicamos distintos algoritmos del procesamiento digital de señales. En este trabajo, la identificación de secuencias CAP se basa en la detección de actividades rítmicas o bien transitorias y actividades de fondo de la señal y para esto asumimos que la potencia entre estos tipos de actividades es diferente, por lo que un cambio en la media de la potencia corresponde a un cambio de actividad. También se describen técnicas clásicas del procesamiento digital de señales como el ajuste de un modelo autorregresivo (AR) a la señal EEG, donde asumimos que los parámetros A_i del modelo AR son iguales mientras no exista un cambio en la actividad de la señal EEG. Así mismo, en esta sección describimos el modelo de generación de EEG propuesto por Rosa [41] y su desarrollo para la obtención de ganancias del modelo propuesto en [29]. Finalmente terminamos con la introducción a los algoritmos tiempo frecuencia usados como herramientas de detección de secuencias CAP.

3.1. Estimación de la respuesta de la corteza del encéfalo

Las señales de EEG tienen su origen en el encéfalo, sin embargo, comúnmente son registradas sobre la piel y el cabello, por lo que en su paso hacia los electrodos, las señales se degradan. Por otro lado, sería impráctico y molesto hacer registros de encefalografía directamente en el encéfalo o al menos sobre su corteza.

Pfurtscheller y Cooper [36], realizaron estudios sobre el comportamiento de la corteza del encéfalo mediante mediciones directas, logrando caracterizarla como un filtro paso bajas.

Llegando a la misma conclusión de que la corteza del encéfalo se comporta como un filtro paso bajas; Martins y Rosa, [34],[32], propusieron un método para caracterizar la respuesta de la corteza del encéfalo mediante observaciones en la señal de EEG registrada. El método propuesto utiliza un modelo AR para la estimación de los parámetros del filtro de la corteza encefálica a partir de señales EEG correspondientes a la fase de sueño REM, el cual está desprovisto de actividades rítmicas. Se propone el uso de estimación lineal selectiva con el fin de estimar sólo una banda del espectro. Esta banda comprende las frecuencias que van de 0 a 30 HZ, lo que permite caracterizar únicamente las frecuencias de interés para el fenómeno de EEG y elimina efectos de ruido tales como el de 60 Hz de la línea de alimentación eléctrica. La figura 3.1 muestra ejemplos de señales encefálica estimada y registrada

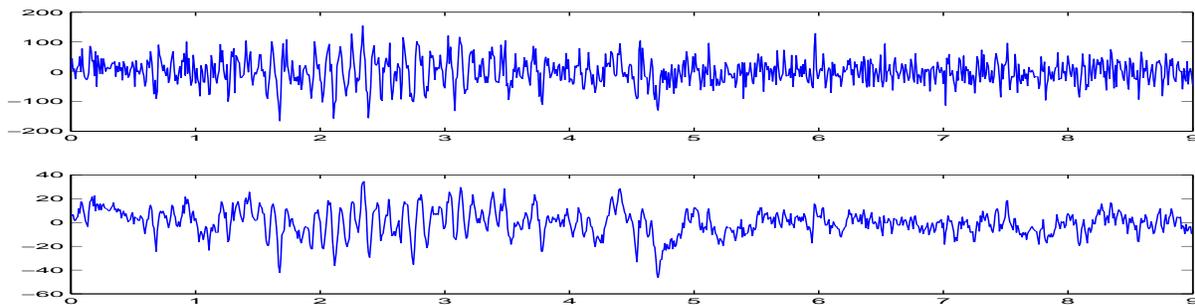


Figura 3.1: Arriba: Señal EEG Cortical Estimada. Abajo: EEG registrado

3.2. Función de Correlación

En la década de los 50's, el uso de la función de intercorrelación o correlación cruzada, en el análisis de la señal de encefalografía, fue ampliamente difundido; siendo ésta la antecesora del análisis espectral.

La función de correlación $R_{xy}(l)$ suministra una medida de la similitud o interdependencia entre las señales $x(k)$ y $y(k)$. El proceso de correlación se basa en la suma de productos entre muestras de ambas señales en función de un parámetro l (el desplazamiento de una señal con respecto a la otra).

Matemáticamente la función de correlación se expresa como:

$$R_{xy}[l] = \sum_{k=0}^{N-|l|-1} x[k]y[k-l] \quad (3.1)$$

Donde N comprende el número de muestras de la señal.

3.2.1. Función de Autocorrelación

En los comienzos del uso de la técnica de autocorrelación, la capacidad de cómputo disponible en aquellos años era rebasada; [22]. La función de autocorrelación fue entonces sustituida por el análisis de cruces por cero, que se basaba en el hecho de que la función de autocorrelación puede aproximarse sustituyendo las señales $x[k]$ y $x[k+l]$ por sus signos: +1 para $x[k]>0$ y -1 para $x[k]\leq 0$ como se menciona en [22]. El resultado de esta sustitución dió origen a la función conocida como *correlación de coincidencia de polaridad*.

La autocorrelación es un caso particular de la función de intercorrelación donde una sola señal se compara consigo misma. Matemáticamente la función de autocorrelación se expresa como:

$$R_x[l] = \sum_{k=0}^{N-|l|-1} x[k]x[k+l] \quad (3.2)$$

Algunas propiedades de la función de autocorrelación son:

$$\begin{aligned} R_x[l] &= R_x[-l] \\ R_x[0] &= E_x \end{aligned}$$

3.3. Modelo Autorregresivo de la señal EEG

En 1969, Zetterberg aplicó por primera vez un modelo autorregresivo a la señal EEG y desde entonces de acuerdo a Kaipio [25], el modelo autorregresivo se ha aplicado en al menos 160 artículos de revistas, principalmente en análisis espectral, clasificación de estados cerebrales, detección de transitorios, predicción de epilepsia y simulación de EEG. La estructura de un modelo autorregresivo es la siguiente:

$$y[k] = - \sum_{n=1}^p a_n y[k-n] + b_0 e[k] \quad (3.3)$$

Donde p es el orden del modelo, a_n y b_0 son los parámetros que lo caracterizan y finalmente $y[k]$ y $e[k]$ representan las secuencias de salida y entrada del sistema, respectivamente, asociado al modelo autorregresivo. La caracterización del modelo consiste en la estimación de sus parámetros a partir de un criterio de minimización de error.

Supongamos que queremos estimar la salida $y[k]$ de un sistema mediante el estimador $\hat{y}[k]$ definido como:

$$\hat{y}[k] = - \sum_{n=1}^p a_n[k]y[k-n] \quad (3.4)$$

Entonces la diferencia entre el valor real $y[k]$ y el valor estimado $\hat{y}[k]$ es el error de estimación $\varepsilon[k]$:

$$\varepsilon[k] = y[k] - \hat{y}[k] \quad (3.5)$$

Sustituyendo $\hat{y}[k]$ en la ecuación de error, ecuación(3.5), resulta el error en términos de los parámetros a_n del sistema:

$$\varepsilon[k] = y[k] + \sum_{n=1}^p a_n y[k-n] \quad (3.6)$$

Por simplicidad en el manejo utilizaremos notación matricial; dando como resultado:

$$\varepsilon[k] = y[k] + A_p^* Y_p[k-1] \quad (3.7)$$

donde:

$$A_p^* = [a_1, a_2, \dots, a_p - 1, a_p]$$

$$Y_p = [y[k-1], y[k-2], \dots, y[k-p-1], y[k-p]]^T$$

Si se minimiza el error entonces la diferencia entre la señal estimada y la señal real es mínima, en otras palabras, la señal estimada es lo más parecida a la señal real. Un criterio utilizado para la minimización del error es el criterio del Error cuadrático promedio (MSE por sus siglas en inglés).

$$E\{|\varepsilon[k]|^2\} \quad (3.8)$$

Minimizando nuestra ecuación de error respecto a sus parámetros A_p y tomando en cuenta este criterio tenemos:

$$\frac{dE\{|\varepsilon[k]|^2\}}{dA_p} = 0$$

donde $|\varepsilon[k]|^2$ ¹:

¹Donde * representa el complejo conjugado

$$|\varepsilon[k]|^2 = \varepsilon[k]\varepsilon^*[k]$$

$$\varepsilon[k]\varepsilon^*[k] = (y[k] + A_p^*Y_p[k-1])(y^*[k] + Y_p^*[k-1]A_p)$$

$$\varepsilon[k]\varepsilon^*[k] = y[k]y^*[k] + y[k]Y_p^*[k-1]A_p + A_p^*Y_p[k-1]y^*[k] + A_p^*Y_p[k-1]Y_p^*[k-1]A_p$$

$$\varepsilon[k]\varepsilon^*[k] = y[k]y^*[k] + 2A_p^*Y_p[k-1]y^*[k] + A_p^*Y_p[k-1]Y_p^*[k-1]A_p \quad (3.9)$$

Haciendo $M_p = Y_p[k-1]Y_p^*[k-1]$; donde:

$$M_p = \begin{bmatrix} y[k-1] \\ y[k-2] \\ \vdots \\ y[k-p] \end{bmatrix} \begin{bmatrix} y^*[k-1] & y^*[k-2] & \cdots & y^*[k-p] \end{bmatrix}$$

$$M_p = \begin{bmatrix} y[k-1]y^*[k-1] & y[k-1]y^*[k-2] & \cdots & y[k-1]y^*[k-p] \\ y[k-2]y^*[k-1] & y[k-2]y^*[k-2] & \cdots & y[k-2]y^*[k-p] \\ \vdots & \vdots & \ddots & \vdots \\ y[k-p]y^*[k-1] & y[k-p]y^*[k-2] & \cdots & y[k-p]y^*[k-p] \end{bmatrix}$$

Y haciendo $m_p = Y_p[k-1]y^*[k]$

$$m_p = \begin{bmatrix} y[k-1]y^*[k] \\ y[k-2]y^*[k] \\ \vdots \\ y[k-p]y^*[k] \end{bmatrix}$$

$$\varepsilon[k]\varepsilon^*[k] = y[k]y^*[k] + 2A_p^*m_p + A_p^*M_pA_p$$

Aplicando la esperanza matemática $E\{\varepsilon[k]\varepsilon^*[k]\}$ tenemos:

$$E\{\varepsilon[k]\varepsilon^*[k]\} = E\{y[k]y^*[k]\} + 2E\{A_p^*m_p\} + E\{A_p^*M_pA_p\}$$

$$E\{\varepsilon[k]\varepsilon^*[k]\} = r_0 + 2A_p^*r_p + A_p^*R_pA_p \quad (3.10)$$

donde:

$$E\{M_p\} = R_p^{MSE}[k-1] = \begin{bmatrix} E\{y[k-1]y^*[k-1]\} & E\{y[k-1]y^*[k-2]\} & \cdots & E\{y[k-1]y^*[k-p]\} \\ E\{y[k-2]y^*[k-1]\} & E\{y[k-2]y^*[k-2]\} & \cdots & E\{y[k-2]y^*[k-p]\} \\ \vdots & \vdots & \ddots & \vdots \\ E\{y[k-p]y^*[k-1]\} & E\{y[k-p]y^*[k-2]\} & \cdots & E\{y[k-p]y^*[k-p]\} \end{bmatrix}$$

$$E\{m_p\} = r_p^{MSE}[k] = \begin{bmatrix} E\{y[k-1]y^*[k]\} \\ E\{y[k-2]y^*[k]\} \\ \vdots \\ E\{y[k-p]y^*[k]\} \end{bmatrix}$$

Tomando en cuenta la siguiente igualdad, [4]:

$$\frac{d}{dC}C^TBC = (B + B^T)C$$

derivamos la ecuación(3.10) respecto los parámetros A_p y obtenemos:

$$\frac{dE\{\varepsilon[k]\varepsilon^*[k]\}}{dA_p} = 2r_p^{MSE}[k] + 2R_p^{MSE}[k-1]A_p^{MSE}$$

igualando a cero para minimizar resulta:

$$r_p^{MSE}[k] + R_p^{MSE}[k-1]A_p^{MSE} = 0$$

Donde ahora el problema de obtener los parámetros A_p se reduce a resolver el sistema de ecuaciones matricial

$$R_p^{MSE}[k-1]A_p^{MSE} = -r_p^{MSE}[k] \quad (3.11)$$

3.4. Modelo de generación de la señal EEG

Son muchos los motivos que llevan a modelar la señal de EEG, entre ellos, la relación estrecha entre los procesos fisiológicos del sueño y la actividad cerebral; por otro lado, contar con un buen modelo de la señal EEG permite extraer características útiles en el análisis y procesamiento.

En 1973 Lopes da Silva, [22] propone un modelo para la generación del ritmo alfa, en el cual Rosa A. [43] se inspira y propone un modelo generalizado capaz de generar los distintos tipos de señal EEG, el cual Lima J. y Rosa A. retoman en [29] para la clasificación de la microestructura de sueño. Este modelo es conocido como modelo de *Mallas Resonantes* y básicamente es un conjunto de filtros sintonizados en cada una de las frecuencias de la señal EEG (alfa, beta, delta, teta) con ganancias variantes en el tiempo, lo que permite caracterizar distintos tipos de actividad rítmica en un instante dado. El banco de filtros es alimentado por ruido blanco gaussiano y por pulsos aleatorios. El ruido blanco modela la presencia de actividad EEG de fondo, mientras que los pulsos modelan actividades transitorias(sección 1.3). La figura(3.2) muestra el diagrama de bloques del modelo de la señal EEG.

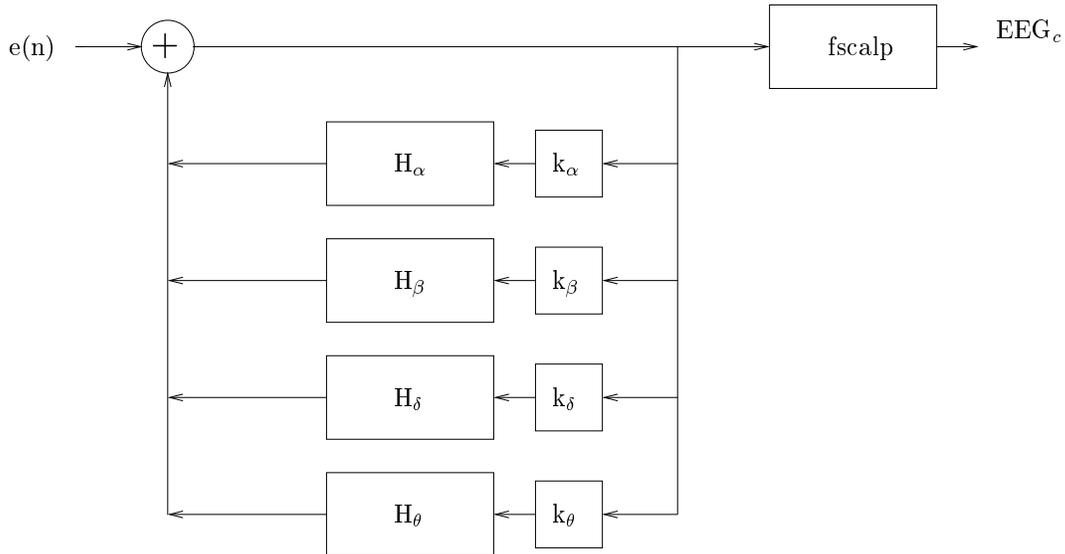


Figura 3.2: Modelo EEG, [33]

De la figura(3.2) definimos:

- H_α : Filtro sintonizado en el rango de frecuencias alfa
- k_α : Ganancia asociada H_α
- H_β : Filtro sintonizado en el rango de frecuencias beta

- k_β : Ganancia asociada H_β
- H_δ : Filtro sintonizado en el rango de frecuencias delta
- k_δ : Ganancia asociada H_δ
- H_θ : Filtro sintonizado en el rango de frecuencias teta
- H_θ : Ganancia asociada H_θ

Los coeficientes de los filtros pueden ser calculados empleando cualquier método que tome en cuenta ciertas consideraciones:

- Las frecuencias centrales de los filtros son sugeridas por estudios histológicos
- Los filtros deberán ser de segundo orden o superior para tener un mejor modelo de los eventos transitorios
- La frecuencia central de los filtros deberá mantenerse constante para diferentes ganancias

Rosa propone un filtro paso banda de segundo orden. Martins [32] estima cada filtro usando predicción lineal y modelos autorregresivos (AR).

3.4.1. Estimación de Ganancias mediante Máxima Verosimilitud

Con el fin de obtener conjuntos de características discriminantes útiles en la clasificación de la señal EEG [29] utiliza el modelo inverso, donde ahora, el sistema está alimentado por la señal de EEG, los filtros están sintonizados en cada banda y se trata de estimar las constantes k_i dado que el resultado es ruido blanco gaussiano.

De la figura(3.3) se tiene que:

$$w(n) = c(n) - \sum_{i=1}^V k_i r_i(n)$$

Considerando que tenemos N muestras independientes, la función de densidad de probabilidad estaría dada por:

$$p(w | k) = p(w(1) | k)p(w(2) | k)...p(w(N) | k)$$

Como son muestras independientes gaussianas:

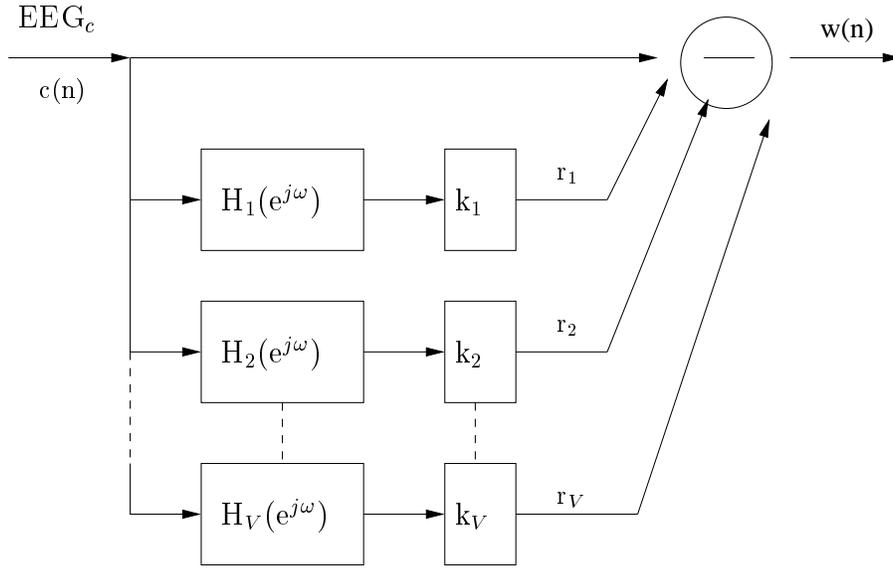


Figura 3.3: Modelo para la extracción de características de la señal EEG , [40]

$$p(W | K) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(c(i) - \sum_{j=1}^V k_j r_j(i))^2}{2\sigma^2}\right)$$

aplicando logaritmo natural en ambos lados de la ecuación

$$\ln(p(w | k)) = \ln\left(\prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(c(i) - \sum_{j=1}^V k_j r_j(i))^2}{2\sigma^2}\right)\right)$$

$$\ln(p(w | k)) = \text{cte} \sum_{i=1}^N \left(c(i) - \sum_{j=1}^V k_j r_j(i)\right)^2$$

Para un k_u genérico

$$\text{cte} \sum_{i=1}^N \left(c(i) - \sum_{\substack{j=1 \\ j \neq u}}^V k_j r_j(i) + k_u r_u(i)\right)^2$$

De acuerdo con el criterio de Máxima verosimilitud, se tiene que:

$$\hat{K}_{ml} = \arg \max_K p(W|K)$$

Entonces, derivando $\ln(p(W | K))$ respecto a k_u e igualando a cero para maximizar k_u

$$\frac{d}{dk_u} cte \sum_{i=1}^N \left(c(i) - \sum_{\substack{j=1 \\ j \neq u}}^V k_j r_j(i) + k_u r_u(i) \right)^2 = 0$$

$$2cte \sum_{i=1}^N \left(c(i) - \sum_{\substack{j=1 \\ j \neq u}}^V k_j r_j(i) + k_u r_u(i) \right) r_u(i) = 0$$

$$\sum_{i=1}^N \left(c(i) - \sum_{j=1}^V k_j r_j(i) \right) r_u(i) = 0$$

$$\sum_{i=1}^N c(i) r_u(i) - \sum_{j=1}^V k_j r_j(i) r_u(i) = 0$$

Definiendo

$$K = [k_1, k_2, \dots, k_V]^T$$

$$R_i = [r_1(i), r_2(i), \dots, r_V(i)]^T$$

$$C = [c(1), c(2), \dots, c(N)]^T$$

Para cada k en forma matricial se tiene; [29]:

$$R_u^T C - \sum_{j=1}^V k_j R_u^T R_j = 0$$

$$AK = b \tag{3.12}$$

Donde

$$A = \begin{bmatrix} R_1^T R_1 & R_1^T R_2 & \cdots & R_1^T R_V \\ R_2^T R_1 & R_2^T R_2 & \cdots & R_2^T R_V \\ \vdots & \vdots & \ddots & \vdots \\ R_V^T R_1 & R_V^T R_2 & \cdots & R_V^T R_V \end{bmatrix}$$

$$b = \begin{bmatrix} R_1^T C \\ \vdots \\ R_V^T C \end{bmatrix}$$

Finalmente, k_{ml} :

$$k_{ml} = A^{-1}b \quad (3.13)$$

Después de haber estimado las ganancias de cada una de las bandas, el modelo de EEG queda completamente determinado.

3.4.2. Estimación de ganancias mediante el Error Cuadrático Medio

Reordenando un poco el modelo inverso de EEG, propuesto por Lima y Rosa [29], obtendremos el estimador de ganancias mediante el criterio del error cuadrático medio. El modelo reordenado se muestra en la figura(3.4).

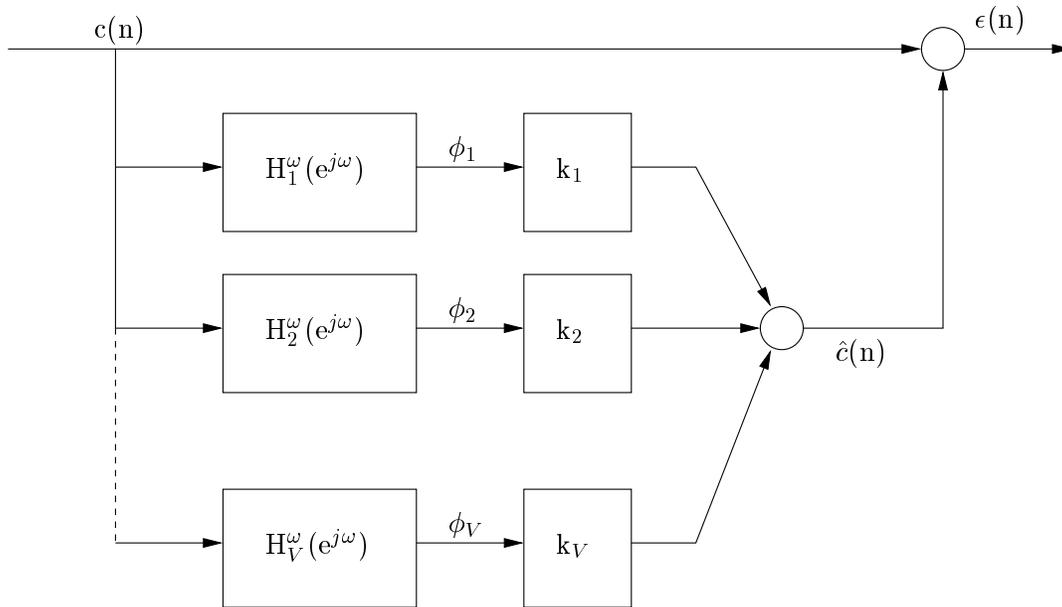


Figura 3.4: Modelo Inverso reordenado[40]

donde:

- $c(n)$: Señal de EEG
- $\hat{c}(n)$: Señal de EEG estimada
- k_i : Ganancias a estimar
- $H_i^\omega(e^{j\omega})$: Filtros sintonizados a las distintas frecuencias de EEG

tenemos que el error de predicción está dado por:

$$\varepsilon = c(n) - \hat{c}(n)$$

Siendo $\hat{c}(n)$ una combinación de funciones base ϕ_i .

Por otro lado, del teorema de ortogonalidad se tiene que el error en la estimación \hat{c} es mínimo cuando:

$$E[\varepsilon\phi_i^*] = E[\phi_i\varepsilon^*] = 0$$

Para el caso de dos dimensiones, lo anterior lo podemos ver gráficamente en la figura(3.5).

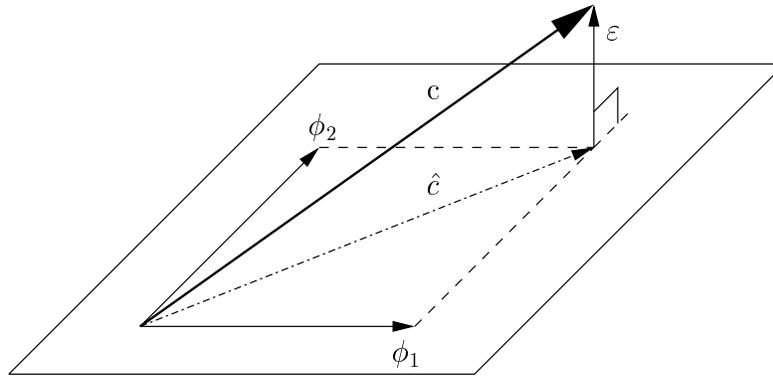


Figura 3.5: Teorema de proyección en 2 dimensiones

Y el error cuadrático medio está dado por:

$$E[\varepsilon c^*] = E[c \varepsilon^*]$$

Del modelo mostrado en la figura(3.4), tenemos que:

$$\phi_i = \sum_{-\infty}^{\infty} h_i(m)c(n-m), i = 1, 2 \dots V$$

Haciendo

$$H_i = [h_i(1) \ h_i(2) \ \cdots \ h_i(M-1)]^T$$

$${}_n\tilde{C} = [c(n) \ c(n-1) \ \cdots \ c(n-M+1)]^T$$

Por lo que

$$\phi_i(n) = H_i^T {}_n\tilde{C}$$

y

$$\hat{c}(n) = \sum_{i=1}^V k_i \phi_i(n) = \sum_{i=1}^V k_i H_i^T {}_n\tilde{C}$$

Sustituyendo en la condición de ortogonalidad del error

$$E \left[\left(c(n) - \sum_{i=1}^V k_i H_i^T {}_n\tilde{C} \right) \phi_j^*(n) \right] = 0; j = 1, 2 \dots V$$

$$E \left[\left(c(n) - \sum_{i=1}^V k_i H_i^T {}_n\tilde{C} \right) {}_n\tilde{C}^H H_j^* \right] = 0$$

$$E \left[H_j^H {}_n\tilde{C}^* c(n) - \sum_{i=1}^V k_i H_i^T {}_n\tilde{C} {}_n\tilde{C}^H H_j^* \right] = 0$$

$$H_j^H E \left[{}_n\tilde{C}^* c(n) \right] - \sum_{i=1}^V k_i H_i^T E \left[{}_n\tilde{C} {}_n\tilde{C}^H \right] H_j^* = 0 \quad (3.14)$$

Donde:

$$E \left[{}_n\tilde{C} {}_n\tilde{C}^H \right] =$$

$$= \begin{bmatrix} E[c(n)c(n)^*] & E[c(n)c(n-1)^*] & \cdots & E[c(n)c(n-M+1)^*] \\ E[c(n-1)c(n)^*] & E[c(n-1)c(n-1)^*] & \cdots & E[c(n-1)c(n-M+1)^*] \\ \vdots & \vdots & \ddots & \vdots \\ E[c(n-M+1)c(n)^*] & \cdots & \cdots & E[c(n-M+1)c(n-M+1)^*] \end{bmatrix}$$

$$E \left[{}_n\tilde{C}_n \tilde{C}^H \right] = \mathbf{R} = \begin{bmatrix} R_c(0) & R_c(1) & \cdots & R_c(M-1) \\ R_c(-1) & R_c(0) & \cdots & R_c(M-2) \\ \vdots & \vdots & \ddots & \vdots \\ R_c(1-M) & \cdots & \cdots & R_c(0) \end{bmatrix}$$

Como $\mathbf{R}(l) = \mathbf{R}(-l)$

$$E \left[{}_n\tilde{C}_n \tilde{C}^H \right] = \mathbf{R} = \begin{bmatrix} R_c(0) & R_c(1) & \cdots & R_c(M-1) \\ R_c(1) & R_c(0) & \cdots & R_c(M-2) \\ \vdots & \vdots & \ddots & \vdots \\ R_c(M-1) & \cdots & \cdots & R_c(0) \end{bmatrix}$$

Siendo \mathbf{R} la matriz de correlación con estructura Toeplitz y hermitiana simétrica.

El término $E[{}_n\tilde{C}^* c(n)]$ se define como:

$$E[{}_n\tilde{C}^* c(n)] = \begin{bmatrix} E[c(n)c(n)^*] \\ E[c(n-1)c(n)^*] \\ \vdots \\ E[c(n-M+1)c(n)^*] \end{bmatrix}$$

Qué corresponde a la primer columna de \mathbf{R} por lo que se puede escribir como:

$$E[{}_n\tilde{C}^*] = \mathbf{R}^T I_1$$

Donde I_1 es:

$$I_1 = \left[1 \ 0 \ \cdots \ 0 \right]^T \quad (M \times 1)$$

Por otro lado, agrupando las H_i :

$$\mathbf{H} = \begin{bmatrix} H_1^T \\ H_2^T \\ \vdots \\ H_V^T \end{bmatrix} \quad (V \times M)$$

Finalmente, de lo anterior, podemos escribir la ecuación(3.14) como:

$$(\mathbf{H}\mathbf{R}\mathbf{H}^H)\mathbf{K} = \mathbf{H}^*\mathbf{R}^T I_1$$

Despejando K:

$$K_{LMS} = (\mathbf{H}\mathbf{R}\mathbf{H}^H)^{-1}\mathbf{H}^*\mathbf{R}^T I_1 \quad (3.15)$$

3.5. Estimación de parámetros del modelo de generación de EEG mediante algoritmo RLS

El algoritmo de mínimos cuadrados (LS por sus siglas en inglés) permite obtener una solución determinística al problema de estimación lineal. El empleo de este método involucra la inversión de la matriz de autocorrelación de la señal EEG, lo que computacionalmente resulta costoso. Para solventar este problema se puede utilizar una estrategia recursiva que se encargue de forma indirecta de la inversión de la matriz. De allí el nombre de método de mínimos cuadrados recursivo (RLS por sus siglas en inglés);[17].

El problema a resolver en este trabajo mediante el uso del método RLS es un problema conocido como identificación de fuente, figura(3.6). Consideramos al cerebro como un filtro FIR cuya salida es la señal de eeg y queremos estimar sus parámetros mediante el uso del algoritmo RLS. El algoritmo RLS obtiene los coeficientes que permiten minimizar la diferencia entre la señal EEG real y aquella estimada por nosotros; el algoritmo minimiza esta diferencia en el sentido de los mínimos cuadrados, es decir, la suma de los cuadrados de la diferencia entre la señal real y la estimada; [23].

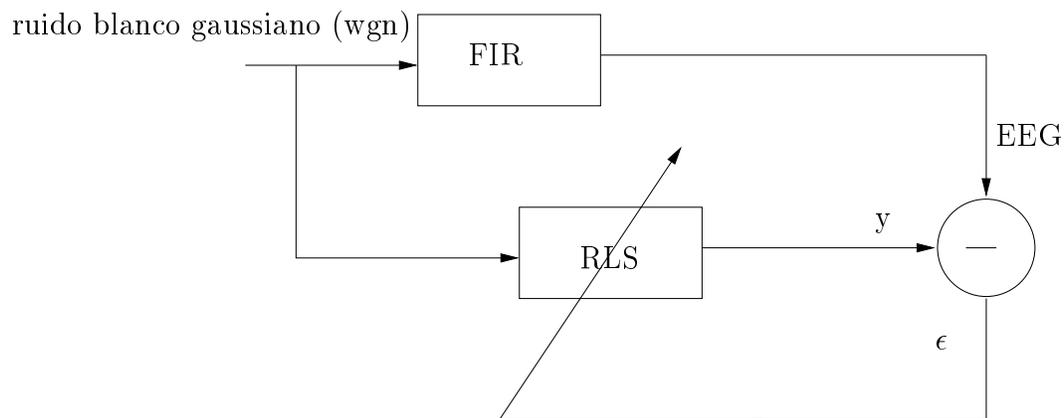


Figura 3.6: Identificación del modelo RLS del cerebro

El criterio de los mínimos cuadrados se define como:

$$\sum_{n=0}^k \lambda^{k-n} |\varepsilon_p^f|^2$$

donde:

ε_p^f : Error de predicción.

λ : Constante menor a 1 conocida como factor de olvido.

De la sección anterior: *Modelo autorregresivo de la señal EEG* obtuvimos que la solución al problema de minimización bajo el criterio del error cuadrático promedio (MSE) está dada por:

$$\mathbf{R}_p[k-1]A_p = -\mathbf{r}_p[k]$$

Se demuestra; [4], que la solución al problema de los mínimos cuadrados tiene la misma forma que la solución MSE; sin embargo, las matrices \mathbf{R}_p y \mathbf{r}_p se definen bajo el criterio de los mínimos cuadrados como sigue:

$$\mathbf{R}_p^{Ls}[k-1] \triangleq \sum_{n=0}^k \lambda^{k-n} Y_p(n-1)Y_p^*(n-1)$$

$$r_p^{Ls}[k] \triangleq \sum_{n=0}^k \lambda^{k-n} Y_p(n-1)y(n)$$

Finalmente la solución al método de los mínimos cuadrados queda como:

$$R_p^{Ls}[k-1]A_p = -r_p^{Ls}[k]$$

La particularidad del método RLS, como ya expusimos, se centra en la obtención indirecta de la inversa de la matriz R_p^{Ls} mediante un procedimiento recursivo.

Si $R_p^{Ls}[k]$ se escribe recursivamente resulta:

$$R_p^{Ls}[k] = \lambda R_p^{Ls}[k-1] + Y_p[k]Y_p^*[k]$$

La inversa de $R_p^{Ls}[k]$ queda como sigue :

$$R_p^{Ls}[k]^{-1} = \left[\lambda R_p^{Ls}[k-1] + Y_p[k]Y_p^*[k] \right]^{-1}$$

Del lema de inversión matricial se tiene que:

$$\left[A + BD^{-1}C \right]^{-1} = A^{-1} - A^{-1}B \left[D + CA^{-1}B \right]^{-1} CA^{-1}$$

para nuestro caso:

$$A = \lambda R_p^{Ls}[k-1] ; B = Y_p[k] ; D = I ; C = Y_p^*[k]$$

por lo tanto:

$$R_p^{Ls}[k]^{-1} = \frac{1}{\lambda} \left[R_p^{Ls}[k-1]^{-1} - \frac{R_p^{Ls}[k-1]^{-1} Y_p[k] Y_p^*[k] R_p^{Ls}[k-1]^{-1}}{\lambda + Y_p^*[k] R_p^{Ls}[k-1]^{-1} Y_p[k]} \right]$$

Donde λ sirve para ponderar las muestras de instantes anteriores de tal forma que a las muestras más recientes tienen un peso mayor que las muestras más alejadas;[4] .

3.6. Representaciones tiempo - frecuencia (TFR)

La transformada de Fourier ha sido de gran ayuda en el procesamiento de señales, sin embargo en el mundo real, el uso de esta herramienta no basta para caracterizar el comportamiento de la señal. Por ejemplo supóngase una señal compuesta por varias frecuencias a diferentes instantes tal como la mostrada en la figura(3.7) donde la señal se compone por dos senoidales, la primera a 20 hz y la segunda de 10 Hz.

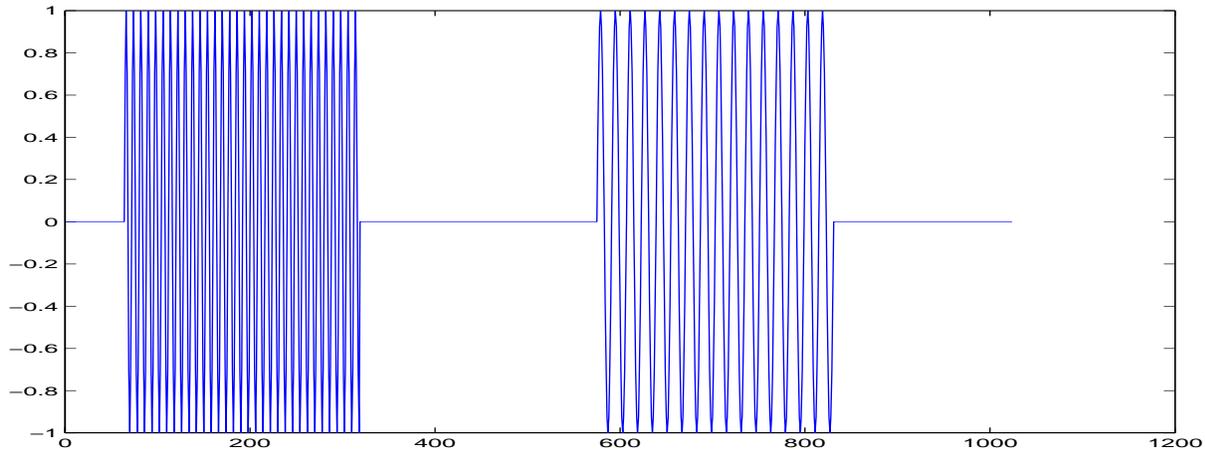


Figura 3.7: Señal compuesta por senoidales a 20hz y 10hz

Al calcular el espectro de potencia mediante la transformada de Fourier obtenemos el resultado de la figura(3.8), donde podemos observar las dos espigas correspondientes a las frecuencias de la señal original; sin embargo, no tenemos la posibilidad de saber en que tiempo ocurre cada frecuencia.

Las distribuciones tiempo - frecuencia son herramientas matemáticas que nos permiten conocer el comportamiento de una señal a lo largo del tiempo junto con su comportamiento en frecuencia. En el campo de la encefalografía se ha utilizado las técnicas de tiempo - frecuencia principalmente para la clasificación [15], la extracción de características de las señales de EEG [46] y en aplicaciones como detección de señales anormales al funcionamiento del cerebro;[54] o epilepsia [7];[52] con resultados notables.

Los algoritmos tiempo - frecuencia tratan de solventar el inconveniente que tiene Fourier de representar únicamente el contenido frecuencial de una señal y perder toda referencia con el tiempo en que ésta se presenta; sin embargo, en las distribuciones tiempo - frecuencia surgen otros problemas, como por ejemplo: los términos de cruce y la resolución; motivo por el cual se desarrollan un gran número de distribuciones tiempo - frecuencia. Dada la gran cantidad de distribuciones tiempo - frecuencia que existen y por cuestiones didácticas, en

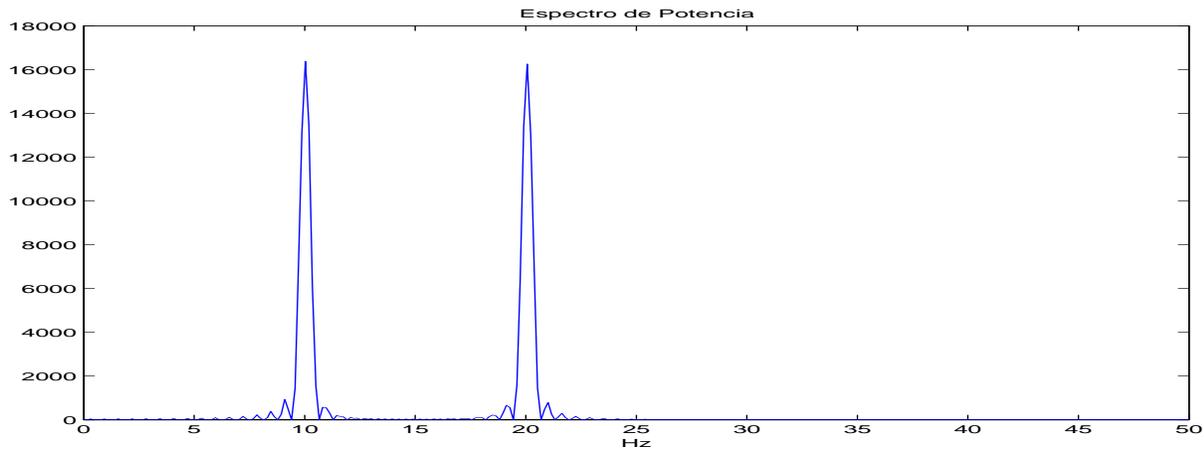


Figura 3.8: Espectro de la señal compuesta por senoiales a 20hz y 10hz

este trabajo nos referiremos a tres de ellas, pertenecientes a la clase de Cohen [8]: Wigner Ville, Choi - Williams, Bessel; y a un caso aparte, por no pertenecer a la clase de Cohen, el espectrograma con la transformada corta de Fourier (STFT).

La idea general de una distribución tiempo - frecuencia es la obtener información del comportamiento frecuencial de una señal a cada instante de tiempo, así como su frecuencia instantánea a lo largo del tiempo y también, por ejemplo, si queremos conocer la energía total de la señal en su representación tiempo - frecuencia tendremos que sumar la energía en cada tiempo y a una frecuencia dada, lo que implica,[9]:

$$\int TFR_x(t, f) dt df = E_x$$

Si queremos conocer la energía en las diferentes frecuencias, obtendríamos lo que se conoce como marginal de tiempo,[9]:

$$\int TFR_x(t, f) df = |x(t)|^2$$

O bien, si deseamos conocer la energía para una frecuencia, obtenemos la marginal de frecuencia,[9]:

$$\int TFR_x(t, f) dt = |X(f)|^2$$

3.6.1. Espectrograma

El espectrograma es una herramienta muy usada en el análisis tiempo frecuencia. La idea básica atrás del espectrograma es la de considerar la señal como estacionaria o al menos cuasi estacionaria en una ventana de tiempo, en la cual se calcula su espectro mediante la

transformada de Fourier para después mover la ventana y repetir el proceso. La expresión continua del espectrograma está dado por:

$$STFT_x(t, \omega) = \int x(\tau)h(\tau - t)e^{-j\omega\tau}d\tau \quad (3.16)$$

Donde $h(\tau)$ es una función ventana. Una de las desventajas del espectrograma es el compromiso entre la longitud de la ventana y la resolución en tiempo y frecuencia. Ventanas grandes de tiempo proporcionan buena resolución en frecuencia, pero pobre resolución en tiempo; mientras que ventanas cortas de tiempo proporcionan buena resolución en tiempo pero pobre resolución en frecuencia.

La expresión discreta del espectrograma está dada por:

$$STFT[n, f] = \left| \sum_{k=-N+1}^{N-1} h[k]x[n+k]e^{-j2\pi fk} \right|^2 \quad (3.17)$$

En la figura(3.9) y figura(3.10) se aprecia el resultado del espectrograma en dos y tres dimensiones calculado a la señal mostrada en la figura(3.7).

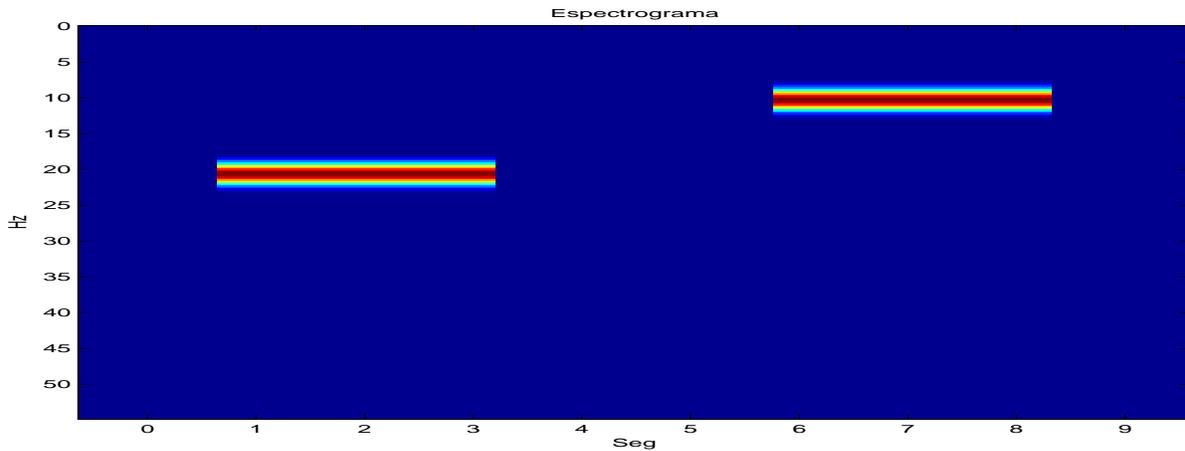


Figura 3.9: Espectrograma de una señal compuesta por frecuencias de 20hz y 10hz

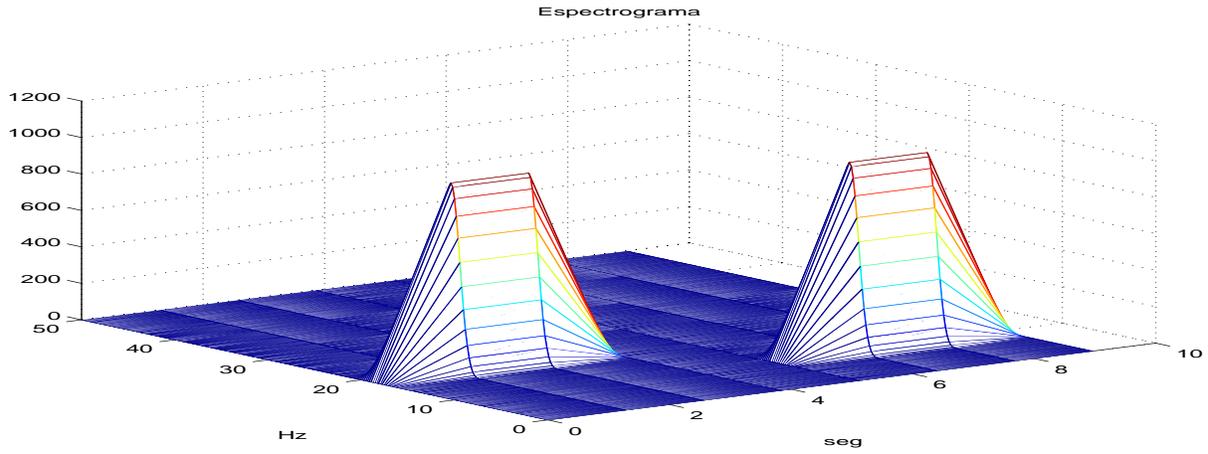


Figura 3.10: Espectrograma 3D de una señal compuesta por frecuencias de 20hz y 10hz

3.6.2. Distribuciones de la Clase de Cohen

La Clase de Cohen define de manera general a una familia de distribuciones tiempo - frecuencia que comparten una misma estructura, [9]. La Clase de Cohen se define como:

$$C_x(t, \omega) = \frac{1}{2\pi} \int \int \int x(\mu + \frac{\tau}{2})x^*(\mu - \frac{\tau}{2})\Phi(\xi, \tau)e^{i(\xi\mu - \tau\omega - \xi t)}d\mu d\tau d\xi \quad (3.18)$$

Donde:

$\Phi(\xi, \tau)$: Es llamado el kernel de la distribución, el cual tiene como propósito el eliminar lo mejor posible los términos cruzados de la señal, preservar sus autotérminos y mantener una buena resolución. Para facilitar el estudio de las distribuciones con sólo tener que modificar el tipo de kernel, éste debe cumplir con ciertas condiciones para que la distribución cumpla con determinadas características,[44]:

3.6.3. Distribución Wigner - Ville

La Distribución Wigner - Ville fue presentada por Wigner en 1932, como una aportación a la física cuántica y posteriormente Ville en 1948 establece la forma actualmente conocida, como relata Rosado [44]. Matemáticamente se define como:

$$WVD[n, f] = 2 \sum_{k=-\infty}^{\infty} x[n+k]x^*[n-k]e^{-j4\pi fk} \quad (3.19)$$

En comparación con la transformada corta de Fourier, conocida como espectrograma, la distribución Wigner - Ville nos ofrece mayor resolución a expensas de la aparición de artefactos como son los términos de cruce que pueden ser reducidos mediante la selección apropiada de una ventana suavizante como muestra Hope; [1], y la aparición de energías negativas,

figura(3.11); lo que constituye su principal desventaja.

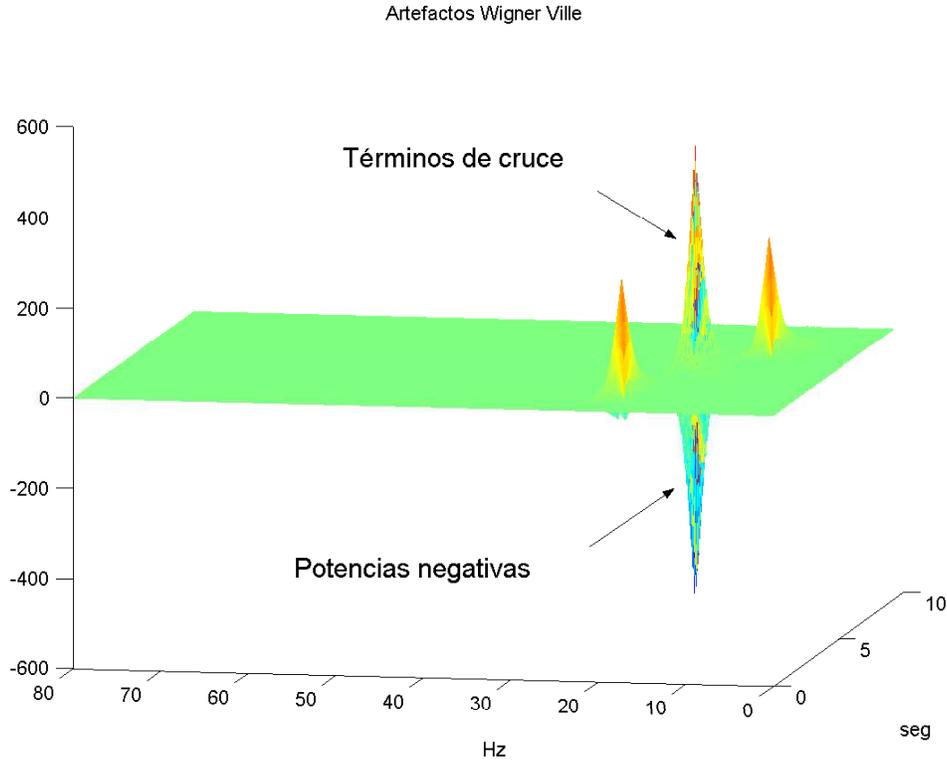


Figura 3.11: Artefactos en Distribución Wigner - Ville para una señal compuesta por frecuencias de 20hz y 10hz

Excepto por fines de comparación con otros métodos tiempo frecuencia, la distribución Wigner - Ville es raramente utilizada en el tratamiento de señales bioeléctricas debido a que los términos de cruce no tienen significado biológico,[2]. Para evitar las interferencias de la distribución se realiza un “suavizado” mediante un Kernel.

3.6.4. Distribución Choi - Williams

Choi - Williams fue uno de los primeros investigadores en crear una distribución tiempo frecuencia usando el método de kernel; como se expone en Baura[5]. La distribución Choi - Williams o distribución exponencial, se basa en el kernel:

$$\Phi(\xi, \tau) = e^{-\frac{\xi^2 \tau^2}{\sigma}}$$

Donde sigma es un parámetro que puede variar entre 1 y 80; Corlay[10]. Cuando σ tiende al límite superior, la distribución tiende a parecerse a la distribución Wigner - Ville. Cuando σ tiende al límite inferior, el kernel presenta un pico más cercano al origen y es cuando se

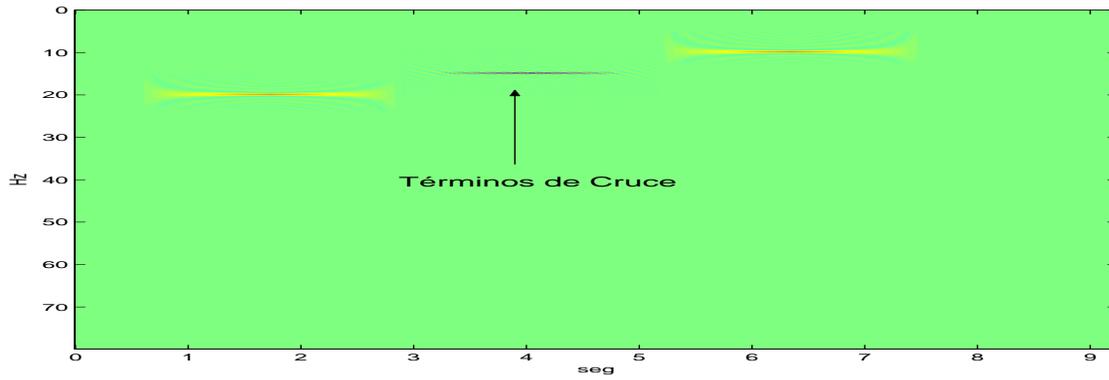


Figura 3.12: Distribución Wigner - Ville de señal compuesta por frecuencias de 20hz y 10hz

eliminamos los términos cruzados; Corlay[10].

Matemáticamente la distribución Choi - Williams se define como:

$$CW[n, f] = 2 |h[0]|^2 |x[n]|^2 + 2 \sum_{\substack{k=-N+1 \\ k \neq 0}}^{N-1} |h[k]|^2 K[n, k] e^{-j4\pi f k} \quad (3.20)$$

En la figura(3.13) y figura(3.14) podemos observar la eliminación de los términos de cruce que obtuvimos con la distribución Wigner - Ville, figura(3.11) y figura(3.12)

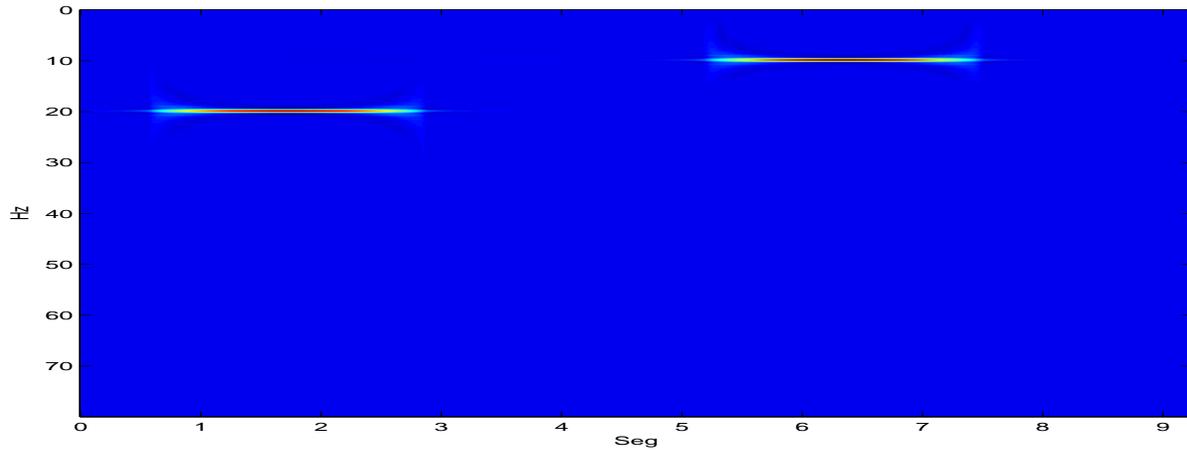


Figura 3.13: Distribución Choi - Williams de señal compuesta por frecuencias de 20hz y 10hz

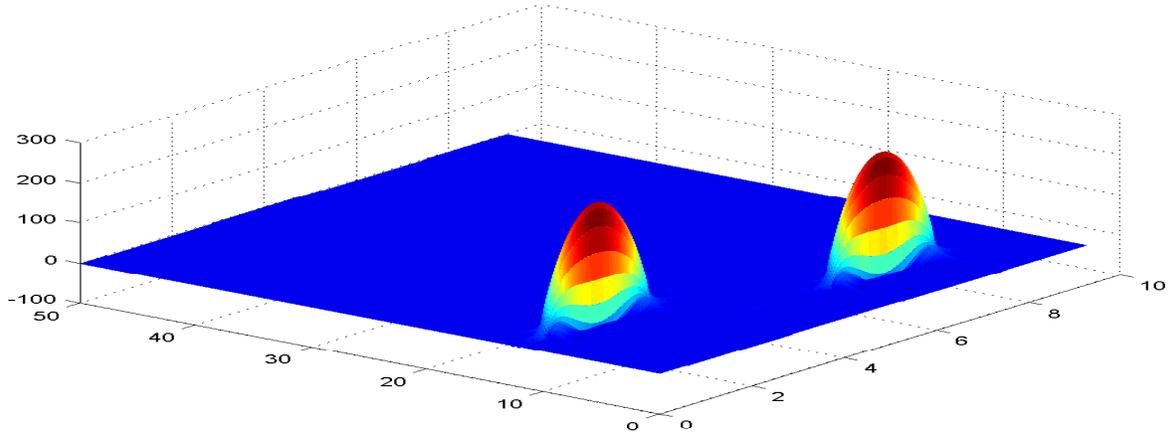


Figura 3.14: Eliminación de los términos de cruce con la Distribución Choi - Williams

3.6.5. Distribución Bessel

La distribución Bessel forma parte de la clasificación de Cohen, [9], fue introducida primeramente en estudios de ultrasonido y doppler; esta distribución fue concebida para adaptarse en ambientes aleatorios no estacionarios. Su kernel se define como:

$$\Phi(\xi, \tau) = \frac{J_1(2\pi\alpha\xi\tau)}{\pi\alpha\xi\tau}$$

Donde J_1 es la función Bessel tipo uno de orden uno; α es un factor de escala $\alpha > 0$.

La representación discreta de esta distribución es:

$$BD[n, f] = -2 |h[0]|^2 |x[n]|^2 + 2 \sum_{m=0}^{N-1} K[n, k] e^{-j4\pi f k}$$

$$K[n, m] = \sum_{p=-2\alpha m}^{2\alpha m} \frac{1}{\pi\alpha m} \sqrt{1 - \left(\frac{p}{2\alpha m}\right)^2} x[n + p + m] x^*[n + p - m] \quad (3.21)$$

En la figura(3.15) y figura(3.15) muestran el resultado de la distribución Bessel aplicada a la señal de la figura(3.7). Podemos ver sobre todo, que con esta distribución el ancho de banda de las zonas de mayor frecuencia se reduce.

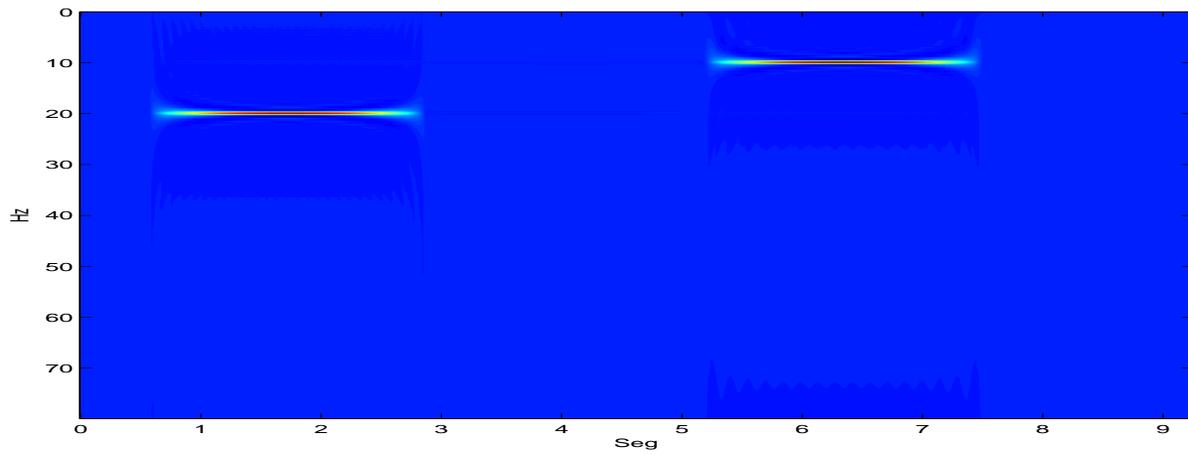


Figura 3.15: Distribución Bessel de señal compuesta por frecuencias de 20hz y 10hz

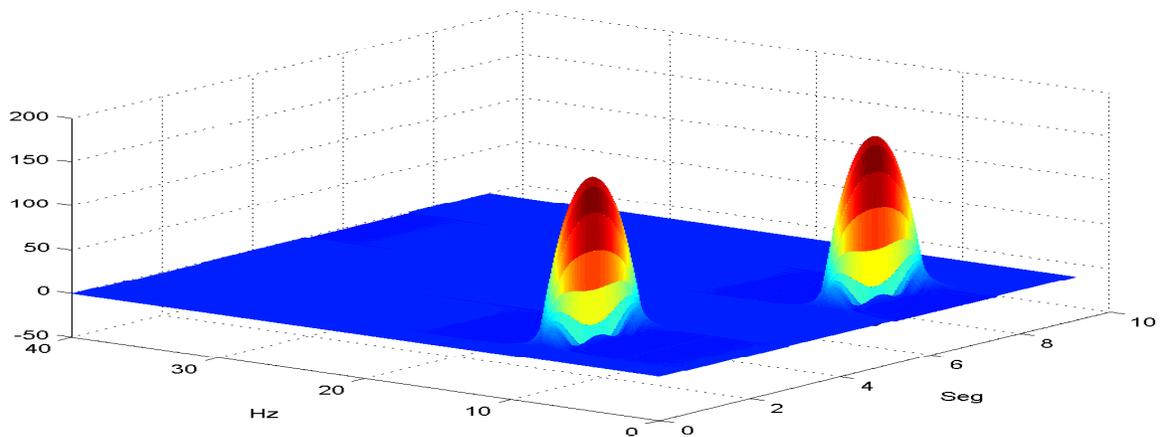


Figura 3.16: Distribución Bessel 3D de señal compuesta por frecuencias de 20hz y 10hz

3.7. Transformadas tiempo - escala

Las wavelets ² son familias de funciones definidas a partir de una o varias funciones iniciales conocidas como funciones madre $\varphi(x)$.

$$\varphi_{a,b} = \frac{\varphi\left(\frac{x-b}{a}\right)}{\sqrt{|a|}}; a, b \in \mathbb{R}, a \neq 0$$

A las funciones madre se le agrega un parámetro a que controla la escala, esto es contrac-

²Algunos de los grandes investigadores de lengua castellana traducen el término wavelet como onduleta

ciones o dilataciones de la función, y un parámetro b que traslada la función. Estos parámetros brindan a las wavelets su característica de análisis en tiempo y a diferentes resoluciones (escala).

Existen tantas wavelets como funciones madre, de hecho, la selección de la mejor wavelet depende de la aplicación, sin embargo existen wavelets consideradas clásicas por ser las más famosas y estudiadas; entre ellas encontramos la Haar, Daubechies, “Mexican Hat”, Gaussiana, Coiflet; [21], etc... En este trabajo nos referiremos únicamente a la wavelets Haar y Daubechies 4.

3.7.1. Haar

Alfred Haar involuntariamente descubrió la wavelet haar alrededor de 1909 mientras hacía estudios sobre bases generadoras de espacios como el espacio Lebesgue [31]. La función madre $h(x)$ de la wavelet Haar está definida como:

$$\varphi(x) = \begin{cases} 1; 0 \leq x < \frac{1}{2} \\ -1; \frac{1}{2} \leq x < 1 \\ 0; \text{otrovalor} \end{cases} \quad (3.22)$$

3.7.2. Daubechies

La transformada Daubechies toma su nombre en honor a su desarrolladora, la Dra. Ingrid Daubechies. Podemos nombrar la transformada Daubechies de acuerdo al número de coeficientes utilizados en su función de escala; por ejemplo la transformada Daubechies 4 está definida por los siguientes 4 coeficientes:

$$\alpha_1 = \frac{1 + \sqrt{3}}{4\sqrt{2}}$$

$$\alpha_2 = \frac{3 + \sqrt{3}}{4\sqrt{2}}$$

$$\alpha_3 = \frac{3 - \sqrt{3}}{4\sqrt{2}}$$

$$\alpha_4 = \frac{1 - \sqrt{3}}{4\sqrt{2}}$$

Donde la función escala está definida como:

$$V_{j-1} = \alpha_1 V_j^{2m-1} + \alpha_2 V_j^{2m} + \alpha_3 V_j^{2m+1} + \alpha_4 V_j^{2m+2}$$

$$V_j = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & 0 \\ 0 & 0 & \cdots & 1 \end{bmatrix}$$

3.8. Análisis de secuencias CAP en el Plano tiempo - frecuencia

En este trabajo tratamos los resultados de los métodos tiempo frecuencia como imágenes, para ello convertimos los resultados en 256 niveles de gris y partiendo del hecho que los estados de la secuencia CAP son binarios, binarizamos las imágenes.

La binarización es el proceso de convertir una imagen representada con cierto número de niveles de gris en otra con solo dos niveles: blanco y negro. Para ello, es necesario fijar un umbral de binarización, todo valor de la imagen que supere ese nivel se considera blanco y lo que resulte estar por debajo del umbral se considerará negro; [16]. El punto clave del proceso de binarización radica en la correcta selección del umbral, el cual permita conservar la conectividad de las regiones; [45]. A partir de la binarización podemos identificar las secuencias CAP de manera más fácil, asociando el nivel 255 de gris a la Fase B y el nivel 0 a la Fase A de una secuencia CAP; esto permite separar los umbrales entre Fases de manera que se reduzca el error en la identificación. En este trabajo estableceremos umbrales de binarización de manera heurística, tratando de evidenciar las dos fases de la secuencia CAP, sin embargo será necesario desarrollar un método automático para la selección del umbral óptimo.

Aún cuando en este trabajo se realiza la identificación de secuencias CAP mediante la binarización, podemos proponer otras técnicas de imagenología para su identificación, tal es el caso del análisis de textura, partiendo del hecho que las texturas de las Fases A y B son diferentes. O la segmentación de espectrogramas para la extracción de información como se propone en [28].

3.9. Conclusiones

El procesamiento de señales ha contribuido al desarrollo del análisis de las señales de EEG, el cual, con el tiempo se ha ido perfeccionando y con el advenimiento de equipos de cómputo más avanzados su complejidad ha ido en aumento; sin embargo, el aumento en la complejidad del análisis de las señales y la cantidad de algoritmos con la que hoy día se

cuenta, no garantiza que sus resultados sean los más adecuados para cada problema, ya que muchos algoritmos aplicados a la señal de EEG tienen su origen en aplicaciones totalmente disímboles, es por eso que aquí hemos presentado distintos algoritmos del procesamiento digital de señales, desde los algoritmos simples basados en técnicas temporales, pasando por los algoritmos pertenecientes al análisis en frecuencia y finalmente aquellos que mezclan ambos enfoques y que hemos presentado como algoritmos tiempo - frecuencia. Todos estos algoritmos los hemos adecuado a las características y necesidades que plantea el estudio de la señal de EEG y más específicamente al problema de la identificación de secuencias CAP.

Capítulo 4

Implementación de Algoritmos para la Identificación de Secuencias CAP (ISCAP)

En esta sección mostramos como fueron utilizados los diversos algoritmos para lograr la identificación de una misma secuencia CAP. Los algoritmos son los siguientes.

Identificación de algoritmos CAP mediante:

- Potencia
- Estadísticas temporales
- Coeficientes de Correlación
- Modelo Autorregresivo
- Cambio en coeficientes FIR usando RLS
- Métodos tiempo - frecuencia
 - Transformada corta de Fourier (SFT)
 - Transformada Wigner - Ville
 - Transformada Bessel
 - Transformada Choi - Williams
- Métodos tiempo - escala
 - Transformada Haar
 - Daubechies 4

4.1. Método

Las señales empleadas en este trabajo fueron de dos tipos: señales sintéticas y señales reales. Las señales reales fueron obtenidas gracias a la Doctora Rosa María Campos Morales responsable del Laboratorio de Trastorno del Dormir de la Facultad de Psicología. Las señales pertenecen a un registro de sueño de un sujeto sano; la señal de EEG real corresponde a la derivación C4 - A1, adquirida con una frecuencia de muestreo de 100 Hz y una resolución de 12 bits. La obtención de señales sintéticas se detalla en la sección siguiente. Las señales sintéticas se utilizaron en la calibración de los algoritmos; los cuales una vez calibrados fueron aplicados a las señales reales.

Como características discriminantes de las secuencias CAP se emplearon la potencia de la señal, los coeficientes de autocorrelación; los coeficientes A_i de un modelo autorregresivo de la señal, coeficientes obtenidos con el algoritmo RLS; así como métodos tiempo - frecuencia: STF, Wigner - Ville, Choi - Williams, Bessel; y métodos tiempo - escala: Transformada Haar y Daubechies.

4.2. Señales Sintéticas de EEG

Las señales sintéticas de EEG se obtuvieron mediante el modelo de EEG resonante propuesto por Martins [32]. En nuestro caso los filtros fueron estimados mediante modelos autorregresivos como sigue:

Para 50 sujetos se clasificaron los ritmos de EEG correspondientes a ritmo alfa, ritmo beta, ritmo delta y ritmo teta. Para cada uno de ellos se calculó un modelo AR de orden 15. El orden fue estimado en base a los criterios AIC, (Akaike Information-theoretic Criteria) y MDL (Minimum Description Length) presentados en Paliniappan [35]. Los criterios se definen como:

$$\mathbf{AIC} \quad AIC(P) = N \ln(\sigma_\epsilon^2) + 2P$$

$$\mathbf{MDL} \quad MDL(P) = N \ln(\sigma_\epsilon^2) + P \ln(N)$$

Donde:

N: Número de muestras de la señal a modelar.

σ_ϵ^2 : Varianza de la señal a modelar.

P: Orden propuesto para el modelo.

La figura(4.1) muestra el comportamiento de los criterios AIC y MDL en función del orden para una señal EEG asociada a un modelo autorregresivo; podemos observar que el orden adecuado para modelar dicha señal corresponde a un orden 15, que para los dos criterios usados resulta ser un mínimo. El cuadro[4.1] muestra los coeficientes del modelo autorregresivo de orden 15 obtenidos para las 4 bandas principales del EEG; por otro lado, las figuras (4.2;4.3) muestran la respuesta en frecuencia de las 4 bandas principales del EEG obtenidas a partir de los coeficientes del cuadro[4.1].

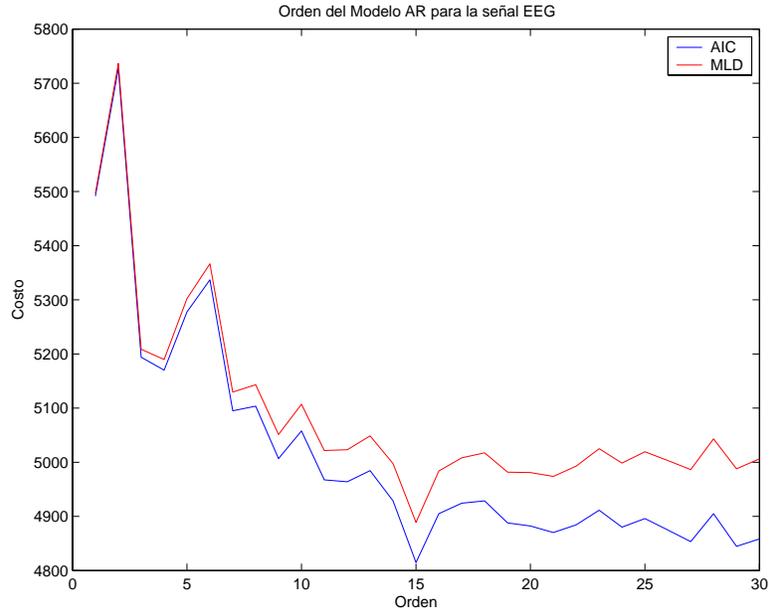


Figura 4.1: Selección del Orden Modelo AR en nuestro trabajo

Alfa	Beta	Delta	Teta
1.0000	1.0000	1.0000	1.0000
-1.8085	1.3892	-1.7445	-1.9160
1.4456	2.0812	0.4983	0.9438
-0.1319	2.7491	0.1442	0.0662
0.1756	3.2948	0.1302	0.1593
-0.1240	3.6362	0.0277	-0.0891
0.1884	3.7326	0.0275	0.0145
0.0689	3.5814	-0.0152	-0.0868
0.2111	3.2196	-0.0072	0.0185
0.0610	2.7074	-0.0244	-0.0254
0.1113	2.1222	-0.0124	0.0504
0.0185	1.5374	-0.0172	0.0219
0.0692	1.0144	-0.0077	0.0432
0.0243	0.5939	-0.0078	0.0052
0.0315	0.2949	-0.0055	-0.0959

Cuadro 4.1: Coeficientes AR Obtenidos para cada ritmo (alfa, beta, delta, y teta)

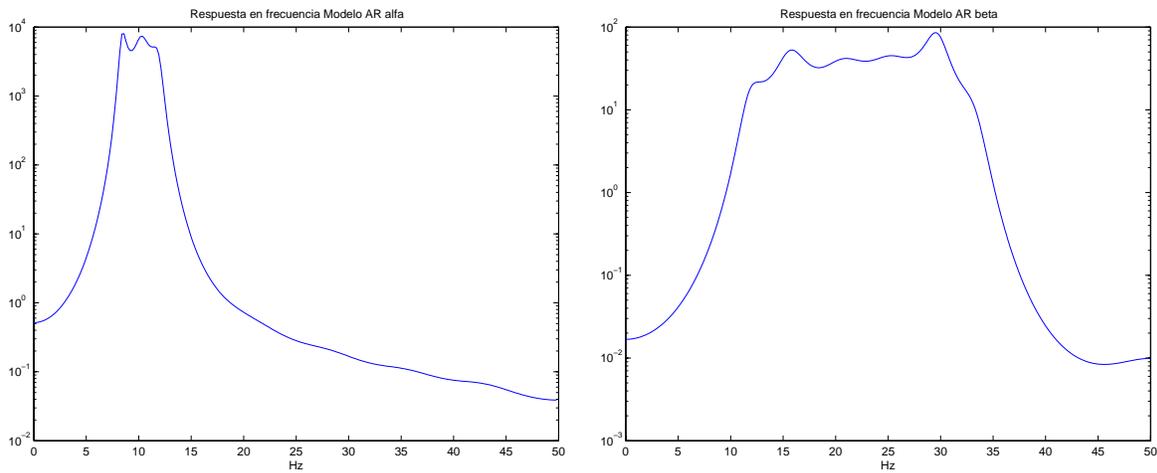


Figura 4.2: Respuesta en frecuencia. Izquierda: Alfa, Derecha: Beta

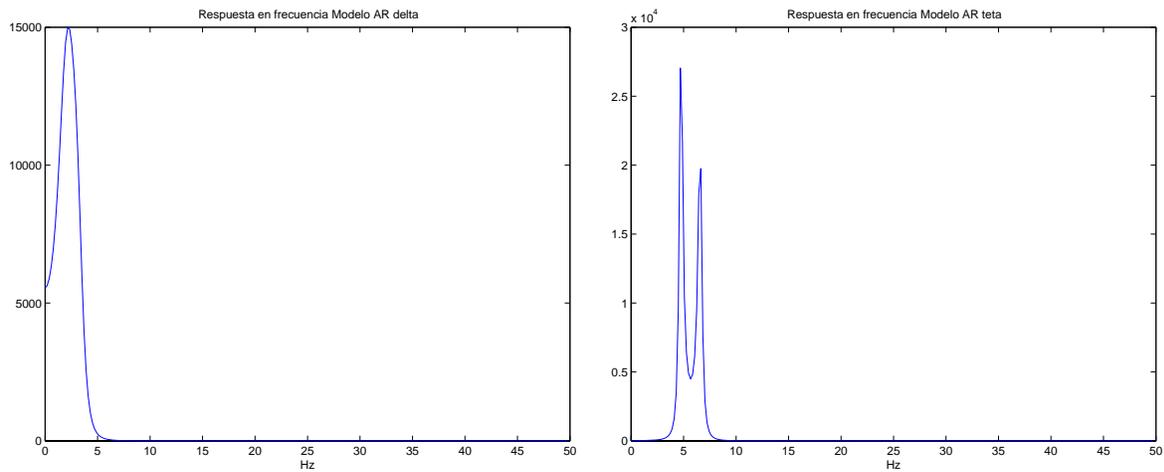


Figura 4.3: Respuesta en frecuencia. Izquierda: Delta, Derecha: Teta

4.2.1. Simulación de señales

A continuación se presenta la simulación de los 4 tipos fundamentales de EEG: Alfa, Beta, Teta, Delta. Se muestra el comportamiento en el plano temporal, en el dominio de la frecuencia y en el plano tiempo - frecuencia. El comportamiento temporal de la señal fue obtenido a partir del modelo autorregresivo determinado por los coeficientes mostrados en el cuadro[4.1]. El comportamiento en el dominio de la frecuencia fue calculado mediante 256 coeficientes de la FFT (Transformada Rápida de Fourier); en tanto que el comportamiento en el plano tiempo - frecuencia fue obtenido mediante la SFT sobre ventanas de 256 muestras y traslape de 0.5 segundos. Las simulaciones de las señales de EEG fueron realizadas tomando en cuenta las características descritas en [37], las cuales se muestran en el cuadro[4.2].

Señal	Voltaje	Frecuencia
Alfa	$5\mu V - 20\mu V$	8Hz - 12 Hz
Beta	$2\mu V - 5\mu V$	mayores a 13Hz
Teta	$50\mu V - 75\mu V$	4Hz - 7Hz
Delta	$75\mu V - 220\mu V$	menores a 3.5 Hz

Cuadro 4.2: Características de la señal EEG [37] utilizadas para la simulación

Alfa

La figura(4.4) muestra la señal sintética correspondiente al ritmo alfa obtenida; podemos observar que el ancho de banda de la señal se distribuye alrededor de los 10 hz, lo que corresponde con el ritmo alfa de las señales reales,[37]. Por otro lado, la amplitud de la señal se estableció dentro del rango de los $5\mu\text{V}$ a los $20\mu\text{V}$ descrito en [37].

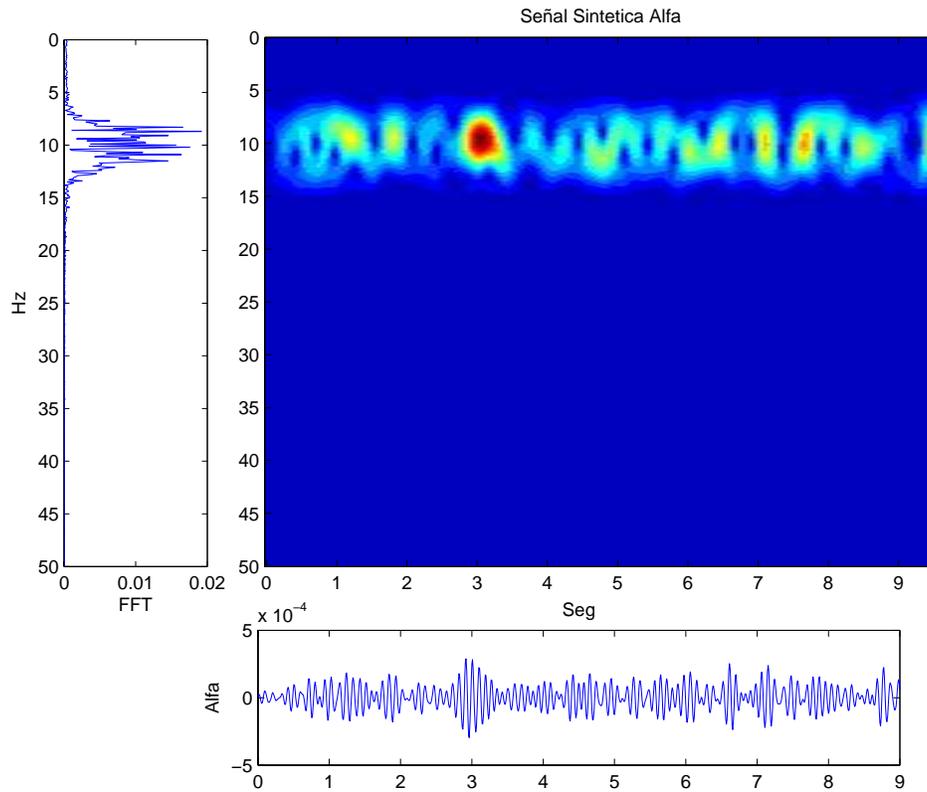


Figura 4.4: Señal Alfa Sintética

Beta

La figura(4.5) muestra la señal sintética beta. La amplitud promedio de la señal se estableció en $2 \mu\text{V}$ de acuerdo en lo descrito en [37] Mientras que el contenido frecuencial de esta señal abarca frecuencias mayores a los 12 Hz, frecuencia que se establece en [37] como limite inferior para una señal tipo beta.

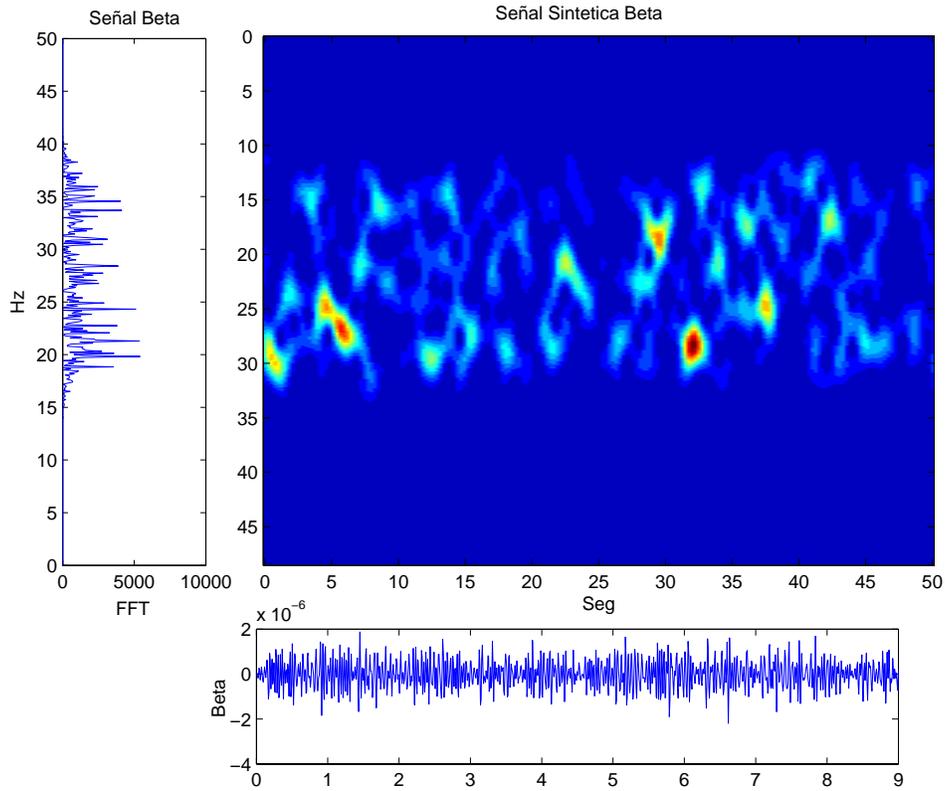


Figura 4.5: Señal Beta Sintética

Teta

La figura(4.6) muestra la señal sintética teta. La amplitud de la señal se estableció alrededor de los $50 \mu\text{V}$ observandose también que el contenido frecuencial de la señal se encuentra alrededor de los 5 hz; parámetros que corresponden a lo expuesto en [37].

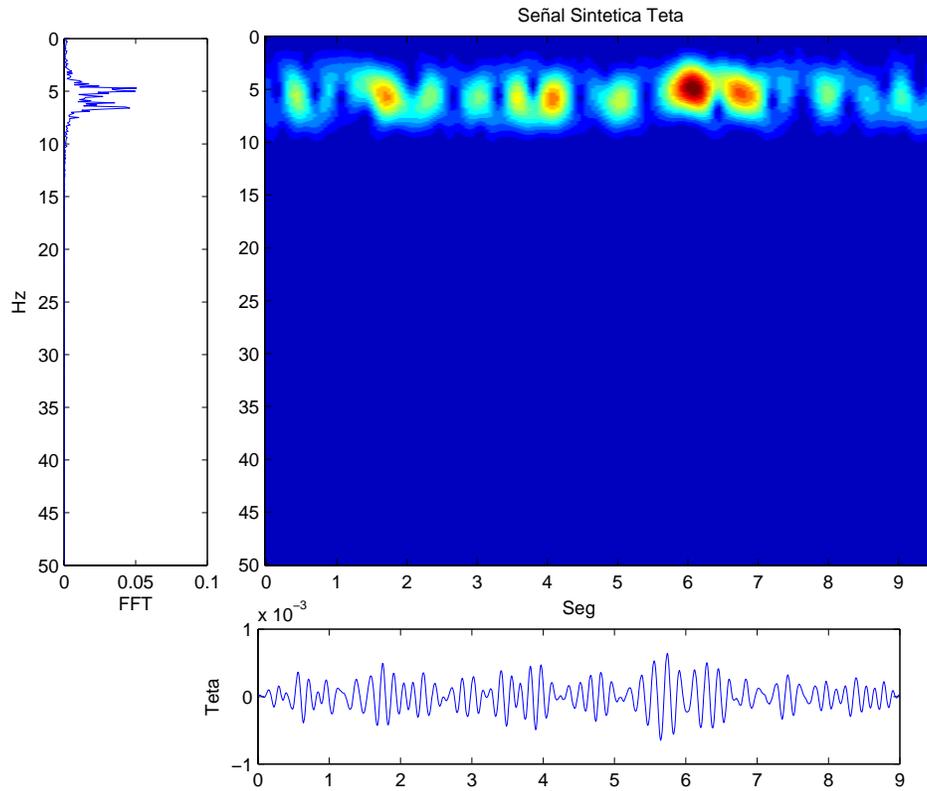


Figura 4.6: Señal Teta Sintética

Delta

La figura(4.7) muestra la señal sintética delta, la cual permite verificar que es la señal de mayor amplitud, alrededor de los $100 \mu\text{V}$ y que tiene frecuencias lentas alrededor de los 2.5 Hz. Esto corresponde a lo expuesto en [37].

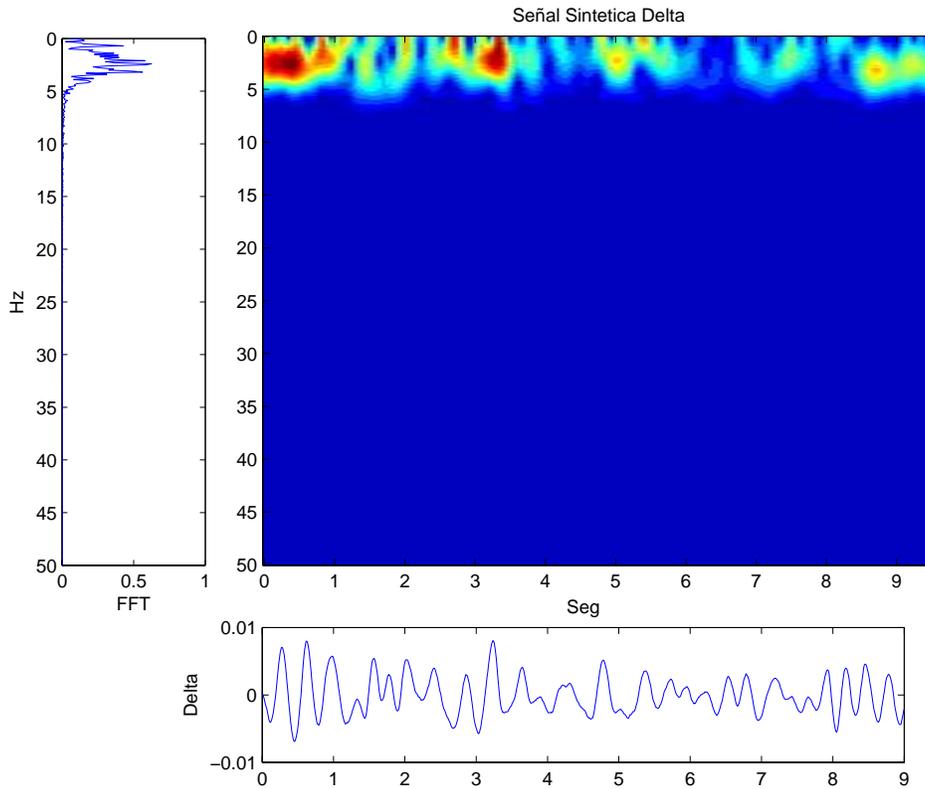


Figura 4.7: Señal Delta Sintética

4.2.2. Estimación de la respuesta de la corteza cerebral

La respuesta de la corteza cerebral fue estimada a partir de un segmento de la señal real de 30 segundos correspondiente a la etapa MOR del sueño de un sujeto. De acuerdo con Rosa y Martins [34], la fase MOR se caracteriza por la ausencia de actividad rítmica, por lo que las ganancias del modelo de EEG mostrado en la figura(3.2) valen cero; lo anterior implica que la señal registrada es únicamente la señal de fondo de EEG que se ve afectada por la corteza del encéfalo.

La figura(4.8) muestra el resultado del espectro paramétrico de la señal MOR obtenida.

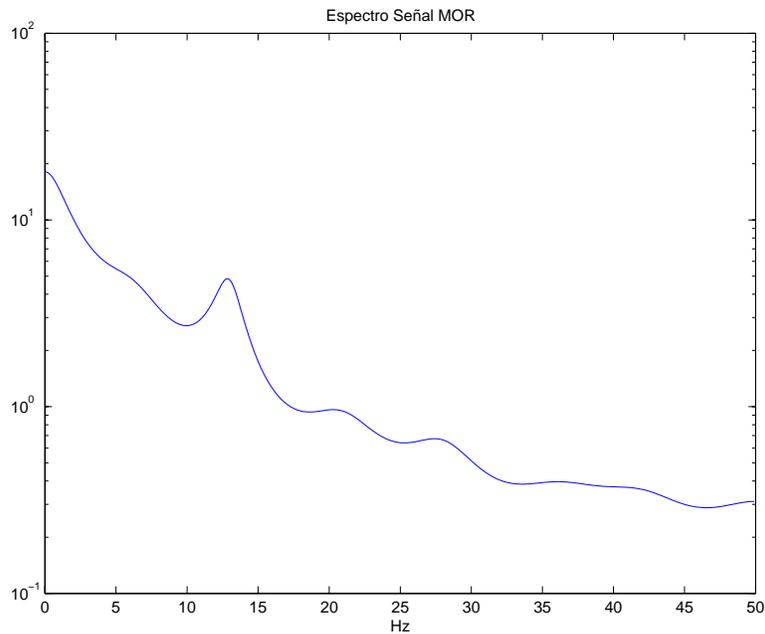


Figura 4.8: Espectro señal MOR

4.3. Identificación de secuencias CAP mediante potencia

La potencia está definida como $p = \sum |EEG|^2$. Este análisis se basa en calcular la potencia de la señal EEG a intervalos de duración igual a 1 segundo. Se establece un umbral igual a la potencia promedio de la señal. Los segmentos de señal que superen el umbral serán candidatos **A** de la secuencia CAPS.

La figura(4.9) muestra el proceso descrito; un segmento de señal EEG de 10 segundos al que se le calcula la potencia a cada segundo y su potencia promedio; finalmente los segmentos de la señal que superan el umbral son considerados como candidatos **A** de la secuencia CAPS.

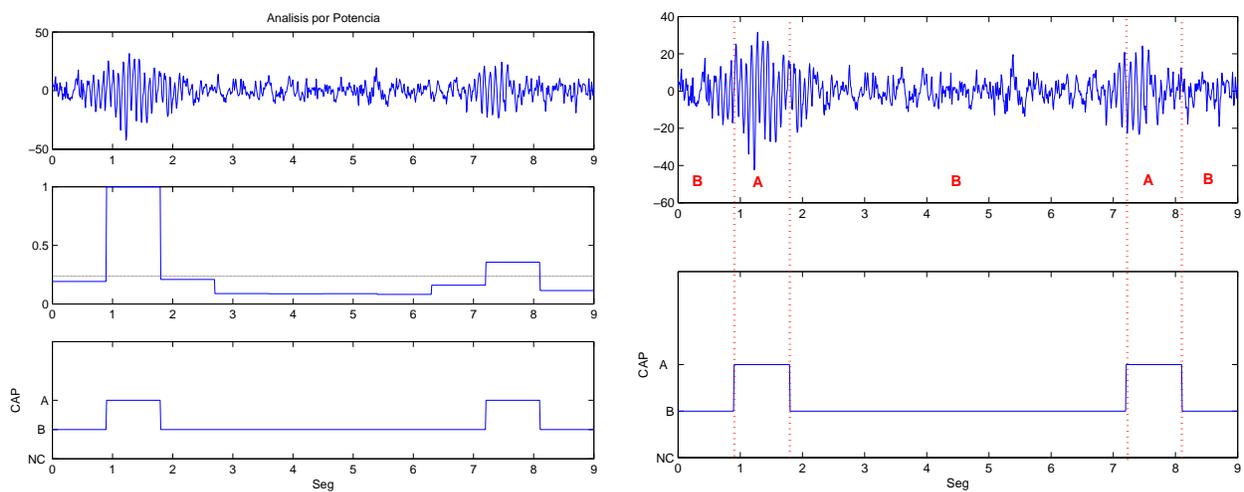


Figura 4.9: Detección CAP por potencia

4.4. Identificación de secuencias CAP mediante Estadísticas temporales

En Ferria,[14], se propone la identificación de secuencias CAP en base a umbrales establecidos a partir de la media y la desviación estándar (σ) de la señal EEG temporal.

A la señal EEG se le calcula el valor absoluto y se obtiene su envolvente. Se fijan umbrales en función de cada una de las etapas de sueño. Los umbrales propuestos por Ferria,[14] son:

- h_1 : media + σ para etapas 1 y 2
- h_2 : media + 1.5σ durante etapa 3
- h_3 : media + 2σ para etapa 4

Si la señal EEG supera el umbral correspondiente a la etapa de sueño analizada, se propone como candidato **A** de la secuencia CAPS.

La figura(4.10) muestra la señal original de EEG que utilizaremos para la detección de candidatos a fase **A** y **B** de la secuencia CAP. La figura(4.11) muestra el proceso a seguir: primero se obtiene el valor absoluto de la señal; una vez calculado el valor absoluto, se calcula su envolvente y se establece el umbral de decisión. Se realiza un promedio de amplitud por segundo, el cual se muestra al fondo de la misma figura.

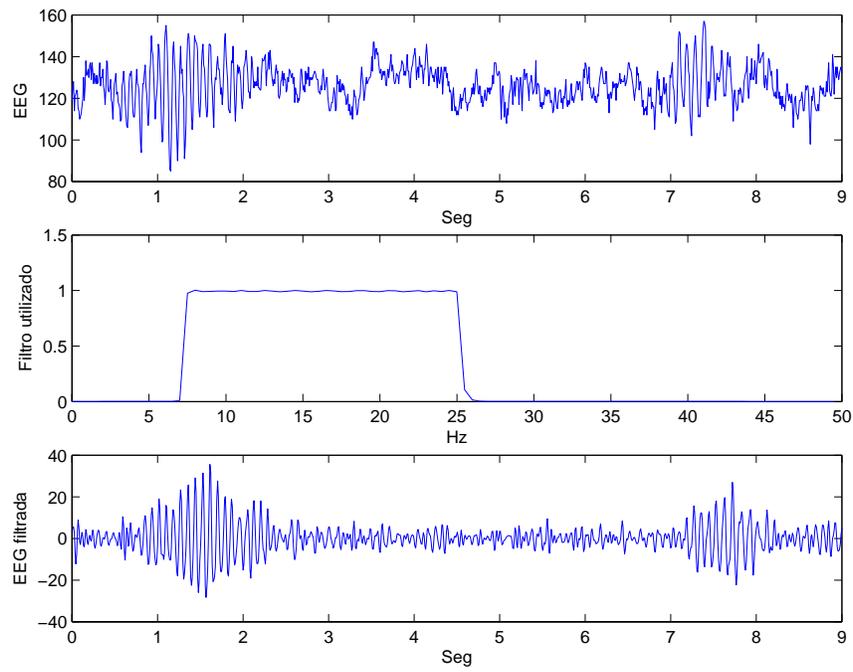


Figura 4.10: Señal EEG original y Señal EEG filtrada 7Hz a 25Hz

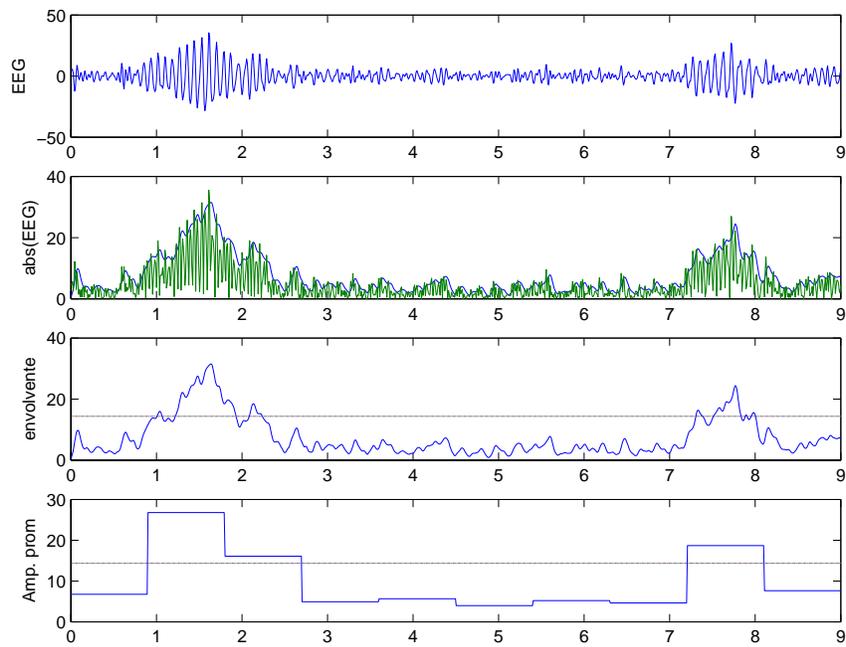


Figura 4.11: Procesamiento CAP mediante estadísticas temporales

La figura(4.12) muestra el resultado de la detección de candidatos a fase **A** y **B** de la secuencia CAP. Este resultado se obtiene a partir de los promedios de amplitud por segundo calculados previamente, aquellos donde el promedio resulte mayor al umbral establecido, se consideran como candidatos a fase **A** y aquellos que no lo superen se consideran elementos fase **B** de la secuencia CAP.

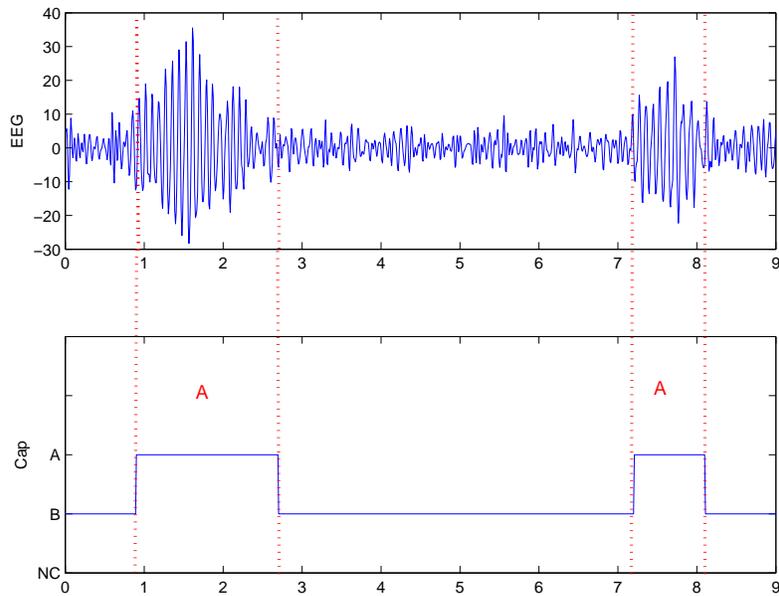


Figura 4.12: Resultado de la detección CAP mediante estadísticas temporales

4.5. Identificación de secuencias CAP mediante coeficientes de Correlación

La caracterización de secuencias CAP mediante coeficientes de autocorrelación se basa en evaluar el “parecido” de la secuencia de autocorrelación de la señal EEG a analizar con respecto a las funciones de autocorrelación de los ritmos alfa, beta, teta y delta generadas sintéticamente. El estimador de la función de correlación utilizado fue el estimador sesgado.

La figura(4.13) representa 10 segundos de una señal real de EEG, previamente calificada con la ayuda de un experto; en ella se observa la presencia de un ritmo de fondo, ritmo beta, y la presencia de dos episodios alfa.

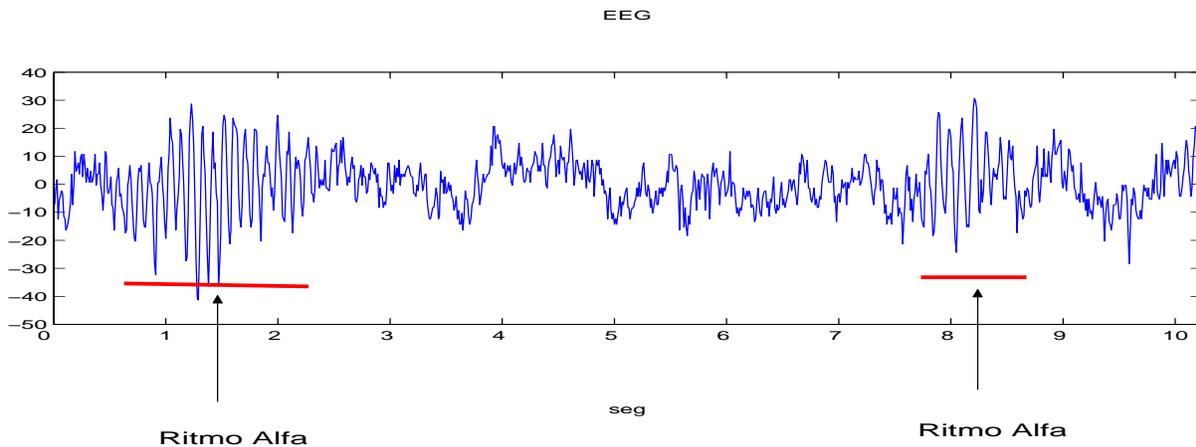


Figura 4.13: Señal EEG

La figura(4.14) muestra 128 puntos extraídos de la secuencia anterior de EEG correspondientes al ritmo alfa presentado entre los 0.52 segundos y 1.81 segundos; mientras que en la figura(4.15) se muestra una secuencia de 128 puntos de ritmo alfa sintético.

La figura(4.16) muestra 128 puntos de las secuencias de autocorrelación sesgada obtenidas tanto para la señal real como la señal sintética.

Para establecer el grado de semejanza entre las funciones de correlación se utilizó una medida de distancia. La distancia utilizada en este trabajo fue la distancia de Chebyshev, la cual resulta ser muy adecuada para conjuntos de datos formados por coeficientes de autocorrelación; Zepeda[53]. La distancia de Chebyshev entre un vector x y un z se define como:

$$D_c = \text{Max} |x - z|$$

Donde la menor distancia indica una gran similitud entre vectores.

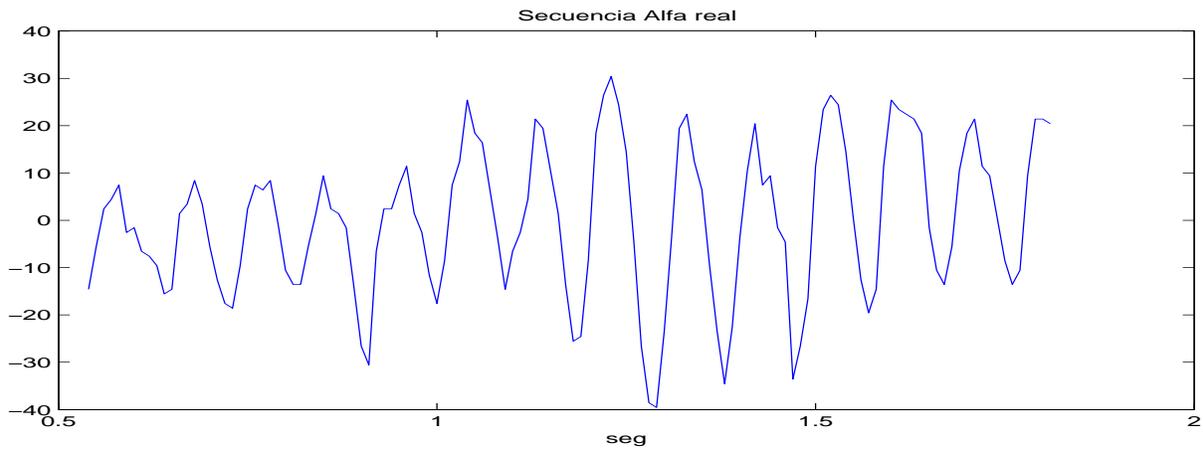


Figura 4.14: Secuencia Alfa real extraída de 4.13

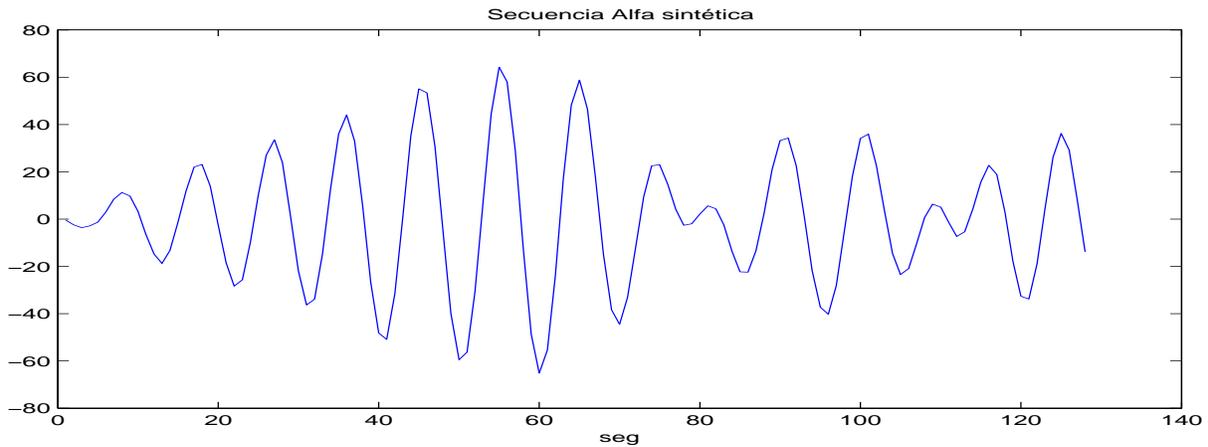


Figura 4.15: Secuencia Alfa Sintética

Comparando la función de autocorrelación del ritmo alfa, con aquella perteneciente a otro ritmo, por ejemplo beta, se puede observar que la distancia entre una y la otra es mayor. En la figura(4.17) se observa la función de autocorrelación de la señal real, con la función de autocorrelación de una secuencia beta sintética.

A diferencia del resultado obtenido en la figura(4.16) donde se observa que ambas funciones de autocorrelación tienen frecuencias de oscilación semejantes y una distancia de 0.4467; la figura(4.17) muestra funciones de correlación sin semejanza alguna, lo cual se refleja en una mayor distancia obtenida, que en este caso es de 0.8731.

En base a lo anterior, para el segmento de 10 segundos de señal EEG mostrado en la figura(4.13), se calculó la función de autocorrelación de segmentos de señal de un segundo de duración y se compararon mediante la distancia de Chebyshev con secuencias de autocorre-

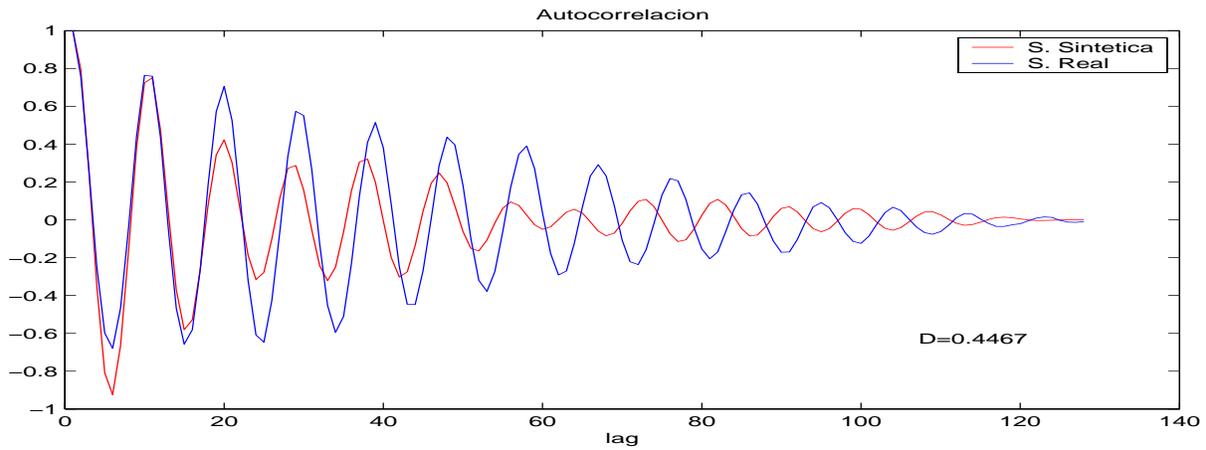


Figura 4.16: Secuencia de autocorrelación de la señal alfa real y alfa sintética. Distancia = 0.4467

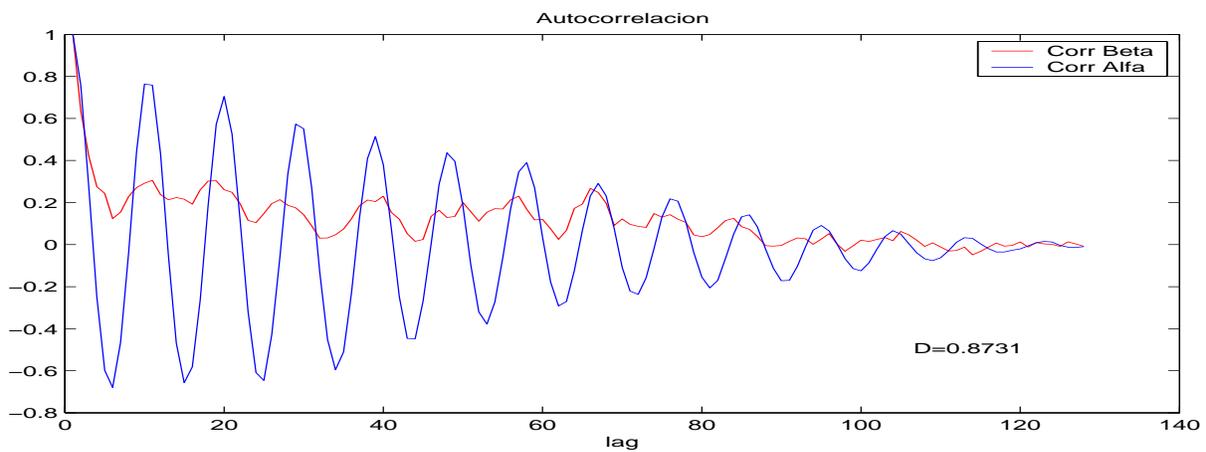


Figura 4.17: Secuencia de autocorrelación de la señal alfa real y beta sintética. Distancia = 0.8731

lación de cada ritmo.

Los resultados de la distancia de Chebyshev se muestran en la figura(4.18), así como la suma de cada una de ellas.

A partir de la suma de distancias mostrada en la figura(4.18), se obtuvieron los candidatos **A** y **B** de la secuencia CAP; para ello se consideraron como candidatos **A**, aquellas distancias menores a la media de la suma de distancias, mientras que los candidatos **B** fueron los que superaron esta media. La razón de tomar las distancias menores a la media se debe a que entre menor sea la distancia mayor es el parecido entre los coeficientes de correlación. En la figura(4.19) se observa como primer candidato **A** el segmento EEG comprendido del

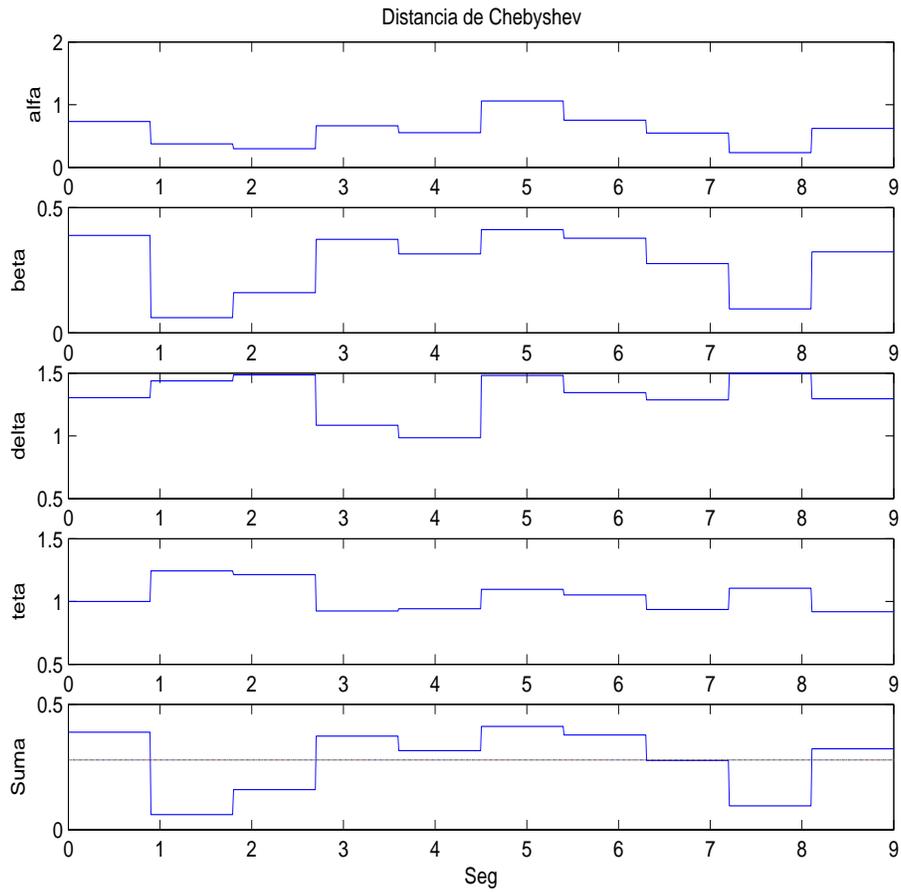


Figura 4.18: Distancias de Chebyshev entre CA de los segmentos de EEG y CA de ritmos Alfa, Beta, Delta, y Teta

segundo 1 al segundo 3 aproximadamente, mientras que el segundo candidato **A** se establece en el segmento aproximado del segundo 6 al 8.

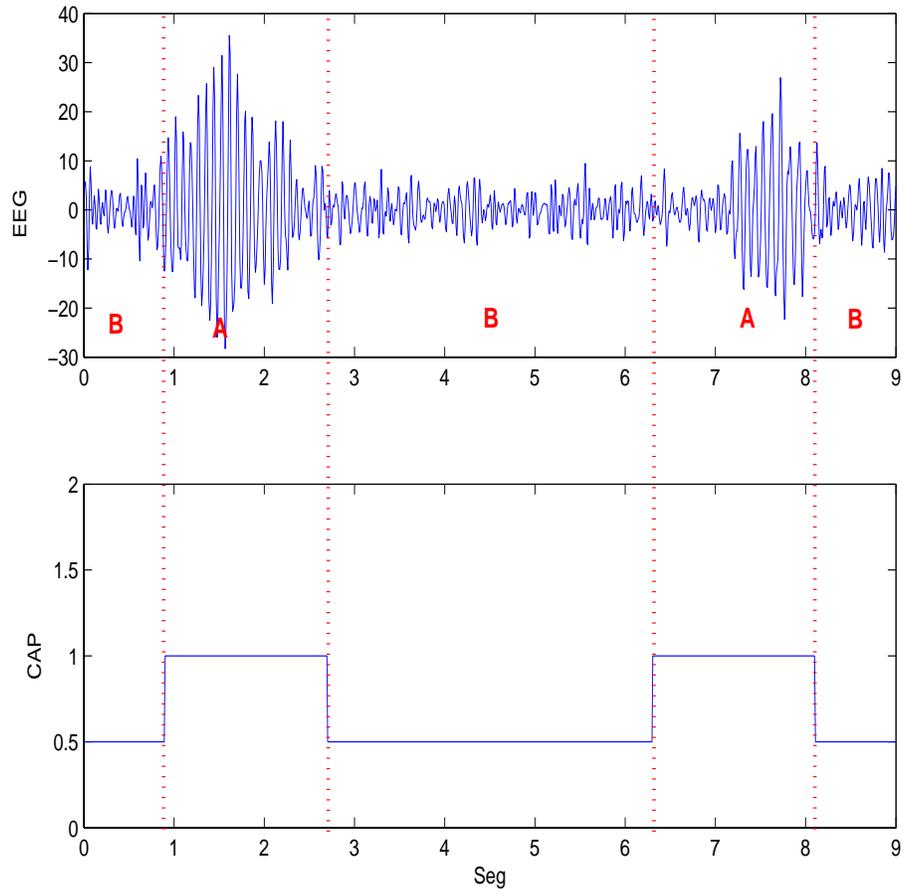


Figura 4.19: Identificación de la secuencia CAP utilizando CA con distancia de Chebyshev

4.6. Identificación de secuencias CAP mediante el Modelo de generación de EEG

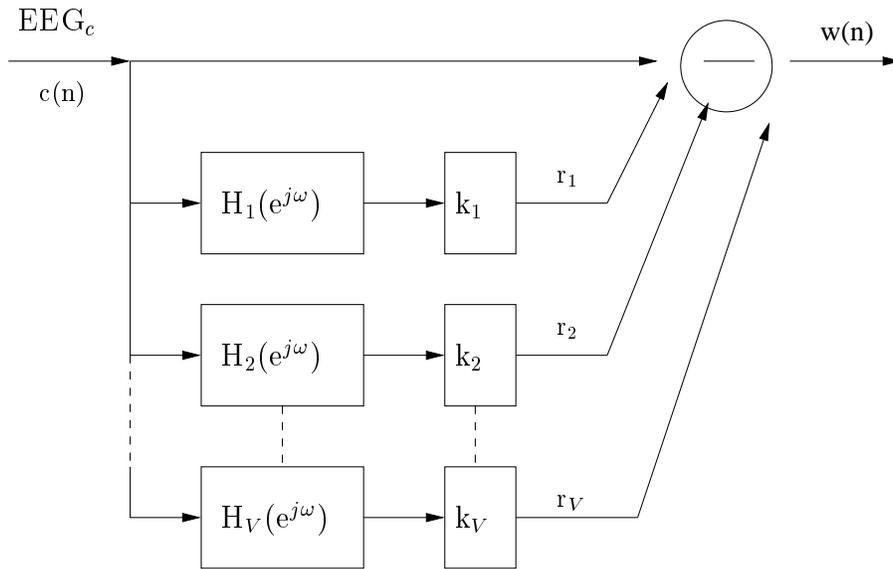


Figura 4.20: Modelo Extracción de características EEG , [40]

El modelo usado para la extracción de características de la señal EEG, mostrado en la figura(4.20) fue presentado por Rosa[40] en 1989. El modelo está compuesto por un conjunto de filtros $H_i(e^{j\omega})$, sintonizados a la frecuencia alfa, beta, delta y teta, respectivamente, alimentados por la señal de EEG cortical, obtenida mediante el filtro inverso resultado de estimar la respuesta del encéfalo (sección anterior).

La figura(4.21) muestra los k_i 's obtenidos del modelo mostrado en la figura(4.20). La estimación de k_i 's se hizo en intervalos de 0.5 seg para obtener mejor resolución; los k_i 's que superaban la media de los k_i 's fueron considerados como candidatos **A** de la secuencia CAP; este resultado se muestra en la figura(4.22).

La figura(4.23) muestra el resultado obtenido al hacer pasar un segmento de EEG a través de los distintos filtros del modelo. Siguiendo el modelo, cada salida es multiplicada por una constante k_i que puede ser estimada por distintos métodos; en este trabajo se usó un estimador de máxima verosimilitud y un estimador de error cuadrático promedio.

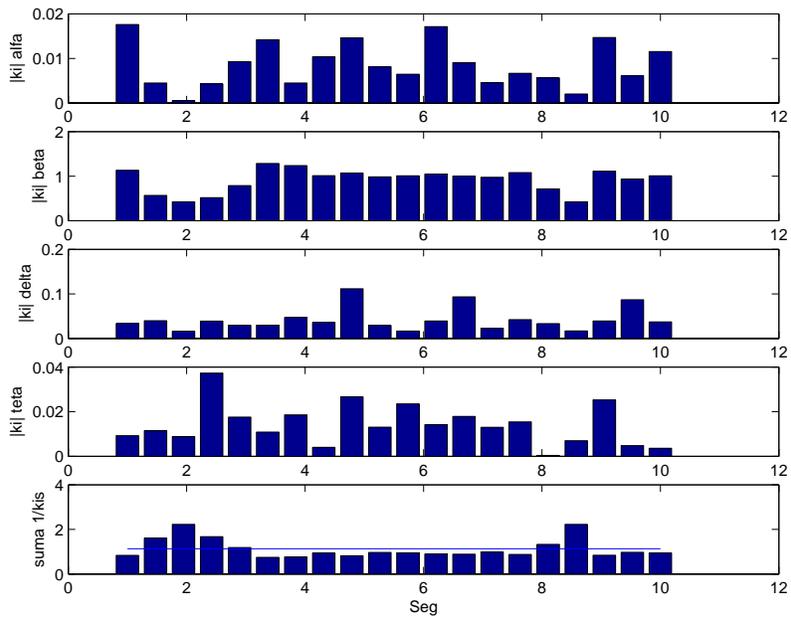


Figura 4.21: k_i obtenidos mediante el modelo de la figura(4.20)

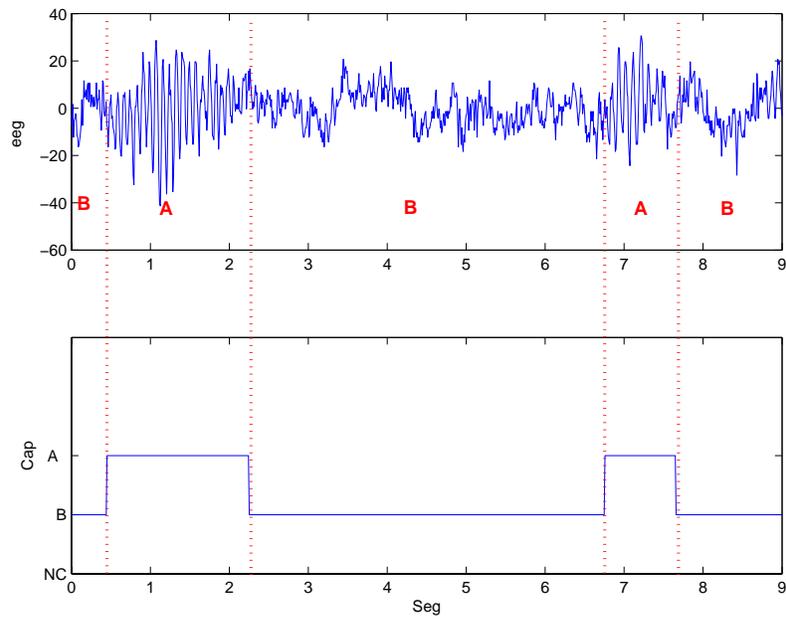


Figura 4.22: Detección de CAP mediante k_i mostrados en la figura(4.21)

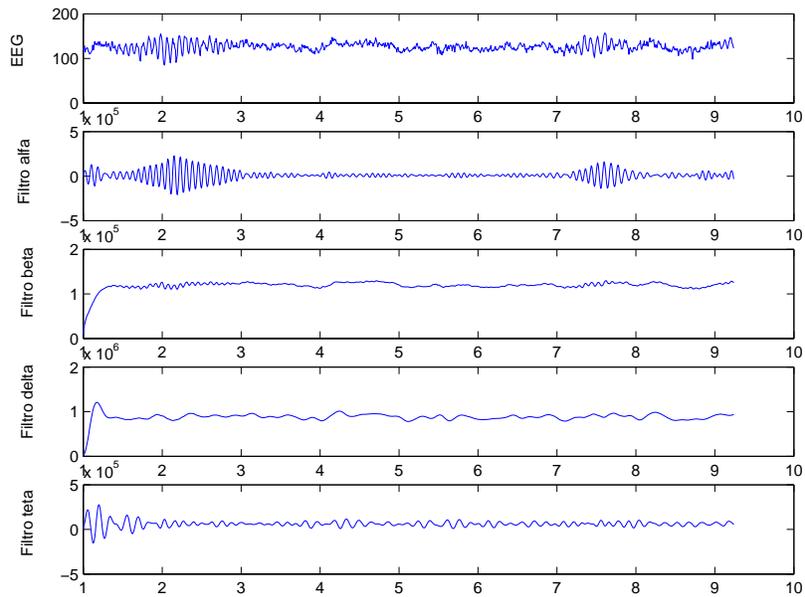


Figura 4.23: Señal EEG filtrada en cada banda

4.7. Identificación de secuencias CAP mediante Modelo Autorregresivo

El uso del modelo autorregresivo en el estudio del EEG es una técnica muy generalizada, la cual supone que al cambiar las propiedades de la señal EEG producirá cambios que se verán también reflejados en los parámetros que la modelan.

La caracterización de secuencias CAP mediante un modelo autorregresivo se realizó calculando segundo a segundo los coeficientes A_i del modelo autorregresivo de la señal de entrada, los cuales fueron comparados, mediante alguna norma o distancia, con los coeficientes de los filtros de cada ritmo previamente obtenidos (Cuadro 4.1).

Básicamente se usaron 2 distancias como forma de comparación:

Distancia Geométrica La distancia geométrica es la distancia más simple y se define en términos geométricos como:

$$\begin{aligned}
 d(U, V) &= \|U - V\|^2 = (u_1 - v_1)^2 + (u_2 - v_2)^2 \\
 U &= (u_1 - u_2) \\
 V &= (v_1 - v_2)
 \end{aligned}$$

Distancia Espectral La distancia espectral $(d_p)^p$, cuyas propiedades se muestran en Gray [18], y que es una distancia también usada en el análisis de voz se define como:

$$V(\theta) = \ln \left(\frac{\sigma^2}{|A(e^{j\theta})|^2} \right) - \ln \left(\frac{\sigma'^2}{|A'(e^{j\theta})|^2} \right)$$

$$(d_p)^p = \int_{-\pi}^{\pi} |V(\theta)|^p \frac{d\theta}{2\pi}$$

Donde

$\frac{\sigma^2}{|A(e^{j\theta})|^2}$: Espectro paramétrico de modelo autorregresivo de parámetros A, [4].

$\frac{\sigma'^2}{|A'(e^{j\theta})|^2}$: Espectro paramétrico de modelo autorregresivo de parámetros A', [4].

Una tercera distancia, la distancia de Itakura, fue implementada:

Distancia de Itakura La distancia de Itakura primeramente fue usada en el análisis y síntesis de voz, Kong [26] propone el uso de la distancia de Itakura para el análisis de EEG. La distancia de Itakura entre dos modelos autorregresivos: AR_x y AR_y , ambos del mismo orden, se define como, Kong [26]:

$$d(\alpha, \beta) = \frac{1}{2} \left(\log \left(\frac{\beta^T R_x \beta}{\alpha^T R_x \alpha} \right) + \log \left(\frac{\alpha^T R_y \alpha}{\beta^T R_y \beta} \right) \right)$$

Donde:

Los coeficientes A_i del modelo AR_x son:

$$\alpha = [1, a_1, a_2, \dots, a_p]^T$$

Los coeficientes A_i del modelo AR_y son:

$$\beta = [1, b_1, b_2, \dots, b_p]^T$$

R_x : Es la matriz de correlación relacionada con el modelo AR_x

R_y : Es la matriz de correlación relacionada con el modelo AR_y

Sin embargo, la distancia de Itakura mostró no ser adecuada para los propósitos de detección de las secuencias CAP.

Para la detección de secuencias CAP mediante modelo autorregresivo, se utilizó un modelo de orden 15 de acuerdo con lo expuesto en la sección *Señales Sintéticas de EEG* de este capítulo.

El primer análisis mediante modelo autorregresivo fue realizado utilizando la distancia geométrica. La figura(4.24) muestra las distancias obtenidas segundo a segundo entre los coeficientes A_i del modelo autorregresivo asociado a ese segmento y los coeficientes correspondientes a los filtros alfa, beta, delta y teta obtenidos previamente. Se muestra también la suma de las distancias segundo a segundo, lo que a partir de esta suma nos permitió establecer los candidatos **A** y **B**. La figura(4.25) muestra el resultado obtenido mediante el uso de la distancia geométrica. En este caso, se establece al segmento de señal EEG comprendido del segundo 2 al 4 como primer candidato **A**, mientras que el segundo candidato **A** lo forma el segmento de señal comprendido entre los 7 y 8 segundos.

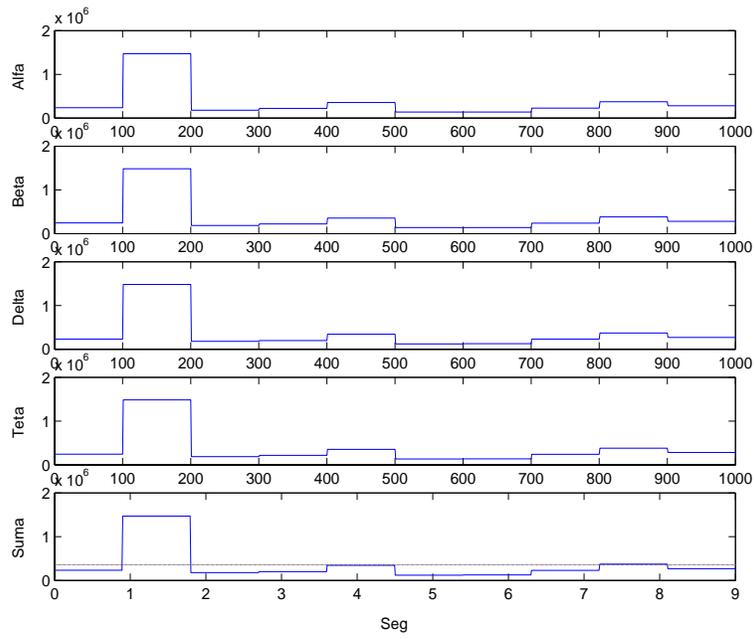


Figura 4.24: Identificación de secuencias CAP en cada banda de la señal mediante Modelo Autorregresivo usando distancia geométrica.

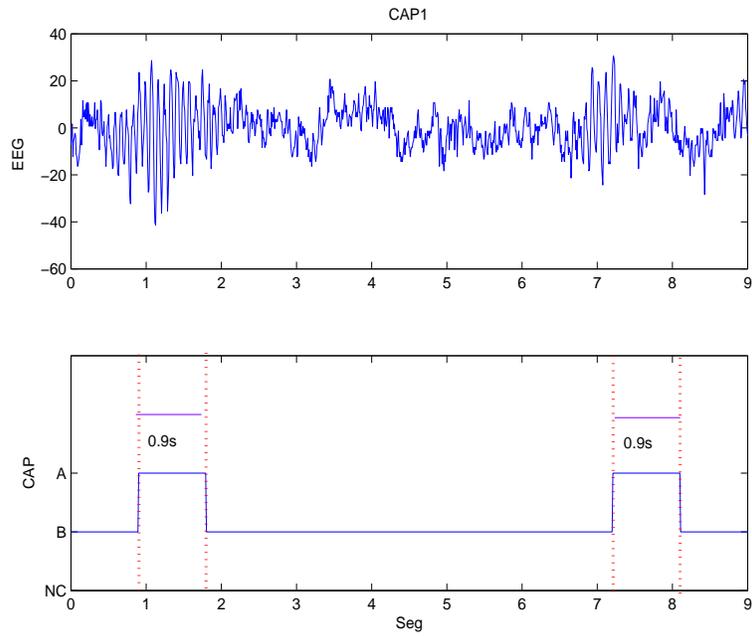


Figura 4.25: Identificación de secuencias CAP mediante Modelo Autorregresivo usando distancia geométrica.

Para el segundo análisis se realizó el mismo procedimiento que en el caso anterior, con la única variante que fue utilizada la distancia espectral. La figura(4.26) muestra las distancias segundo a segundo de los modelos AR estimados cada segundo con los coeficientes de los filtros antes citados.

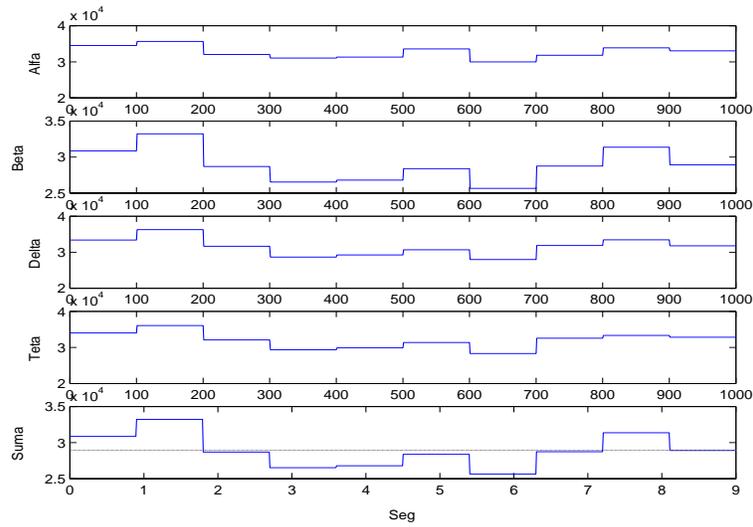


Figura 4.26: Identificación de secuencias CAP en cada banda de la señal mediante Modelo Autorregresivo usando distancia espectral.

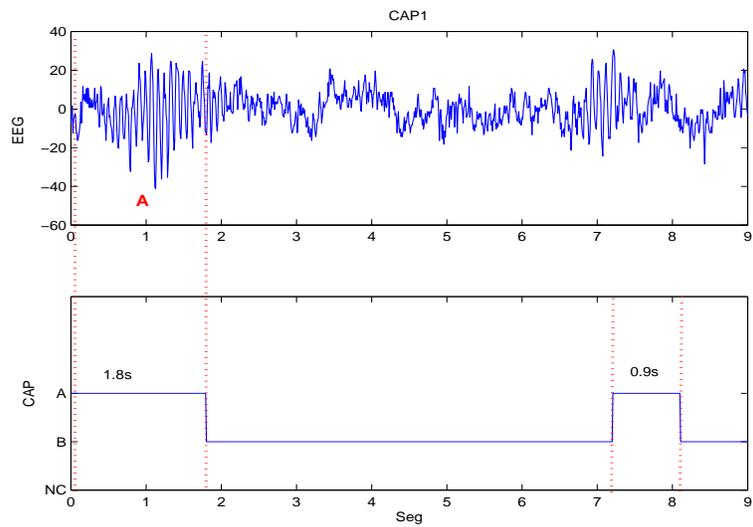


Figura 4.27: Identificación de secuencias CAP mediante Modelo Autorregresivo usando distancia espectral.

4.8. Caracterización de secuencias CAP mediante cambio en coeficientes FIR usando RLS

La idea de esta implementación se basa en hacer un seguimiento de los coeficientes de un filtro FIR asociado a la generación de la señal EEG en estudio; en otras palabras, suponemos que mientras la señal EEG se mantiene estacionaria, la diferencia entre coeficientes deberá ser mínima o nula, mientras que al presentarse un cambio de estado que rompa con la estacionariedad, los coeficientes deberían cambiar.

Para esta implementación, los coeficientes son calculados mediante el algoritmo RLS, lo que nos permite tener un juego de parámetros asociados a cada muestra de la señal, una vez obtenidos, se realiza un cálculo de distancia entre ellos. Las distancias utilizadas fueron las mismas de las secciones anteriores: distancia de Chebyshev, distancia geométrica y la distancia media cuadrática.

El algoritmo RLS implementado corresponde al presentado en [12], [20] y es el siguiente:

Inicialización	$A_N(0)=0$ $W_N(0)=0$ $K_N(0) = 0$ $P_N(0) = \delta I_N$; $\delta =$ Cte positiva pequeña menor a uno, $I =$ Matriz unitaria
Salida	$\hat{d}(n) = A_N^T(n-1)x_N(n)$
Error	$e(n) = d(n) - A_N^T(n-1)x_N(n)$
Ganancia	$K_N(n) = P_N(n-1)x_N(n) [\lambda + x_N^T(n)P_N(n-1)x_N(n)]^{-1}$
Act. Inversa	$P_N(n) = \lambda^{-1} [P_N(n-1) - K_N(n)x_N^T(n)P_N(n-1)]$
Act. Coef.	$A_N(n) = A_N(n-1) + K_N(n)e_N(n)$

La figura(4.28) muestra el espectrograma de la señal EEG obtenido a partir de los coeficientes obtenidos mediante el algoritmo RLS

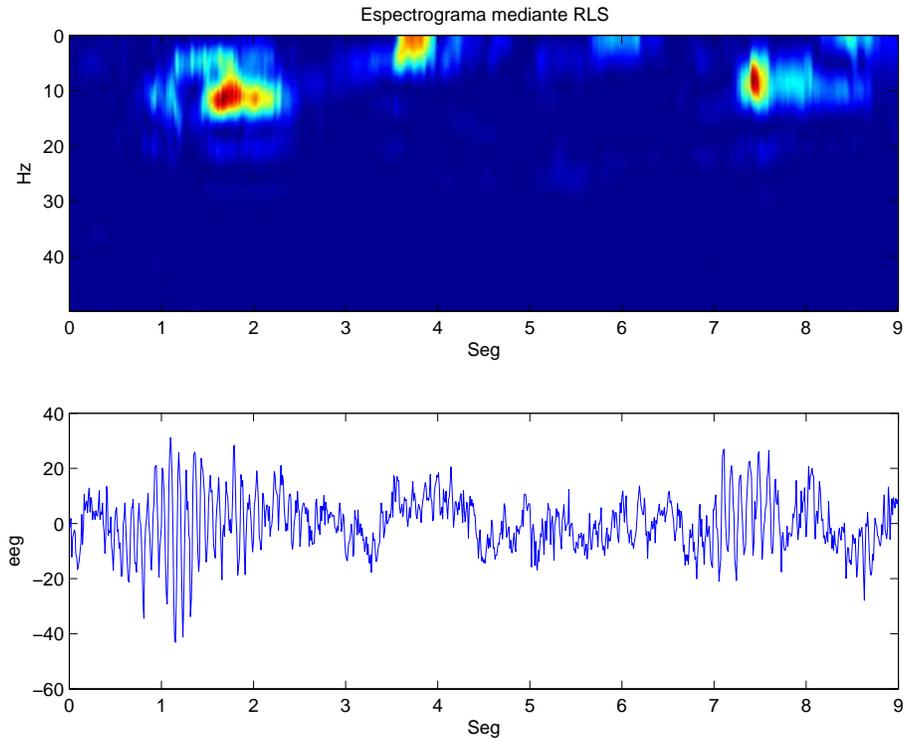


Figura 4.28: Espectrograma mediante coeficientes RLS

En las figuras(4.29,4.30,4.31) se muestra la señal EEG y los valores de distancia obtenidos entre los coeficientes RLS contiguos. Se puede apreciar que la distancia media cuadrática hace más evidente las diferencias de los cambios de la señal EEG. Dado que los resultados obtenidos utilizando la distancia de Chebyshev y la distancia geométrica son muy parecidos y ya que la distancia media cuadrática resalta de mejor manera los cambios en la señal, utilizaremos ésta última para la detección de secuencias CAP.

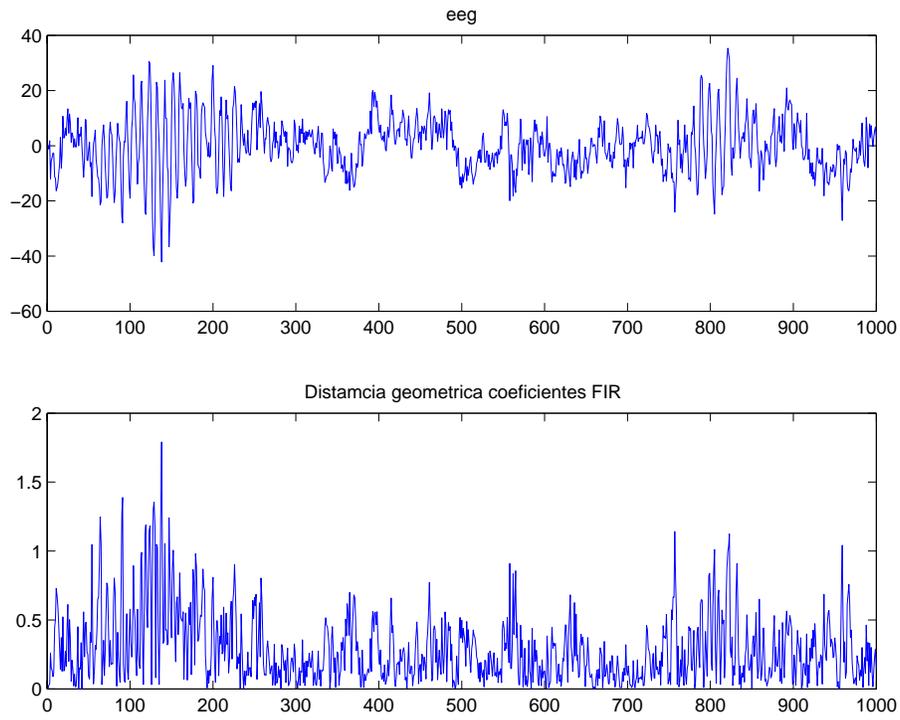


Figura 4.29: Distancia geométrica entre coeficientes RLS

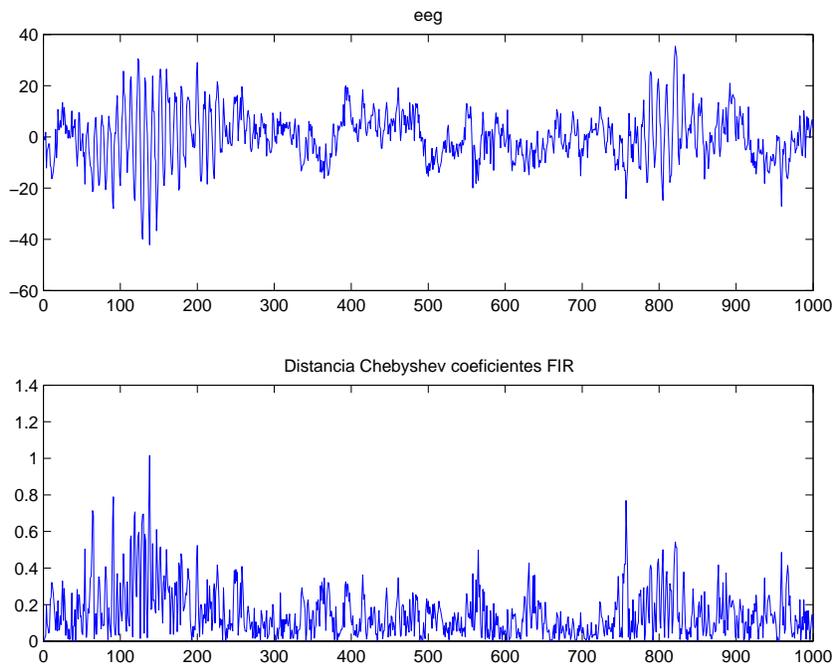


Figura 4.30: Distancia de Chebyshev entre coeficientes RLS

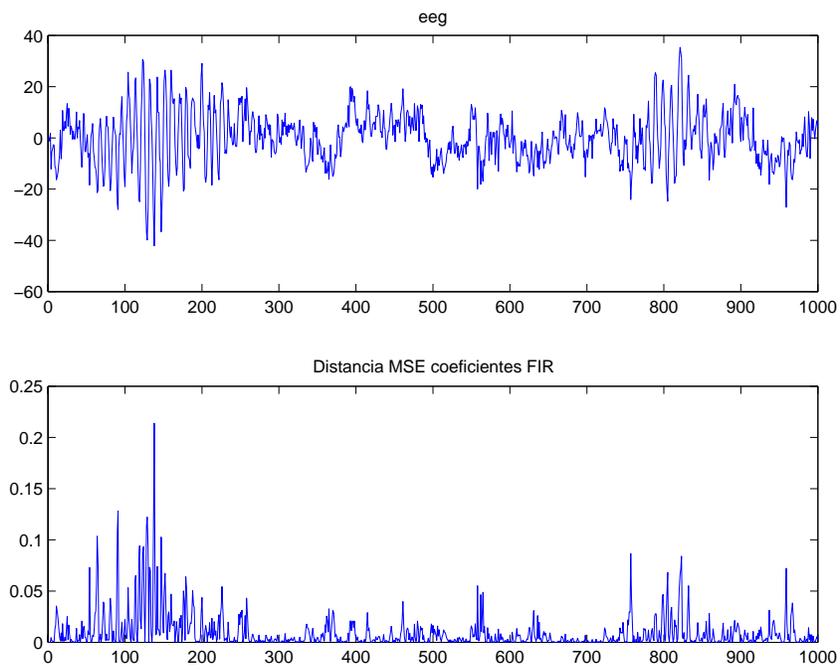


Figura 4.31: Distancia media cuadrática entre coeficientes RLS

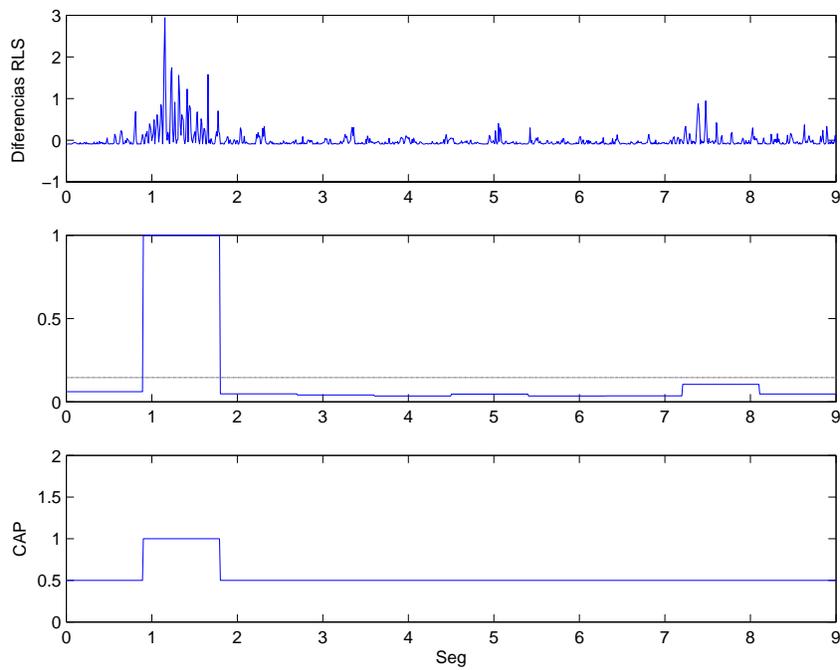


Figura 4.32: Identificación de la secuencia CAP mediante los coeficientes RLS

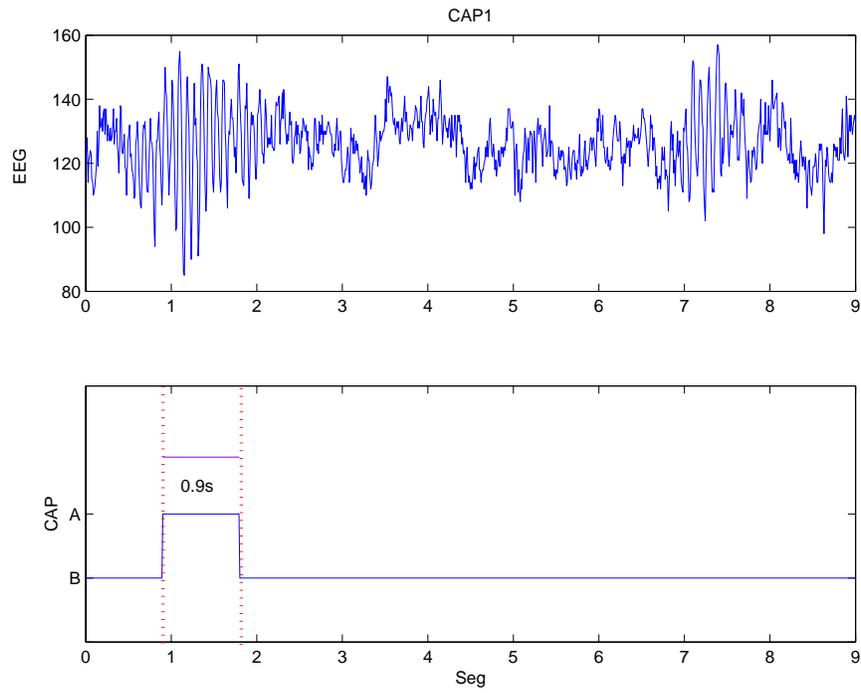


Figura 4.33: Identificación de la secuencia CAP mediante los coeficientes RLS

En base a la distancia media cuadrática comparamos la potencia de los coeficientes segundo a segundo; en la figura(4.32) se muestra como los segmentos que sobrepasan la media global de la diferencia de coeficientes son considerados candidatos **A** de la secuencia CAP, mientras que aquellos que no la superen serán tomados como candidatos **B**. La figura(4.33) muestra el resultado de la identificación obtenido al aplicar este método.

4.9. Identificación de secuencias CAP mediante métodos tiempo - frecuencia

Como mostramos anteriormente, todas las distribuciones tienen en común el producto;[10]:

$$x\left(\mu + \frac{\tau}{2}\right)x^*\left(\mu - \frac{\tau}{2}\right)$$

Dado que el resultado es una distribución real, el producto anterior debe tener simetría hermítica, por lo que conviene calcular dicho producto como:

$$2x\left(\mu + \frac{\tau}{2}\right)x^*\left(\mu - \frac{\tau}{2}\right)$$

para $\tau = 0..\infty$

En forma discreta, este producto será:

$$p[k] = 2x(n+k)x^*(n-k)$$

para $n = 0..N$

Donde N será la longitud de una ventana de análisis.

Formar un vector P_{npf} con los elementos de $p[k]$ de la siguiente forma:

$$P_{npf} = [p[0]p[1]p[2]..p[N]0..,0]p * [N]p * [N - 1]...p * [1]$$

Donde $p^*[\cdot]$ denota el conjugado complejo; y la cantidad de ceros será tal que la longitud de P_{npf} sea igual al número de puntos frecuenciales deseados;[10].

4.9.1. Espectrograma

Implementar el espectrograma (sección 3) es fácil, consiste en calcular el espectro de potencia a una ventana de datos y después ir recorriendo la ventana hacia delante un cierto número de muestras hasta completar la longitud de la señal.

La figura(4.34) muestra la señal EEG, su periodograma y el resultado obtenido al calcular el espectrograma a la señal. En el espectrograma se puede observar la aparición de actividad transitoria a 10 Hz, lo cual coincide con el resultado del periodograma también mostrado, en los intervalos de tiempo 1 y 2 segundos y de 7 a 8 segundos. Se utilizó una ventana cuadrada de longitud de 1 segundo y con traslape de 0.5 seg pensando en que la longitud de los transitorios en una secuencia CAP debe ser de al menos 2 segundos,[29],[41]. La actividad

transitoria parece tener un ancho de banda de casi 5 Hz.

Se comprueba lo obtenido con los otros esquemas de procesamiento: la aparición de un episodio centrado alrededor de los 10 Hz, que corresponde a la frecuencia alfa, en los primeros segundos de la señal y la aparición de un segundo episodio alrededor del segundo siete.

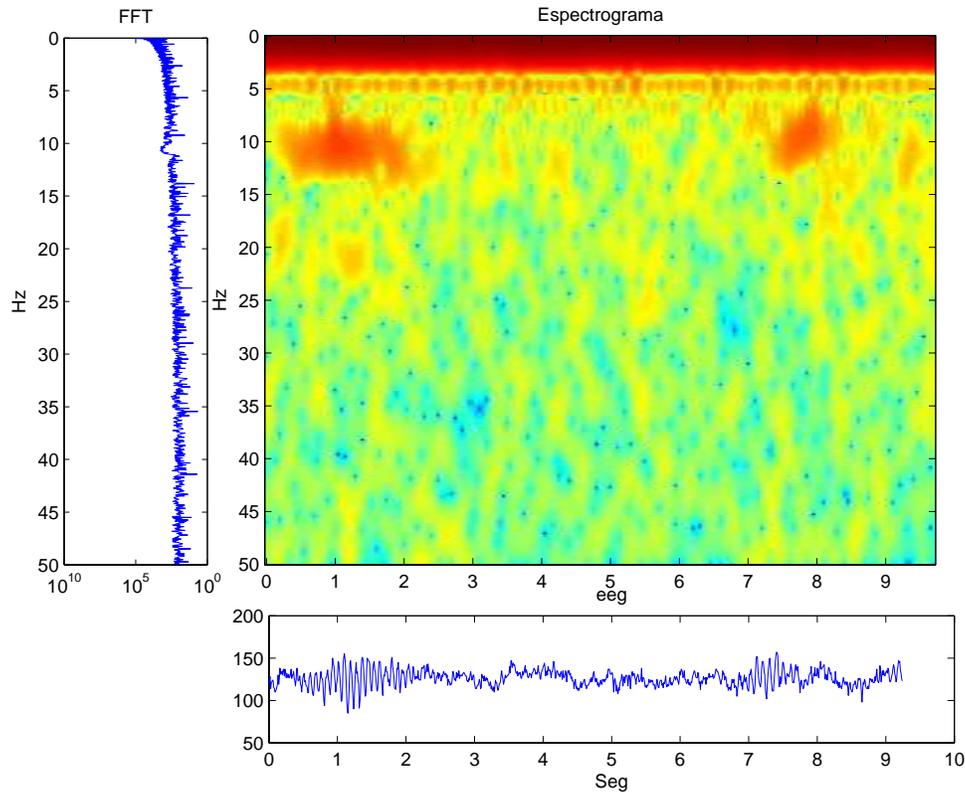


Figura 4.34: Espectrograma Ventana=50 Traslape=45

4.9.2. Wigner - Ville

Para implementar la distribución Wigner-Ville, sección 3 ecuación(3.19), los pasos a seguir son:

1. Para cada instante n , calcular el producto $2x(n+k)x^*(n-k)$
2. Formar el arreglo P_{npf} antes descrito
3. Calcular la fft del arreglo
4. repetir hasta completar la longitud de la señal

En la figura(4.35) mostramos la distribución Wigner - Ville de la señal EEG obtenida sobre una ventana única igual a la longitud de la señal. En este resultado se observan los efectos de los términos de cruce y en comparación con el espectrograma, el ancho de banda de la actividad transitoria se reduce dada la mayor resolución de este método. La aparición de los episodios se localizan de igual forma alrededor de los 10 hz, que como seguimos comprobando corresponden al ritmo alfa, y se sitúa el primero del segundo uno al dos, mientras que el segundo aparece entre el segundo 7 y 8.

En la figura(4.36) se observa la distribución Wigner - Ville en tres dimensiones con el objeto de resaltar los términos de cruce y la distribución negativa de potencia de la señal.

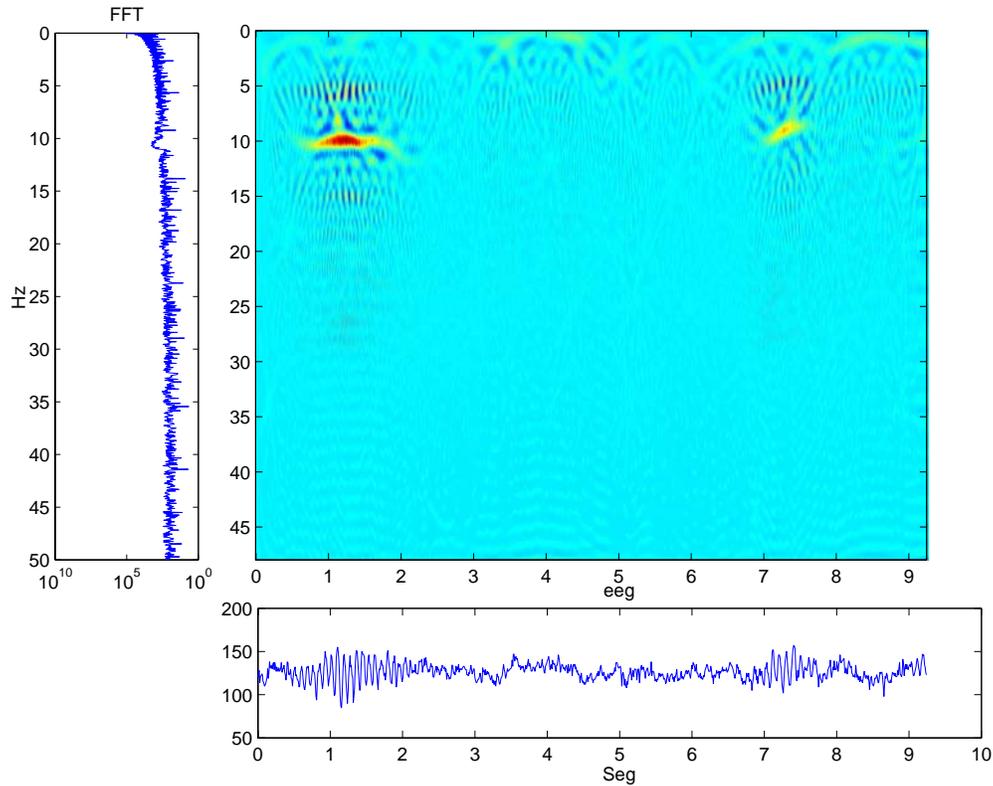


Figura 4.35: Representación de una señal EEG en tiempo, frecuencia y su Distribución Wigner - Ville N=1024; NPF=1024

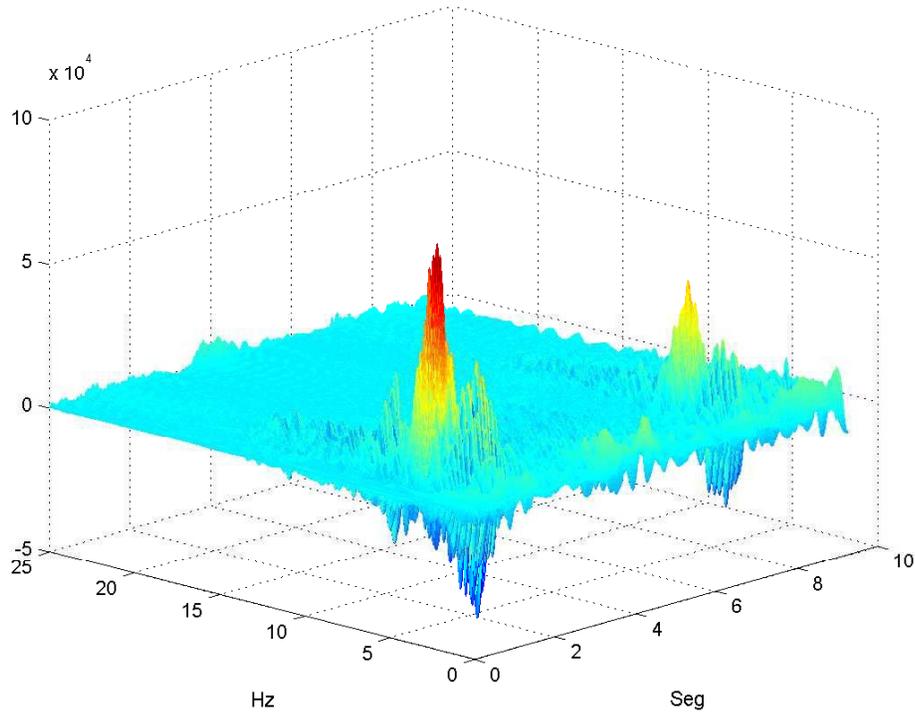


Figura 4.36: Distribución Wigner - Ville $N=1024$; $NPF=1024$

4.9.3. Choi - Williams

Para implementar la distribución Choi - Williams, sección 3 ecuación(3.20), los pasos a seguir son:

1. Para cada instante n , calcular el producto $x[n + m + k]x^*[n + m - k]$, para $k=0\dots N$ y $m=-M+1\dots M+1$
2. Para $k \neq 0$ ponderar el producto por $g[m]$ y pasar al punto 4
3. Si $k=0$, utilizar el término $2|h[0]|^2|x[n]|^2$
4. Formar el arreglo P_{npf}
5. calcular la fft del arreglo P_{npf}
6. repetir hasta el final de la señal

El cálculo de la distribución Choi - Williams de la señal EEG se obtuvo con los siguientes parámetros: $N=1024$, $M=1024$, $\sigma=40$ y $NPF=1024$.

En la figura(4.38) se observa que las componentes negativas de la distribución Choi - Williams son bastante menos significativas que aquellas de la distribución Wigner - Ville, casi desaparecen. También podemos observar en la figura(4.37) que al calcular la distribución Choi - Williams se obtiene un mejor despliegue de la distribución tiempo - frecuencia de la señal; podemos observar la aparición del ritmo alfa. En comparación con el resultado obtenido por la distribución Wigner - Ville, figura(4.35), podemos apreciar la reducción de los artefactos producto de los términos cruzados que produce dicha distribución, por lo que podemos apreciar de forma más clara la duración de los eventos fásicos presentados por la señal EEG.

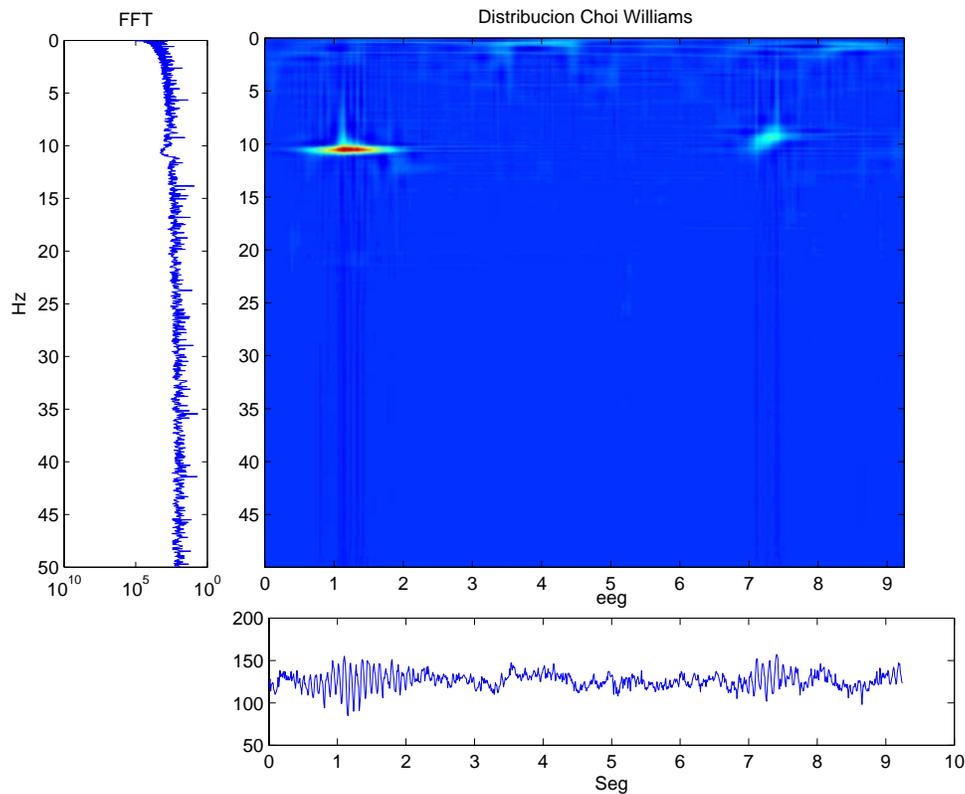


Figura 4.37: Representación de una señal EEG en tiempo, frecuencia y su Distribución Choi - Williams $N=1024$ $M=1024$ $\sigma=40$ $NPF=1024$

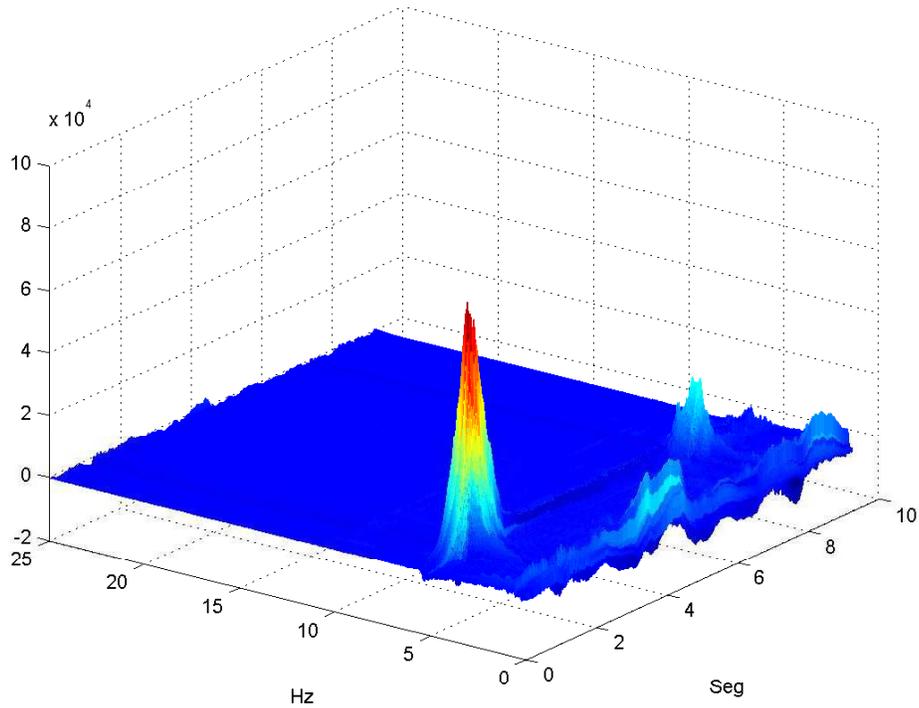


Figura 4.38: Distribución Choi - Williams $N=1024$ $M=1024$ $\sigma=40$ $NPF=1024$

4.9.4. Bessel

Para implementar la distribución Bessel, sección 3 ecuación(3.6.5), los pasos a seguir son:

1. Para cada instante n , calcular el producto $x[n + p + m]x^*[n + p - m]$ para $m=0\dots N-1$ y $p= -2\alpha m\dots 2\alpha m$
2. Para $k \neq 0$ sumar los $4\alpha m$ productos y ponderar
3. Si $k=0$ utilizar $-2 |h[0]|^2 |x[n]|^2$
4. Formar el arreglo P_{nf} y calcular la fft
5. Repetir hasta concluir con la señal

La figura(4.39) muestra el resultado obtenido mediante la distribución Bessel de tiempo - frecuencia con los parámetros siguientes: $N=1024$, $\alpha=0.5$, $NPF=1024$. Podemos observar que a diferencia del resultado obtenido mediante la distribución Choi Williams, en la distribución Bessel, figura(4.40), se aprecian una mayor cantidad de artefactos, por lo que puede resultar más útil el trabajar la distribución Choi - Williams.

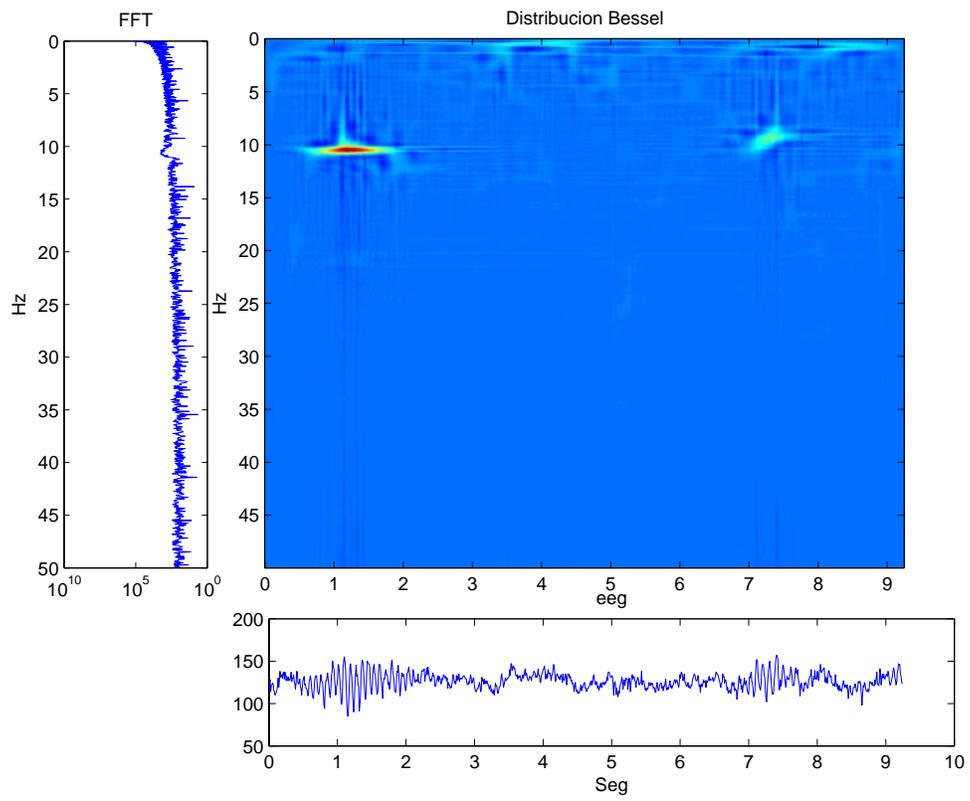


Figura 4.39: Representación de una señal EEG en tiempo, frecuencia y su Distribución Bessel
 $N=1024$ $\alpha=0.5$ $NPF=1024$

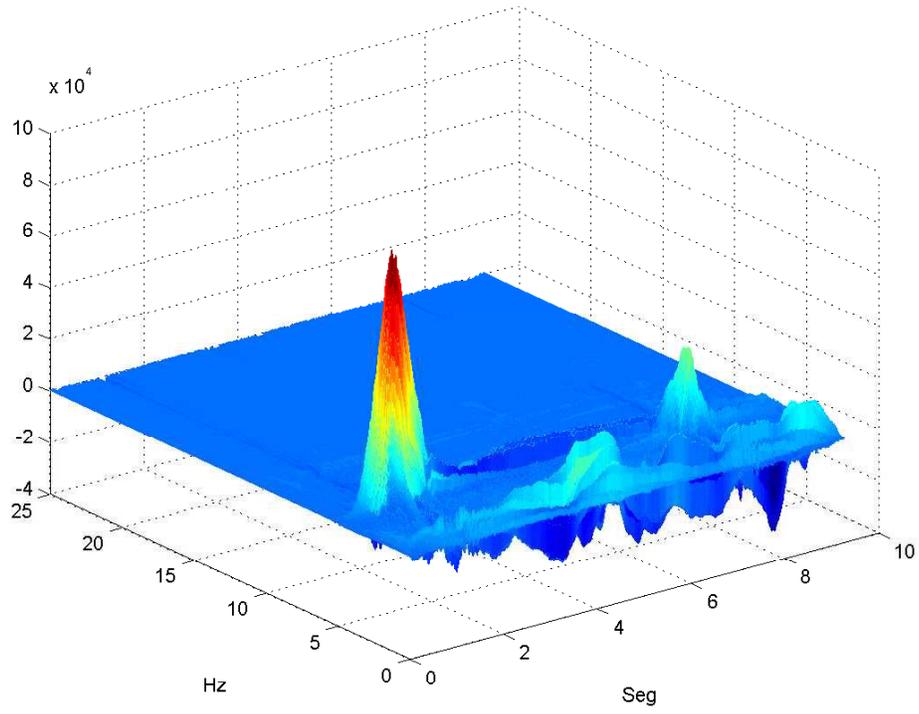


Figura 4.40: Bessel $N=1024$ $\alpha=0.5$ $NPF=1024$

4.10. Identificación de secuencias CAP mediante métodos tiempo - escala

4.10.1. Haar

Un método tiempo - escala simple, lo constituye la transformada Haar, ecuación(3.22) . La transformada Haar básicamente trata de representar la señal por medio de rectángulos cada vez más delgados que se van desplazando en tiempo. Es obvio que la representación de una curva suave como en ocasiones se comporta la señal de EEG, no es la mejor representación; sin embargo nos permite obtener una primera descomposición de la señal EEG en distintas bandas. La figura(4.43) muestra el comportamiento de la señal EEG en 10 diferentes rangos de frecuencia, pudiéndose apreciar que la descomposición de las bandas de baja frecuencia cada vez es más cuadrada, dado que los rectángulos que la aproximan son cada vez más anchos. La figura(4.41) es el llamado escalograma, (sección 3), es una representación bidimensional de los coeficientes obtenidos mediante la descomposición a lo largo del tiempo. En esta figura podemos apreciar que los coeficientes con mayor energía están contenidos en la escala 3, la cual hace referencia a la banda comprendida entre los 6.22Hz y los 12.45 Hz que corresponde a la banda alfa, por lo que podemos decir que la actividad dominante en ese instante de tiempo es actividad alfa, resultado que concuerda con lo que en secciones previas ya habíamos obtenido.

Para la detección de la fase **A** y **B** del ciclo CAP utilizaremos la banda con mayor energía resultante de la transformada haar. En la figura(4.41) podemos ver que los cambios en el tiempo de la señal EEG se ven reflejados en el escalograma como zonas más claras, lo anterior lo podemos ver de manera más clara en la figura(4.42), la cual muestra los coeficientes de la transformada haar en tres dimensiones; vemos picos en los instantes en que la señal EEG cambia de estado; esto resulta muy conveniente para realizar la identificación de secuencias CAP.

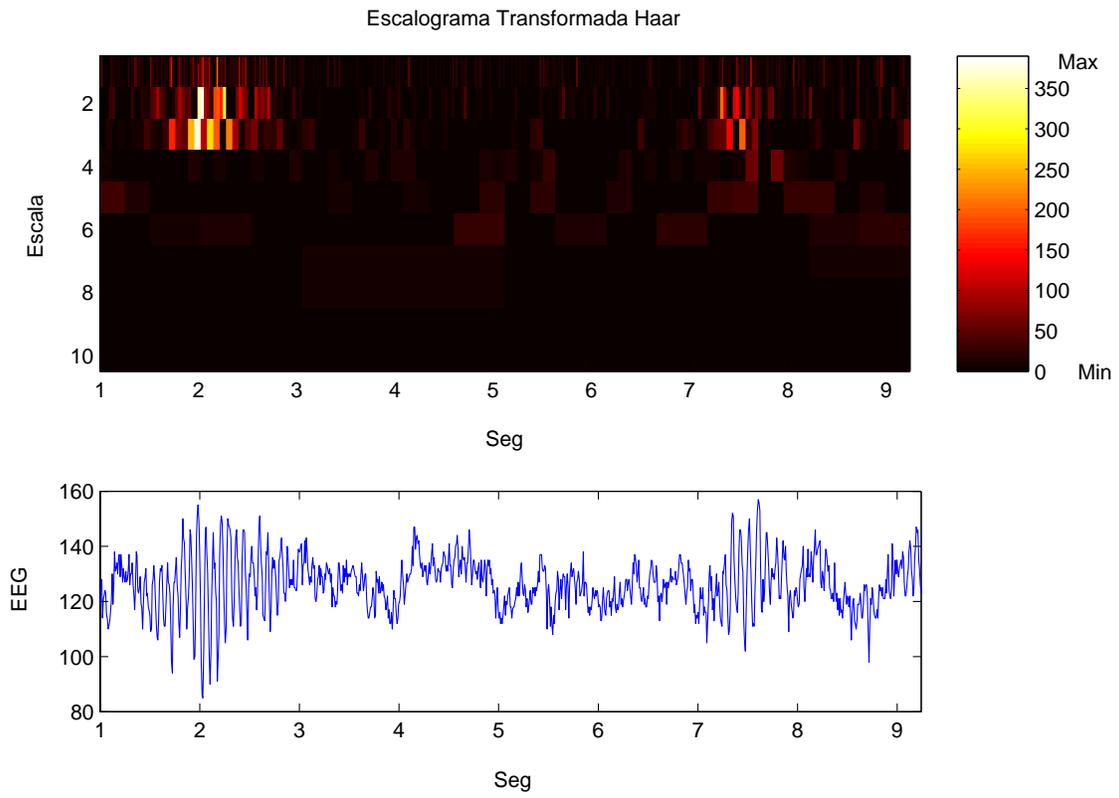


Figura 4.41: Escalograma Transformada Haar

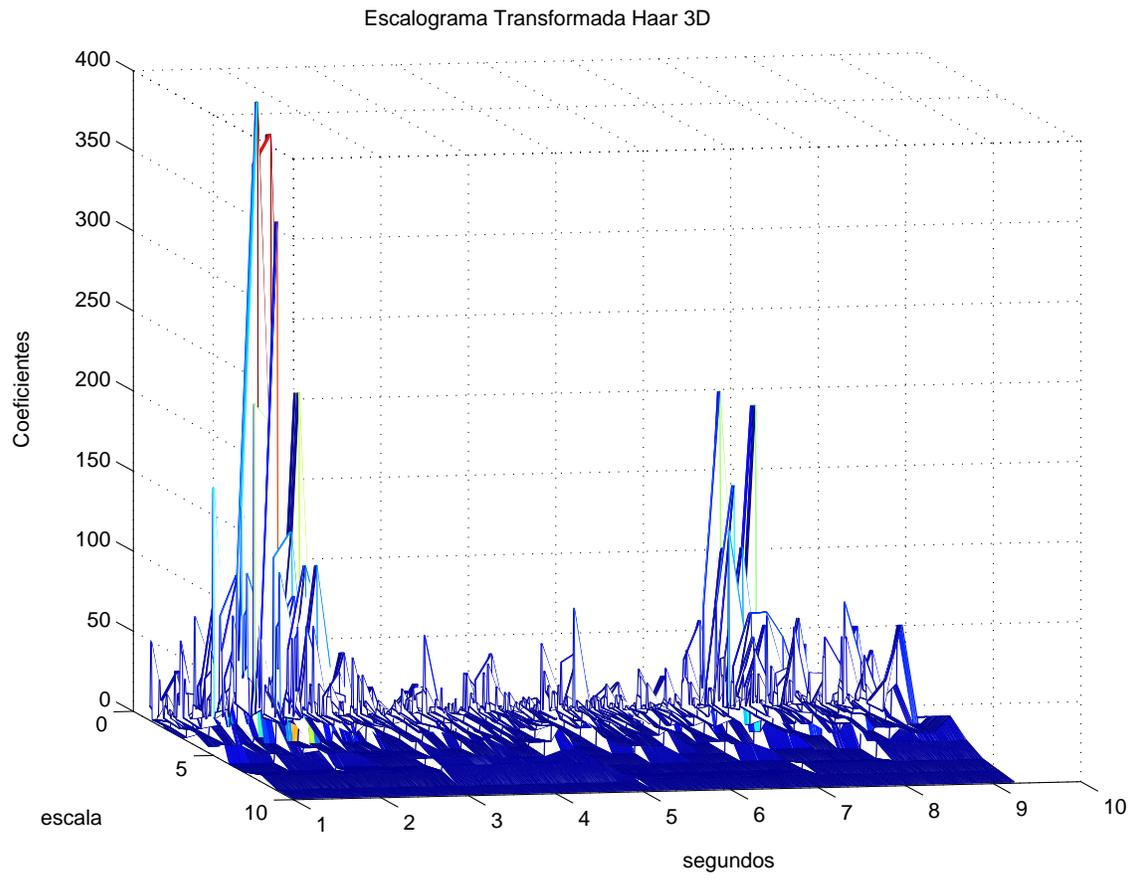


Figura 4.42: Escalograma Transformada Haar

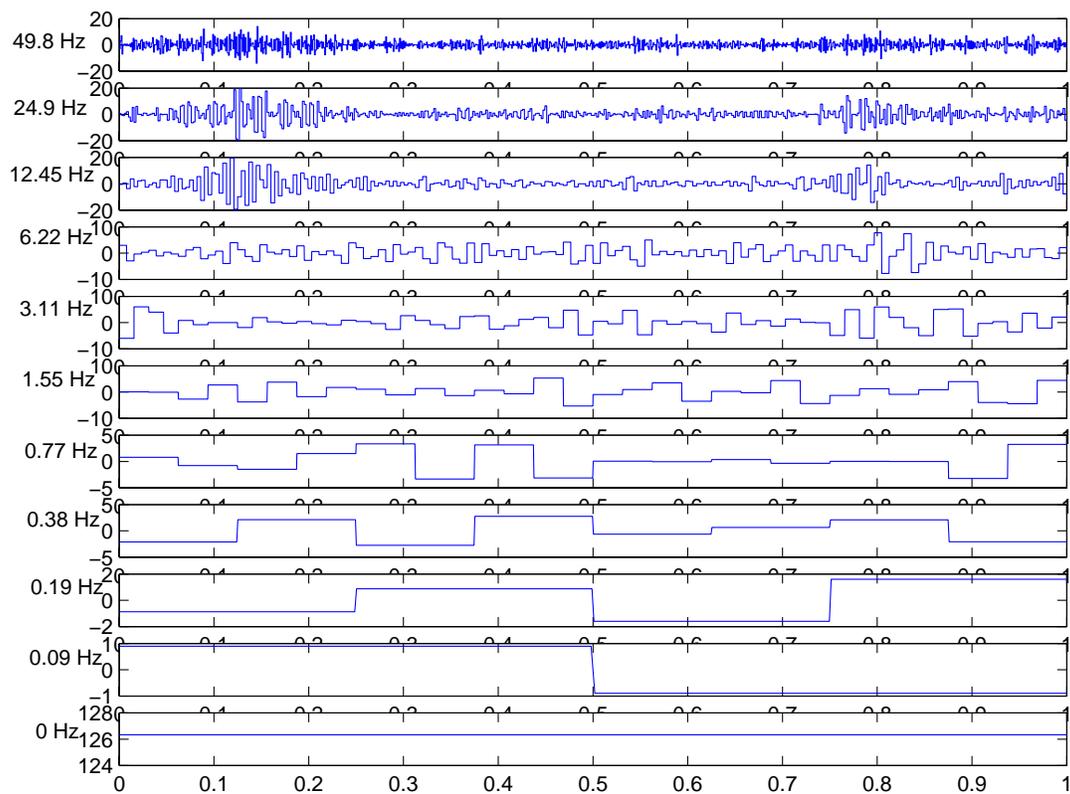


Figura 4.43: Descomposición mediante Transformada Haar

4.10.2. Daubechies

Como la función madre de la transformada Daubechies 4, es una curva más suave, figura(4.44); es de esperar una mejor reconstrucción de la señal EEG. La figura(4.45) muestra el escalograma obtenido mediante la transformada Daubechies 4; donde se aprecia que, como en la transformada haar, la banda con mayor energía es la número 3; que corresponde a una frecuencia de corte aproximada de 8 Hz, ver figura(4.46).

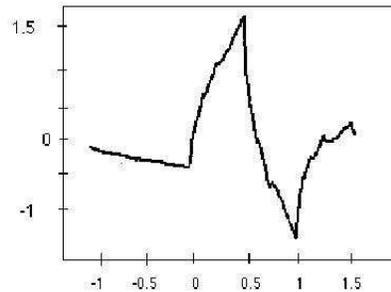


Figura 4.44: Función Onduleta Madre Daubechies; [11]

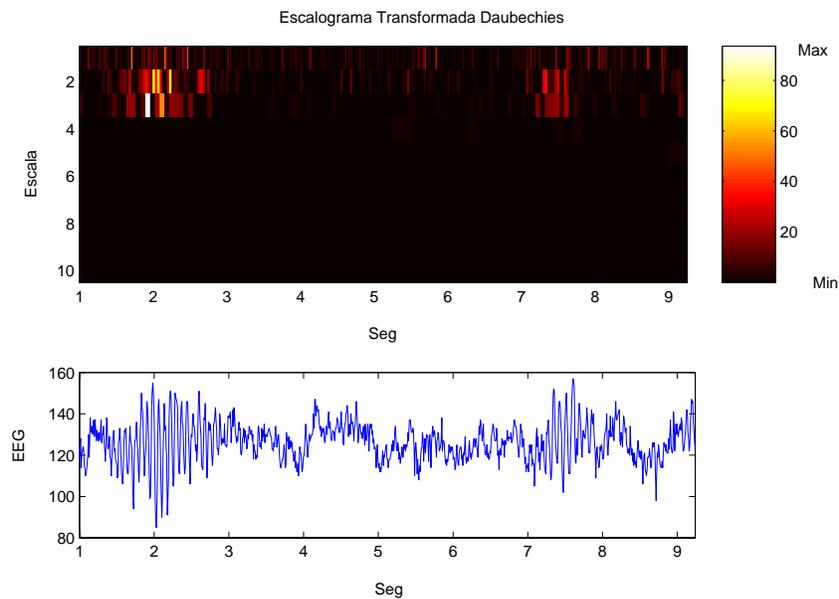


Figura 4.45: Escalograma Transformada Daubechies 4

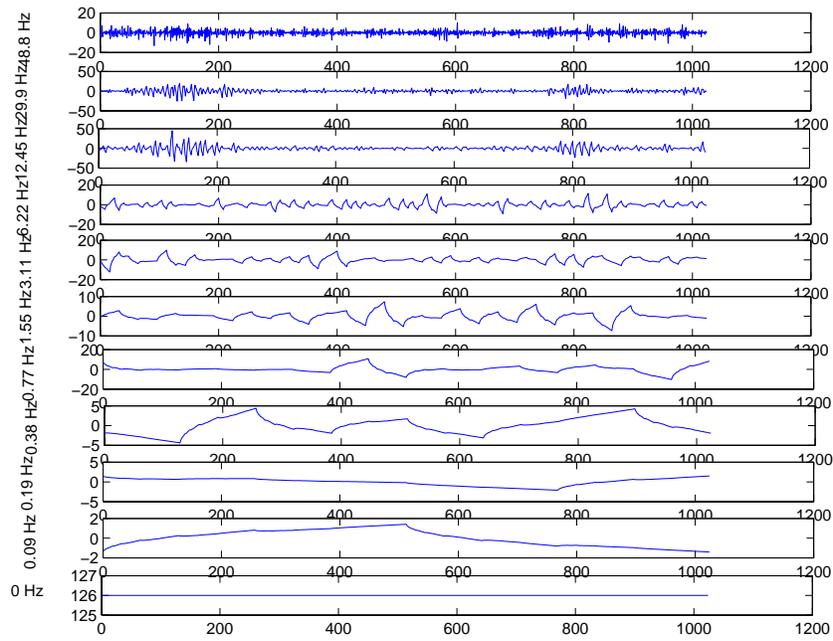


Figura 4.46: Descomposición de la señal EEG mediante transformada Daubechies 4

Igual que con la transformada haar, a partir de la banda de mayor potencia realizamos la detección de las fases **A** y **B** de la secuencia CAP. Para esto se calcula el valor promedio de la señal en la banda seleccionada, es decir, la de mayor potencia y los segmentos que superen el valor promedio serán considerados como fase **A**; figura(4.47).

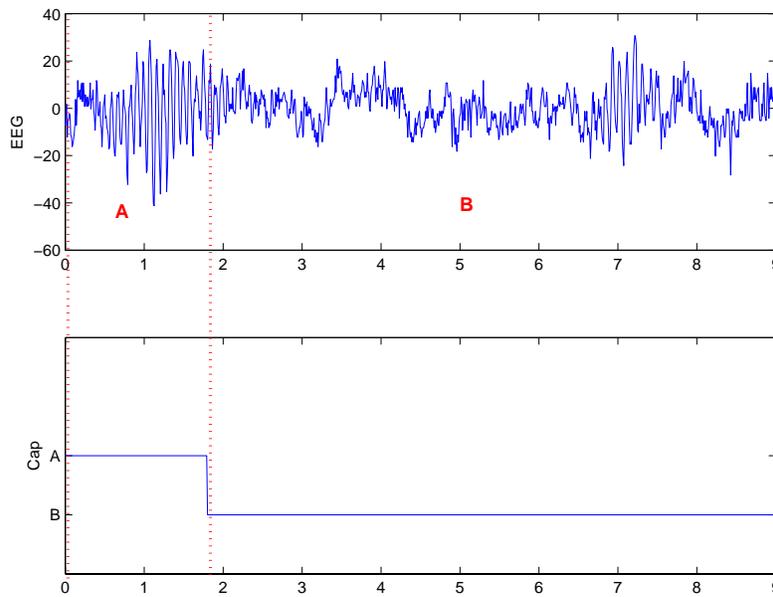


Figura 4.47: Identificación CAP mediante transformada Daubechies 4

4.11. Binarización

En esta sección comenzaremos el tratamiento de las representaciones tiempo - frecuencia, como imágenes; para ello, con el fin de procesar las distribuciones, utilizamos un mapa de 256 niveles de gris mediante el siguiente escalamiento:

$$n_{gris} = m * F(n, f) - m * \text{mín} \{F(n, f)\}$$

$$m = \frac{255}{\text{máx}\{F(n, f)\} - \text{mín}\{F(n, f)\}}$$

Donde:

$F(n, f)$: Valor de la representación tiempo - frecuencia / tiempo escala

$\text{máx}\{F(n, f)\}$: Valor máximo de la representación

$\text{mín}\{F(n, f)\}$: Valor mínimo de la representación

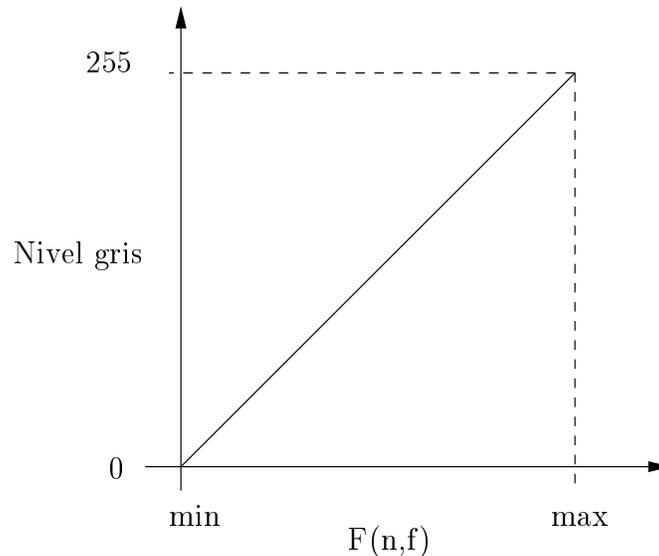


Figura 4.48: Función escalamiento a 256 niveles de gris

Las figuras(4.49; 4.50; 4.51; 4.54) muestran los resultados del escalamiento a 256 niveles de gris y sus respectivos histogramas.

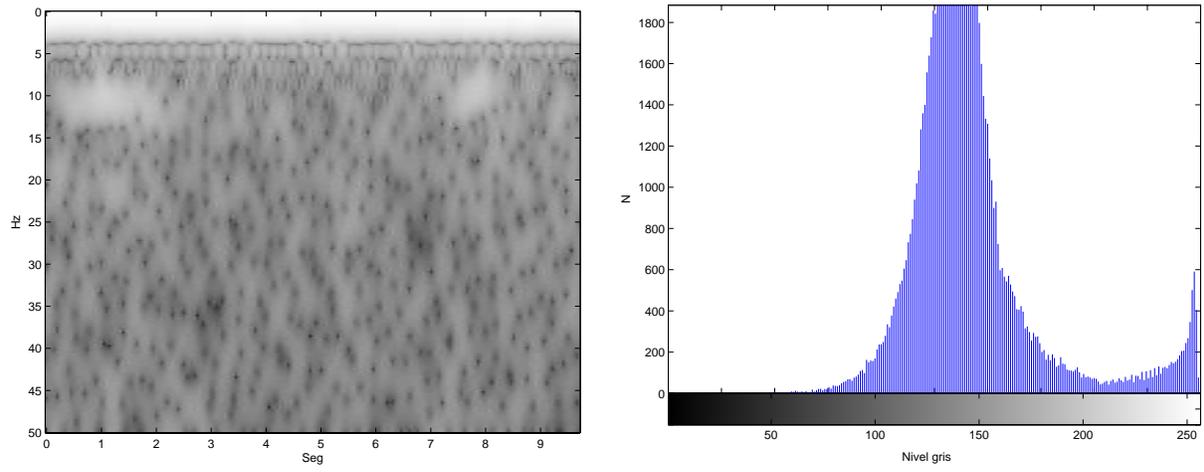


Figura 4.49: Izquierda: Espectrograma 256 niveles de gris secuencia CAP, Derecha: Histograma

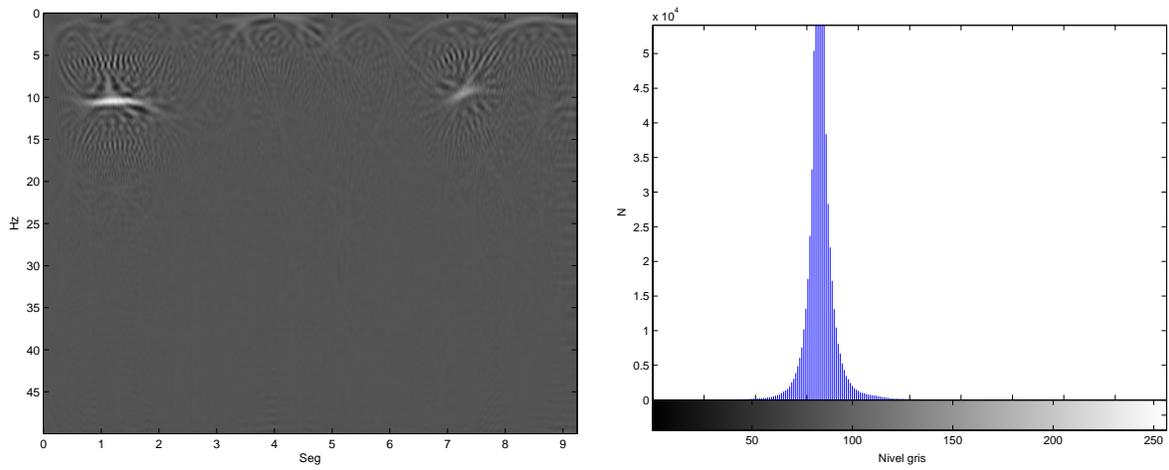


Figura 4.50: Izquierda: Distribución Wigner - Ville 256 niveles de gris secuencia CAP, Derecha: Histograma

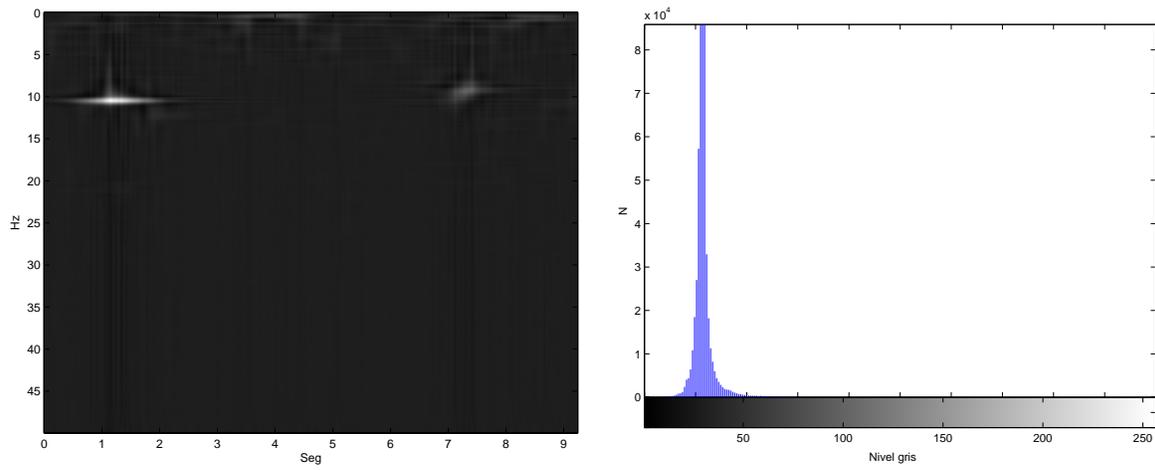


Figura 4.51: Izquierda: Distribución Choi - Williams 256 niveles de gris secuencia CAP, Derecha: Histograma

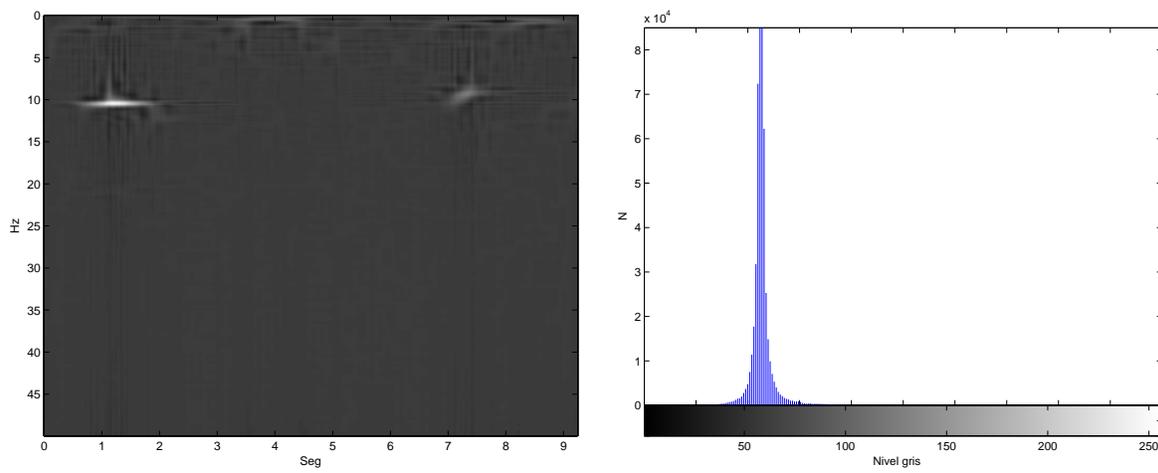


Figura 4.52: Izquierda: Distribución Bessel 256 niveles de gris secuencia CAP, Derecha: Histograma

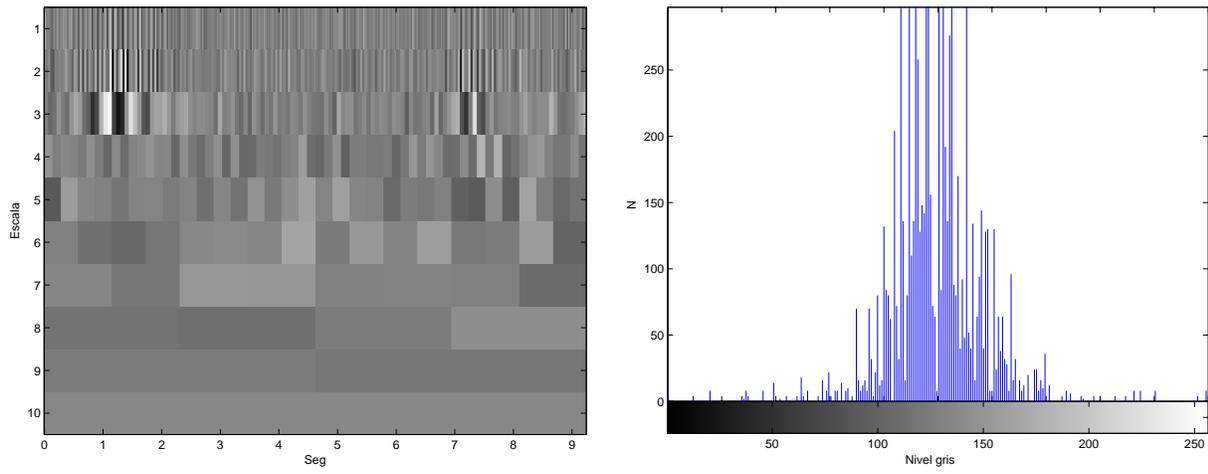


Figura 4.53: Izquierda: Escalograma con haar 256 niveles de gris secuencia CAP, Derecha: Histograma

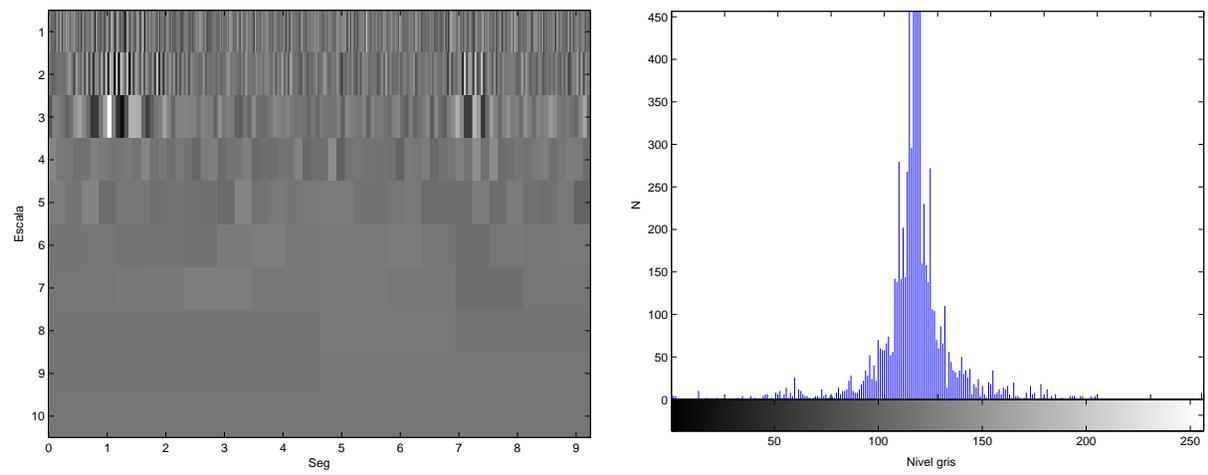


Figura 4.54: Izquierda: Escalograma con Daubechies 4 256 niveles de gris secuencia CAP, Derecha: Histograma

La binarización se aplica a la imagen en 256 niveles de gris, para ello se selecciona un umbral de binarización. Los umbrales seleccionados en nuestro trabajo fueron obtenidos mediante experimentación; las distribuciones fueron binarizadas 256 veces con umbrales de 0 a 255 y se eligió como umbral el valor tal que el resultado obtenido fuera cualitativamente el mejor. Las figuras[4.55; 4.56; 4.57; 4.58] muestran el resultado de la binarización con el mejor umbral.

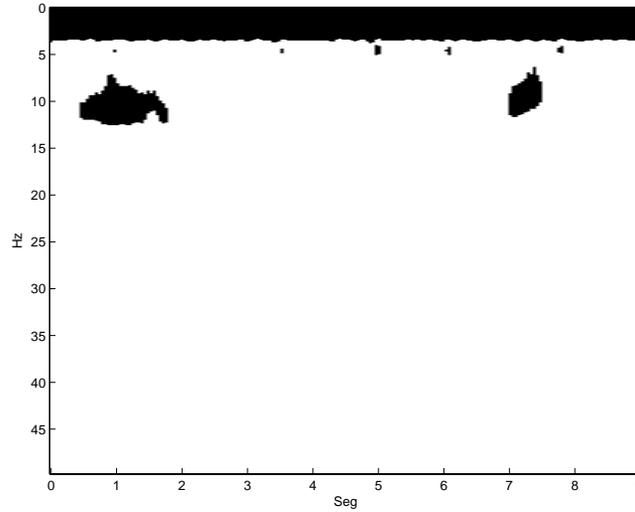


Figura 4.55: Espectrograma binarizado con un umbral de 187

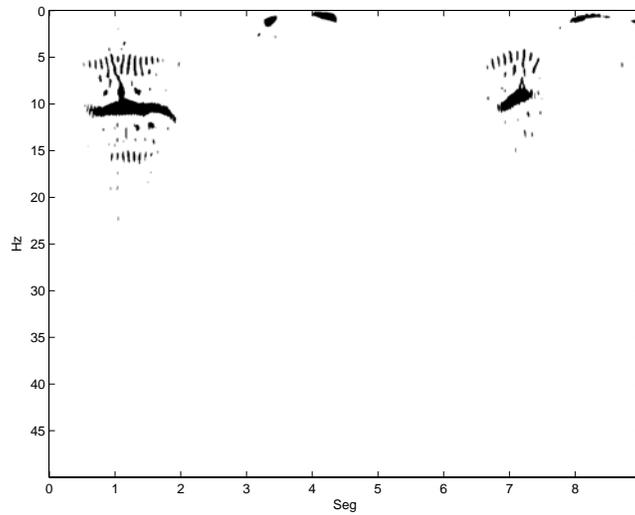


Figura 4.56: Distribución Wigner - Ville binarizada con un umbral de 114

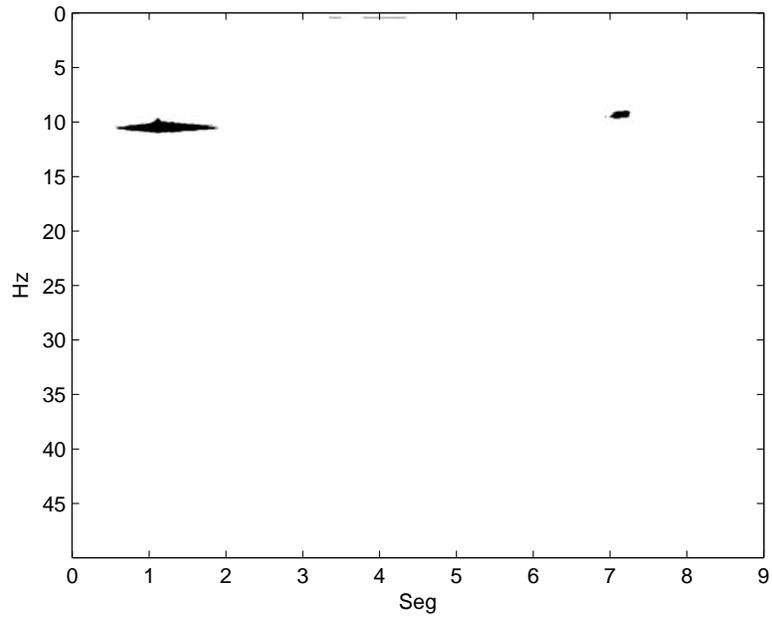


Figura 4.57: Distribución Choi - Williams binarizada con un umbral de 70

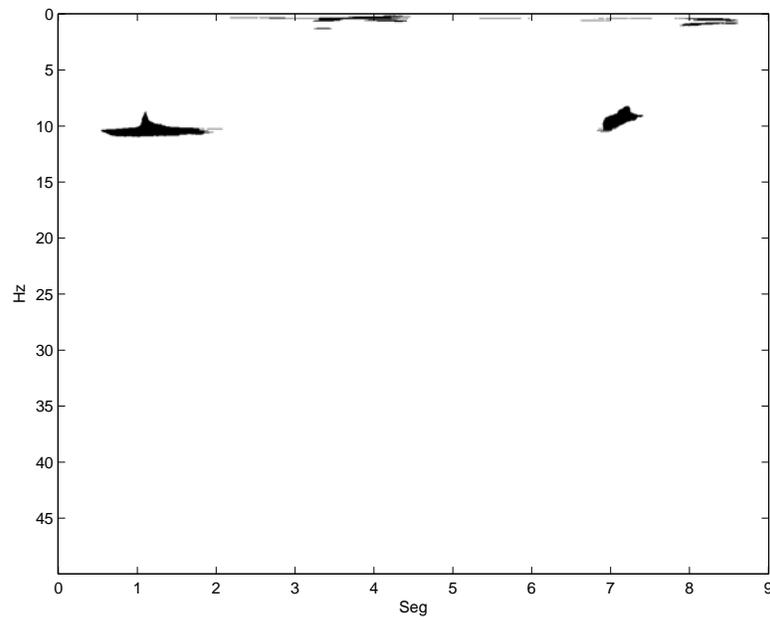


Figura 4.58: Distribución Bessel binarizada con un umbral de 53

El cuadro 4.3 muestra un resumen de los umbrales utilizados para la binarización de cada una de las distribuciones tiempo - frecuencia.

Distribución	Umbral
Espectrograma	170
Wigner - Ville	114
Choi - Williams	114
Bessel	53

Cuadro 4.3: Umbrales utilizados para la binarización

En las siguientes figuras(4.59, 4.60, 4.61, 4.62); se muestran los resultados de la obtención de los bordes de las distribuciones binarizadas. Los bordes se obtuvieron a partir de la implementación de un filtro Sobel en dos dimensiones.

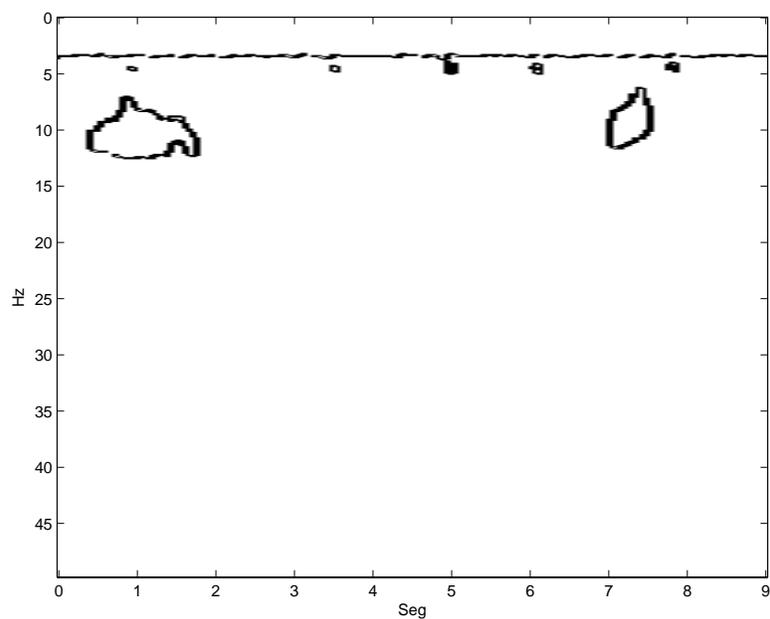


Figura 4.59: Contorno del espectrograma binarizado

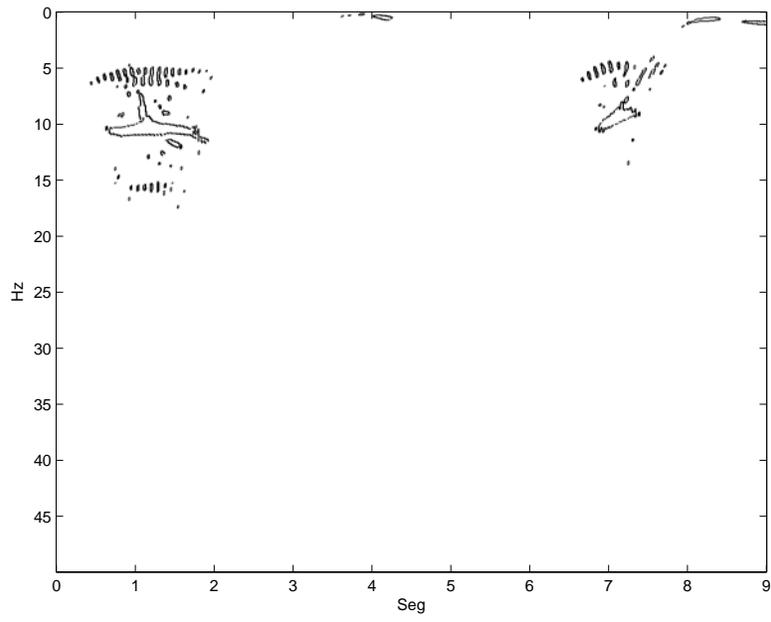


Figura 4.60: Contorno de la distribución Wigner - Ville binarizada

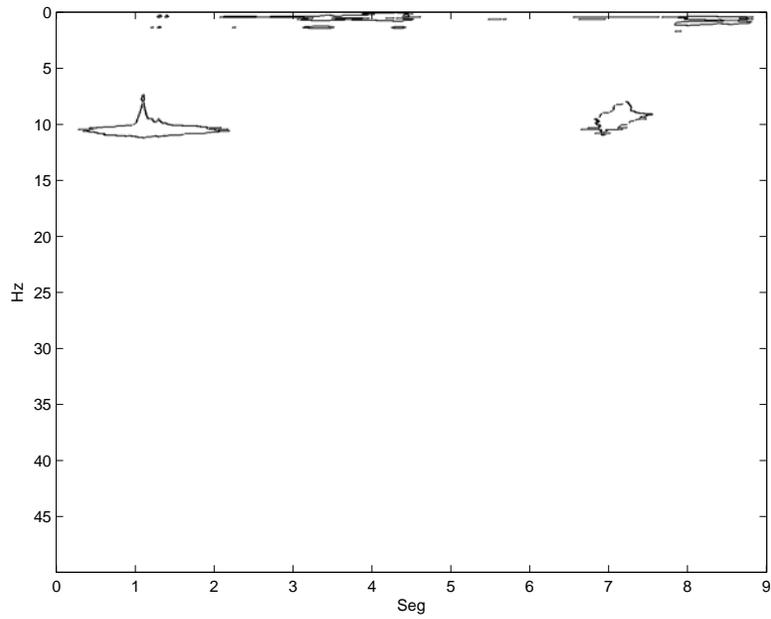


Figura 4.61: Contorno de la distribución Choi - Williams binarizada

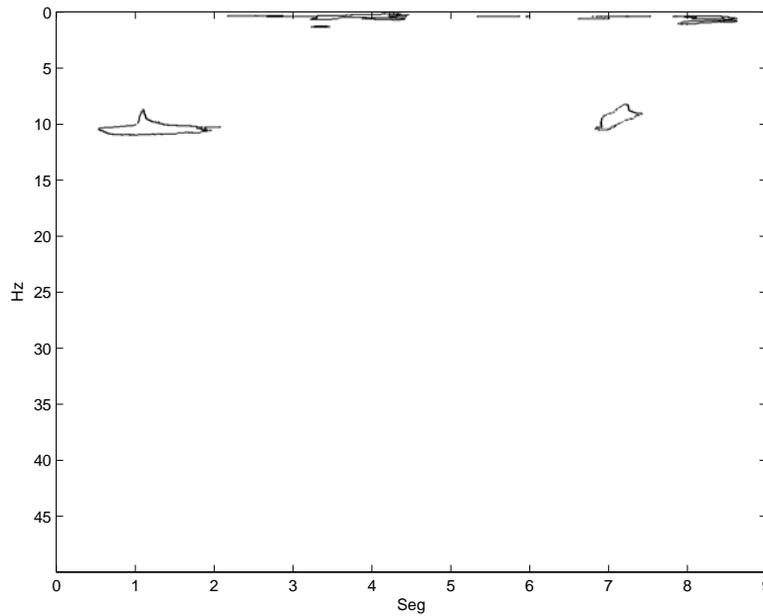


Figura 4.62: Contorno de la distribución Bessel binarizada

4.12. Índices para la evaluación de los resultados

Para la evaluación de los resultados se emplean dos índices de desempeño propuestos por Lima y Rosa en [42]:

- Porcentaje de secuencias CAP detectadas correctamente
- Porcentaje de concordancia entre la clasificación automática y la clasificación visual.

Para definir estos índices de desempeño, se definen los siguientes parámetros:

A Secuencias A identificadas por el algoritmo

B Secuencias B identificadas por el algoritmo

TA Secuencias A identificadas por el algoritmo que corresponden a las secuencias A identificadas de manera visual

TB Secuencias B identificadas por el algoritmo que corresponden a las secuencias B identificadas de manera visual

FP Falsos positivos. Se refiere a las secuencias A identificadas por el algoritmo las cuales no fueron identificadas de forma visual

FN Falsos negativos. Se refiere a las secuencias A que no fueron identificadas por el algoritmo y sí fueron identificadas de forma visual

La figura(4.63) describe gráficamente los parámetros anteriores.

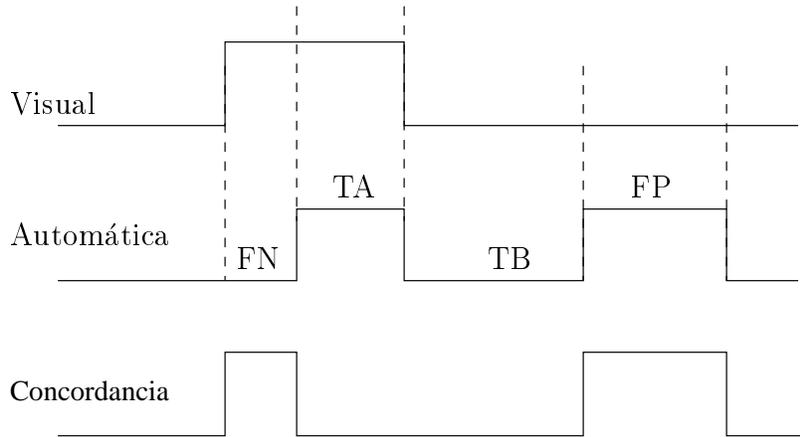


Figura 4.63: Definición de parámetros de evaluación de algoritmos

El porcentaje de secuencias CAP detectadas correctamente se define como el total de secuencias A verdaderas mas el total de secuencias B verdaderas entre el periodo de tiempo de análisis:

$$\frac{TA + TB}{TA + TB + FP + FN} 100 \%$$

En nuestro caso el período de análisis T es de 10 segundos.

El segundo criterio utilizado es la concordancia entre la clasificación visual y la clasificación automática, definida como el error entre la secuencia visual y la automática. Un error de 0 % corresponde al 100 % de concordancia y viceversa:

$$\left(1 - \frac{FP + FN}{TA + TB + FP + FN}\right) 100 \%$$

4.13. Conclusiones

En esta sección se hizo referencia a la forma en que los algoritmos fueron implementados. La implementación se hizo en Matlab©y paralelamente en JAVA con el objeto de contar con código propietario. Cabe señalar que todos los algoritmos muestran como ejemplo una misma secuencia CAP pero el procedimiento es análogo para todas y cada una de las secuencias cap a analizar.

Respecto a los algoritmos tiempo - frecuencia, cabe decir que el resultado fue tratado como una imagen, la cual se escaló a un nivel de 256 niveles de grises y luego se binarizó pensando en una señal de 2 niveles análoga a la representación CAP constituida por un estados A y estados B.

En todos los casos, se pensó en obtener el comportamiento promedio de las características de la señal, esto es potencia, coeficientes de correlación, parámetros AR, etc.. con la idea de si en algún momento llegara a ocurrir un cambio en la señal, sus características saldrían de su comportamiento promedio reflejando un cambio.

Finalmente se hace referencia a los índices utilizados para la evaluación del desempeño de cada algoritmo.

Capítulo 5

Evaluación de los Algoritmos ISCAP

En esta sección presentamos los resultados obtenidos al analizar 101 secuencias CAP con los siguientes algoritmos:

- Identificación de secuencias CAP mediante análisis de potencia
- Identificación secuencias CAP mediante estadísticas temporales
- Identificación secuencias CAP mediante análisis de coeficientes de correlación
- Identificación secuencias CAP mediante un modelo autorregresivo
- Identificación secuencias CAP mediante parámetros RLS
- Identificación secuencias CAP mediante métodos tiempo frecuencia: SFT, Wigner - Ville, Choi - Williams, Bessel
- Identificación secuencias CAP mediante métodos tiempo escala: transformada Haar y transformada Daubechies 4

Se realizaron tres clasificaciones visuales de 101 secuencias CAP de señales de sueño reales con las que se compararon los algoritmos antes mencionados. A manera de ilustración se presentan 10 secuencias CAP y sus gráficas de resultados para cada algoritmo; los resultados de las secuencias restantes se presentan en tablas de resultados en un anexo a este documento [38]. Dentro de estas tablas se incluye la cantidad en muestras de fases **A** y **B** identificadas por cada algoritmo; la cantidad en muestras correspondientes a las fases **A** y **B** calificadas de manera visual; la cantidad de **A** correctos (TA); la cantidad de **B** correctos (TB); la cantidad de falsos positivos (FP) y la cantidad de falsos negativos (FN).

5.1. Identificación de secuencias CAP mediante análisis de potencia

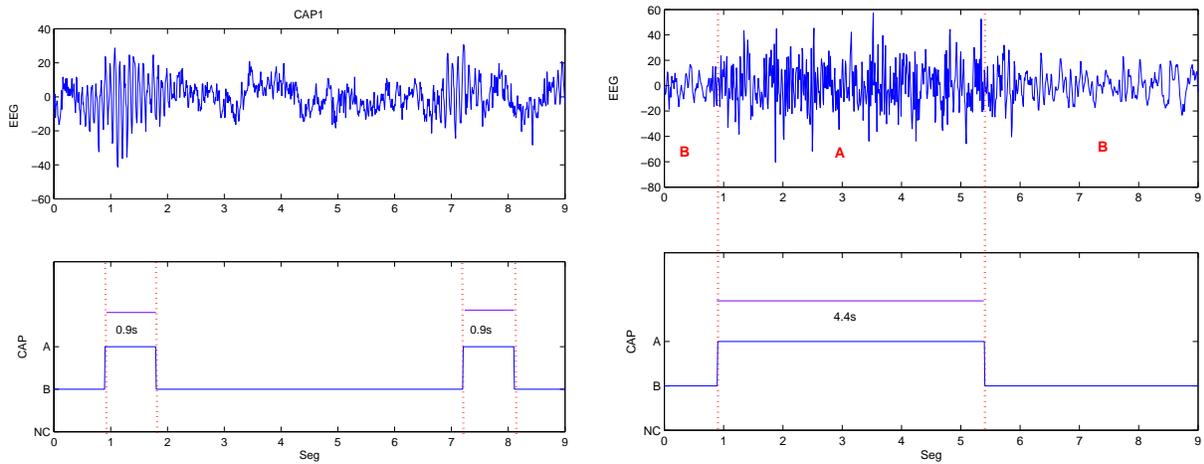


Figura 5.1: Izquierda: Identificación análisis potencia secuencia CAP 1, Derecha: Identificación análisis potencia secuencia CAP 2

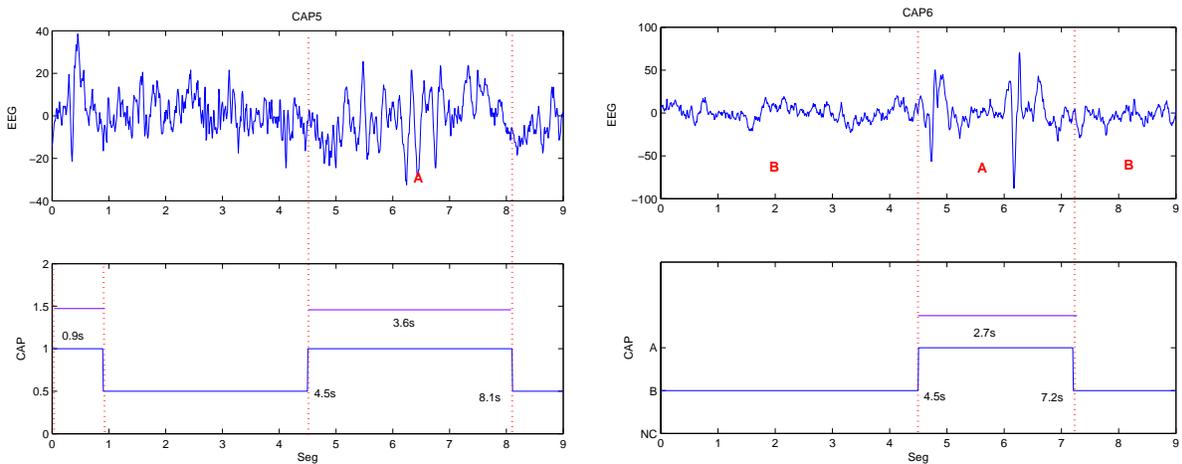


Figura 5.2: Izquierda: Identificación análisis potencia secuencia CAP 5, Derecha: Identificación análisis potencia secuencia CAP 6

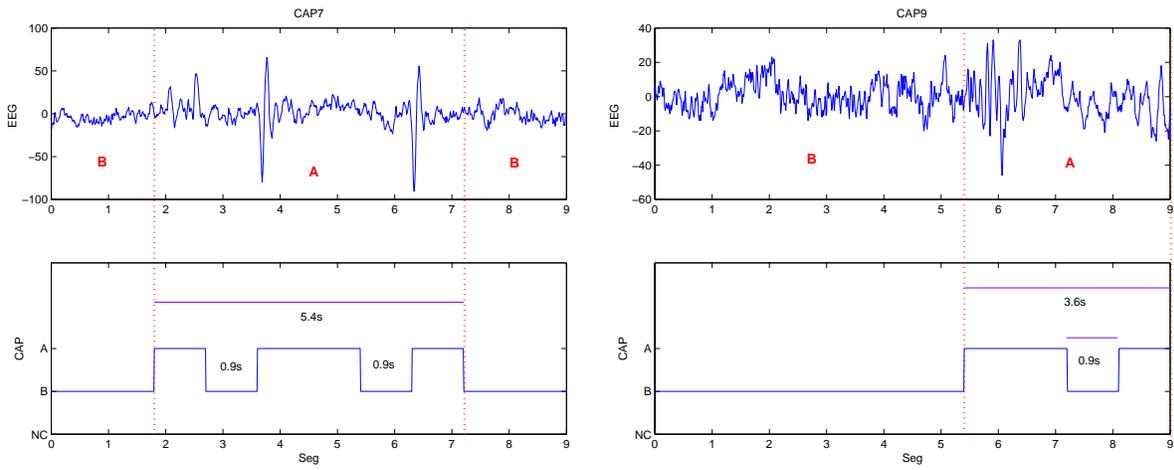


Figura 5.3: Izquierda: Identificación análisis potencia secuencia CAP 7, Derecha: Identificación análisis potencia secuencia CAP 9

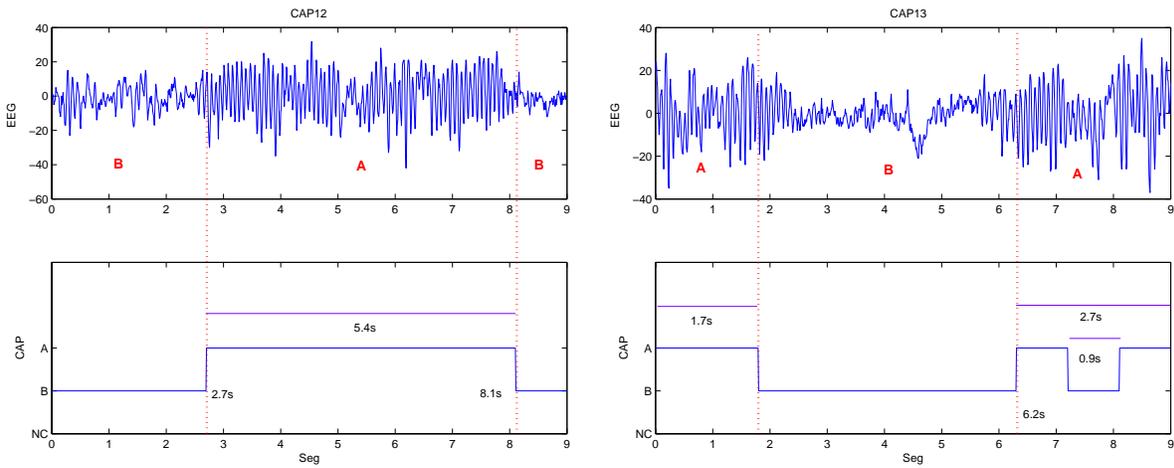


Figura 5.4: Izquierda: Identificación análisis potencia secuencia CAP 12, Derecha: Identificación análisis potencia secuencia CAP 13

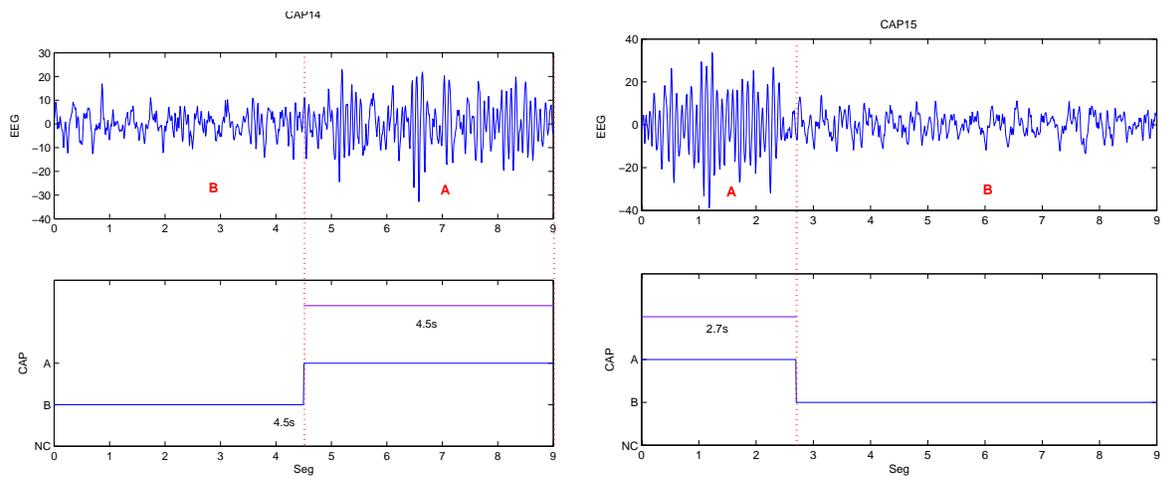


Figura 5.5: Izquierda: Identificación análisis potencia secuencia CAP 14, Derecha: Identificación análisis potencia secuencia CAP 15

Indice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	85.1	84.4	84.1	84.5
%Concordancia visual vs algoritmo	92.5	92.2	92.1	92.3

Cuadro 5.1: Identificación de secuencias CAP mediante análisis de potencia

5.2. Identificación secuencias CAP mediante Estadísticas temporales

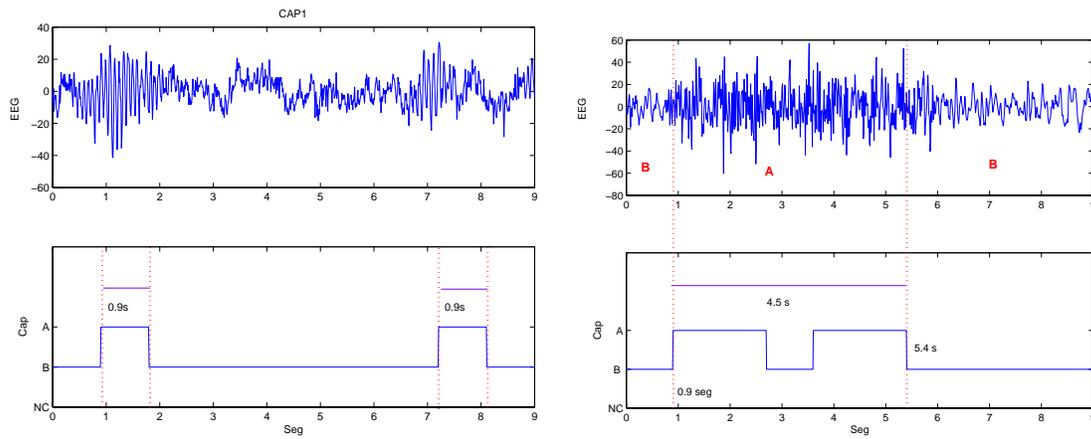


Figura 5.6: Izquierda: Identificación Est. temporales secuencia CAP 1, Derecha: Identificación Est. temporales secuencia CAP 2

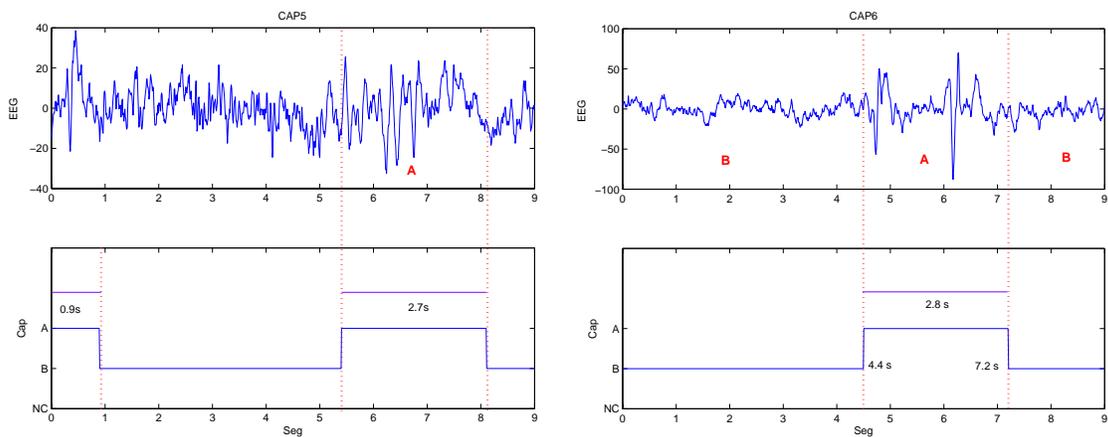


Figura 5.7: Izquierda: Identificación Est. temporales secuencia CAP 5, Derecha: Identificación Est. temporales secuencia CAP 6

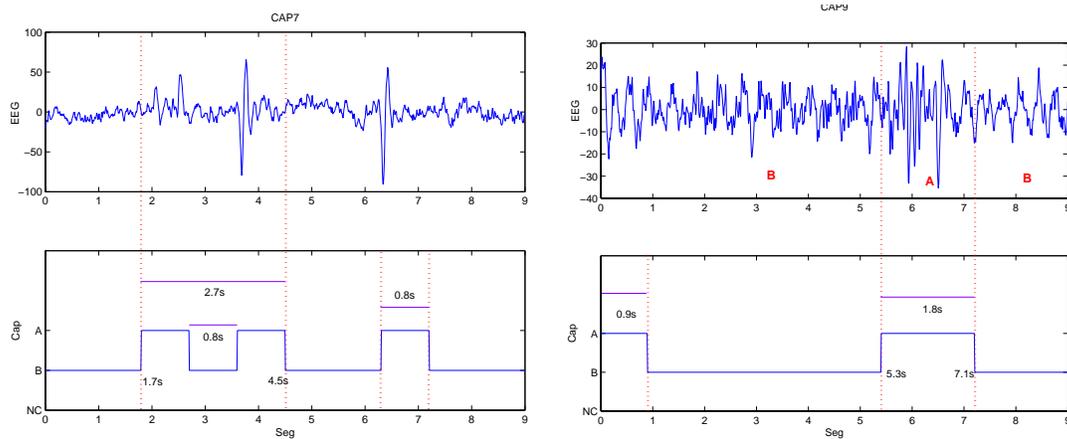


Figura 5.8: Izquierda: Identificación Est. temporales secuencia CAP 7, Derecha: Identificación Est. temporales secuencia CAP 9

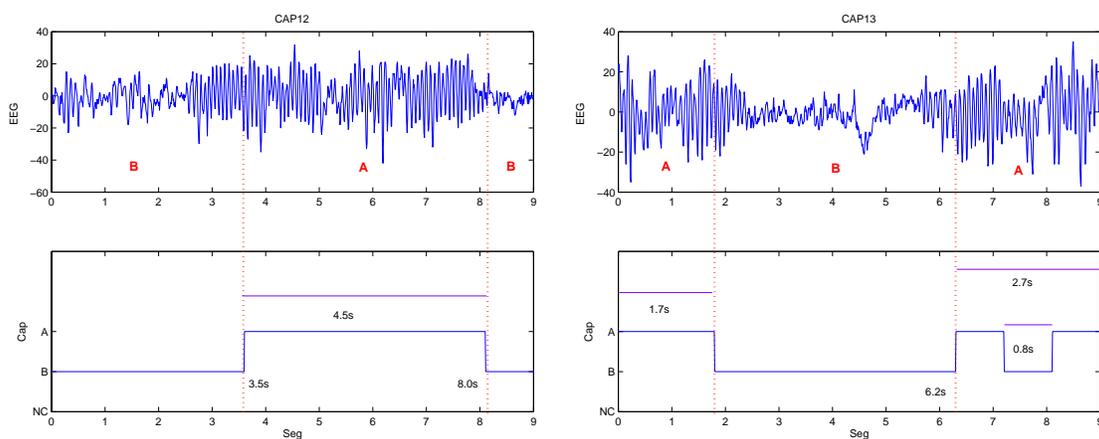


Figura 5.9: Izquierda: Identificación Est. temporales secuencia CAP 12, Derecha: Identificación Est. temporales secuencia CAP 13

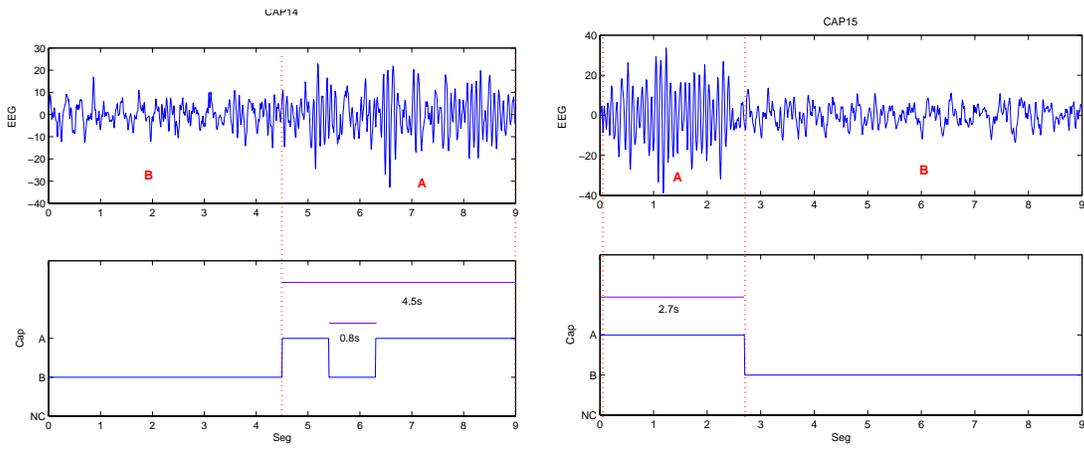


Figura 5.10: Izquierda: Identificación Est. temporales secuencia CAP 14, Derecha: Identificación Est. temporales secuencia CAP 15

Indice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	84.5	84.7	84.1	84.4
%Concordancia visual vs algoritmo	92.2	92.3	92.1	92.2

Cuadro 5.2: Identificación de secuencias CAP mediante estadísticas temporales

5.3. Identificación de secuencias CAP mediante coeficientes de Correlación y distancia de Chebyshev

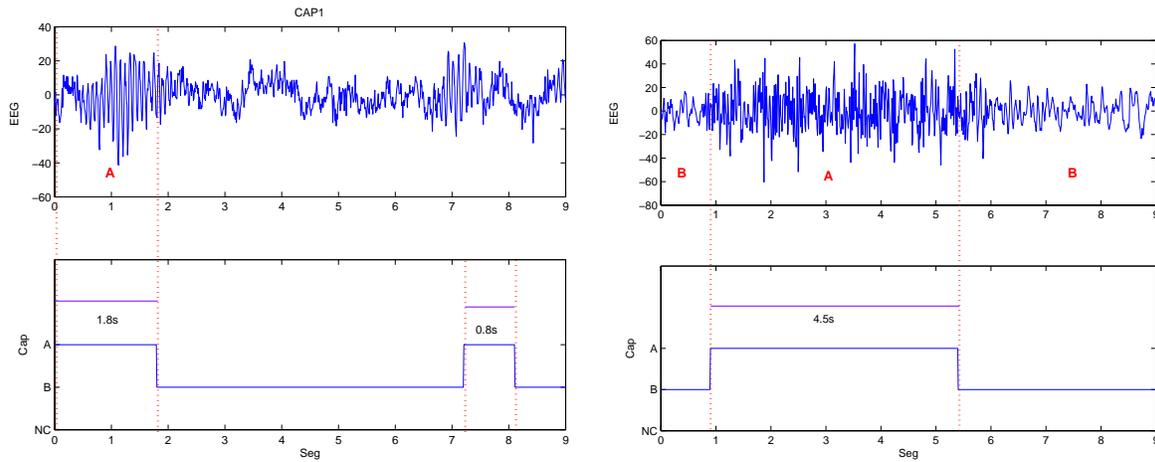


Figura 5.11: Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 1, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 2

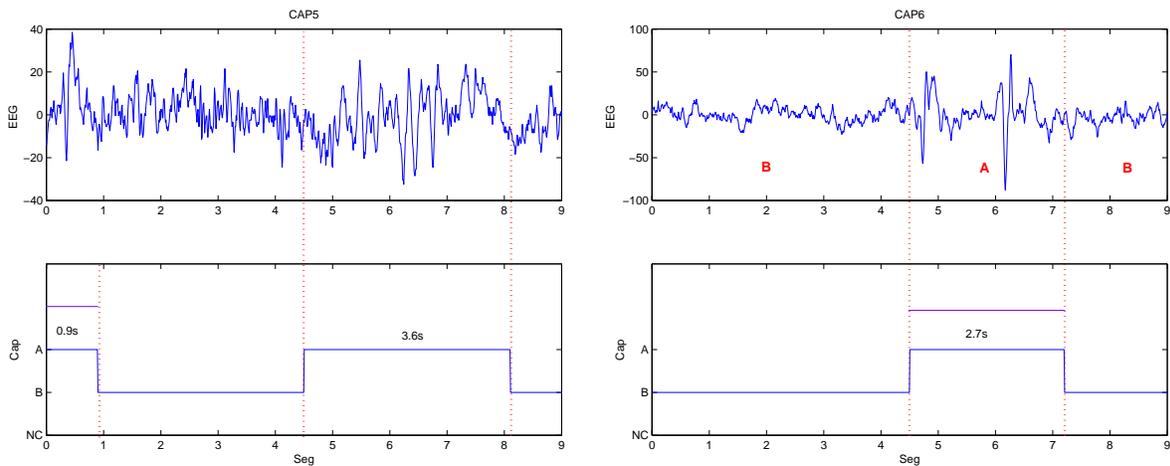


Figura 5.12: Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 5, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 6

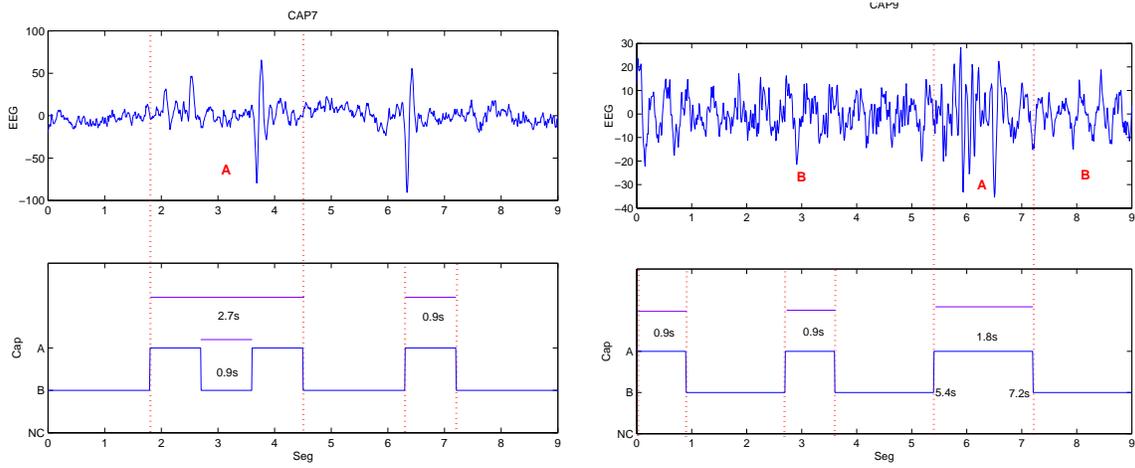


Figura 5.13: Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 7, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 9

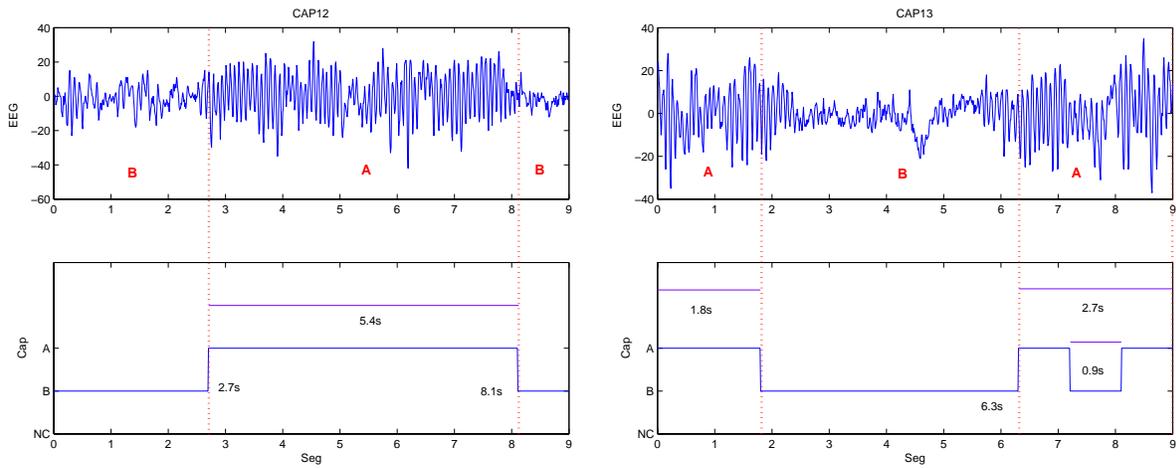


Figura 5.14: Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 12, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 13

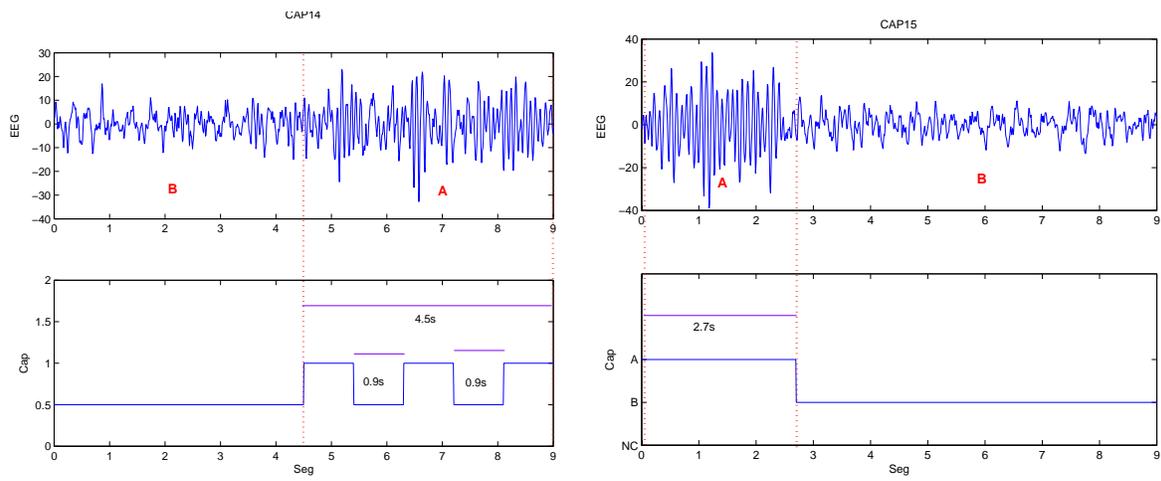


Figura 5.15: Izquierda: Identificación correlación Dist. Chebyshev secuencia CAP 14, Derecha: Identificación correlación Dist. Chebyshev secuencia CAP 15

Indice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	83.9	83	83.7	83.5
%Concordancia visual vs algoritmo	91.9	91.5	91.9	91.8

Cuadro 5.3: Identificación de secuencias CAP mediante coeficientes de Correlación y distancia de Chebyshev

5.4. Identificación de secuencias CAP mediante Modelo Autorregresivo y distancia espectral

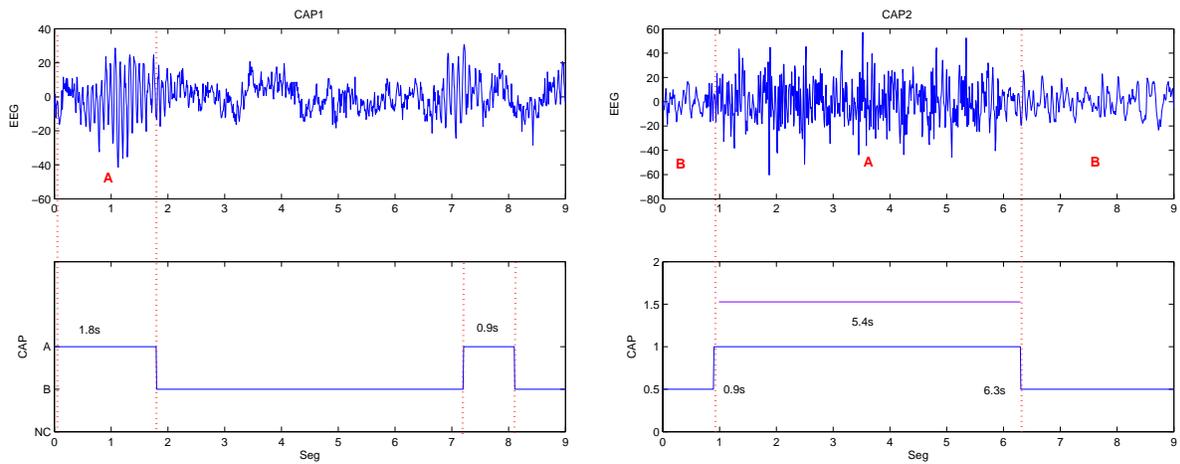


Figura 5.16: Izquierda: Identificación AR-Dist. Espectral secuencia CAP 1 , Derecha: Identificación AR-Dist. Espectral secuencia CAP 2

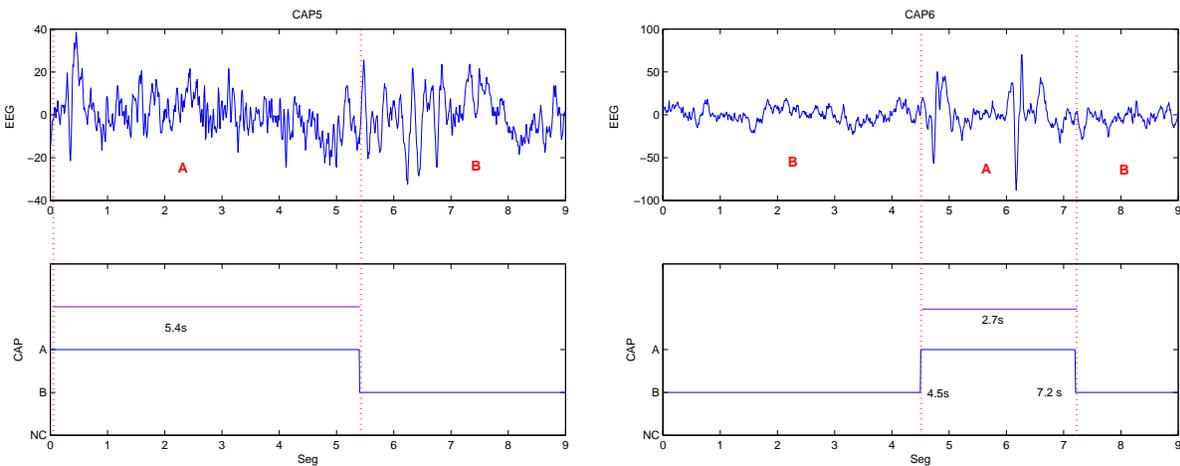


Figura 5.17: Izquierda: Identificación AR-Dist. Espectral secuencia CAP 5, Derecha: Identificación AR-Dist. Espectral secuencia CAP 6

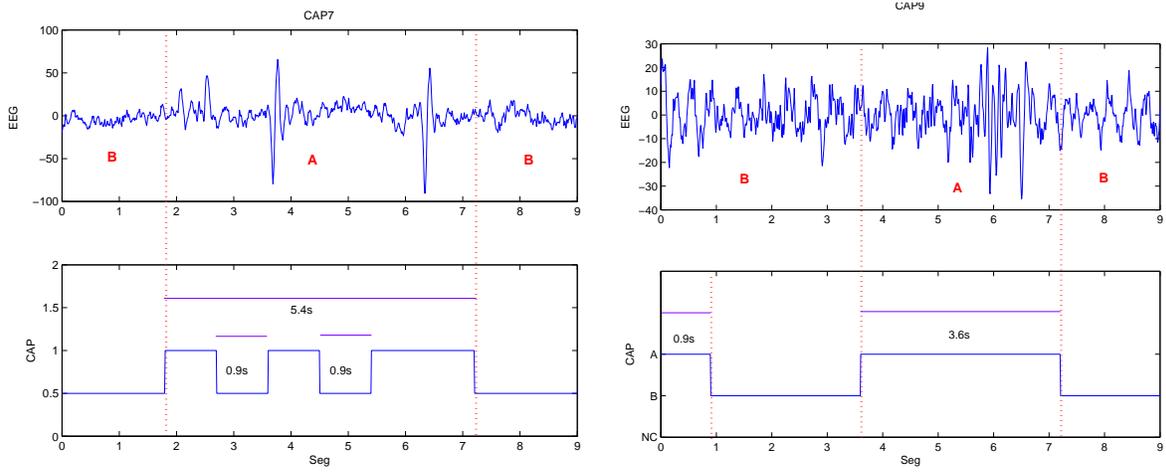


Figura 5.18: Izquierda: Identificación AR-Dist. Espectral secuencia CAP 7, Derecha: Identificación AR-Dist. Espectral secuencia CAP 9

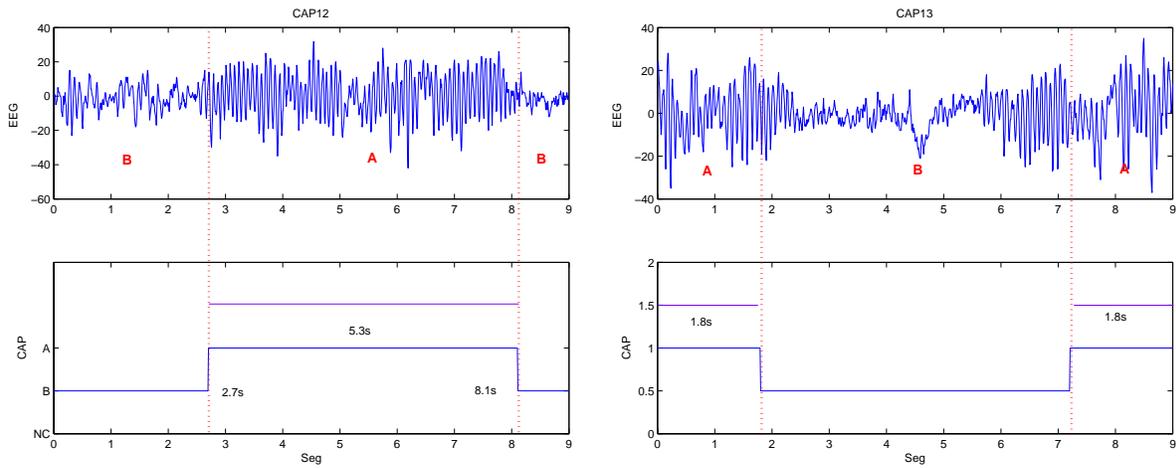


Figura 5.19: Izquierda: Identificación AR-Dist. Espectral secuencia CAP 12, Derecha: Identificación AR-Dist. Espectral secuencia CAP 13

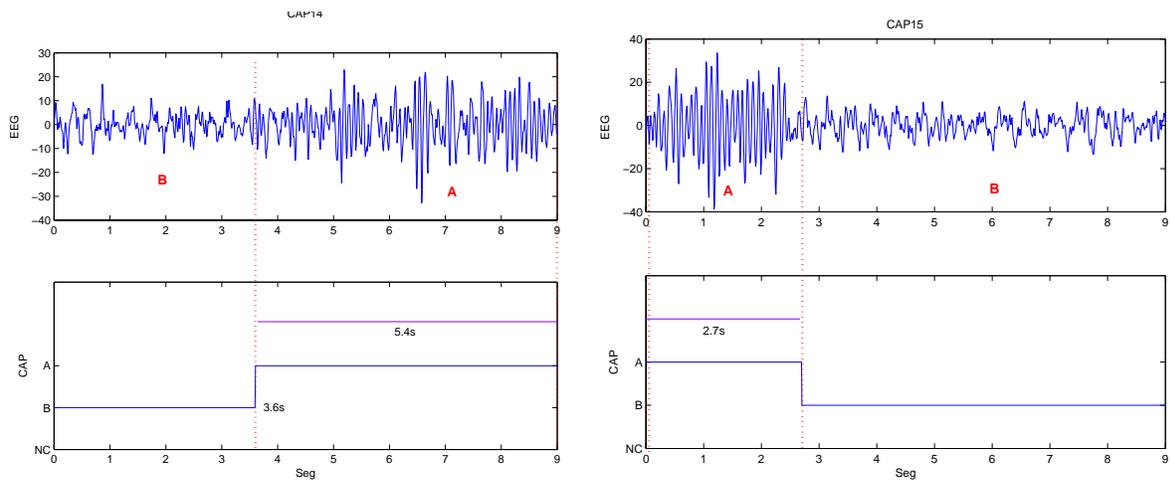


Figura 5.20: Izquierda: Identificación AR-Dist. Espectral secuencia CAP 14, Derecha: Identificación AR-Dist. Espectral secuencia CAP 15

Indice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	83.7	82.7	83	83.1
%Concordancia visual vs algoritmo	91.8	91.4	91.5	91.6

Cuadro 5.4: Identificación de secuencias CAP mediante Modelo Autorregresivo y distancia espectral

5.5. Identificación de secuencias CAP mediante Modelo Autorregresivo y distancia geométrica

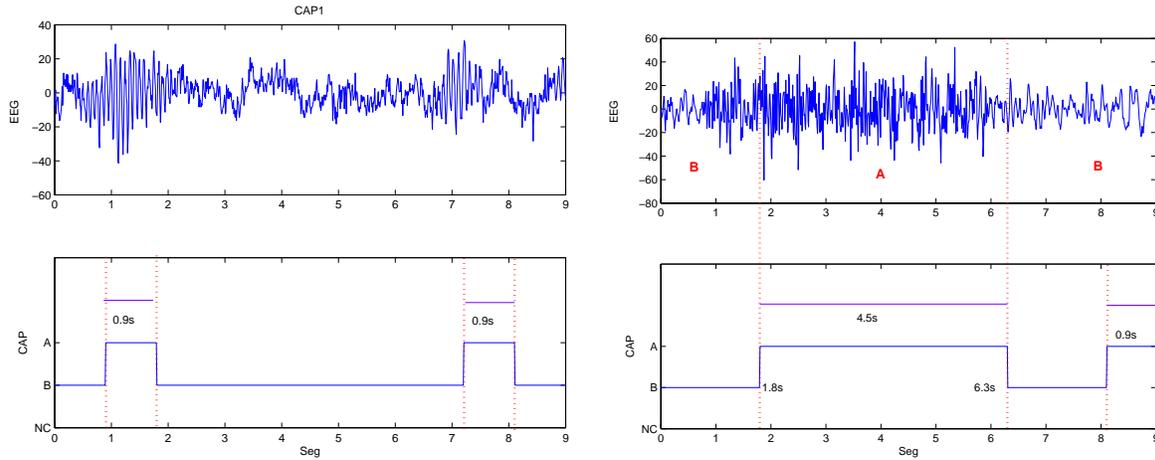


Figura 5.21: Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 1, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 2

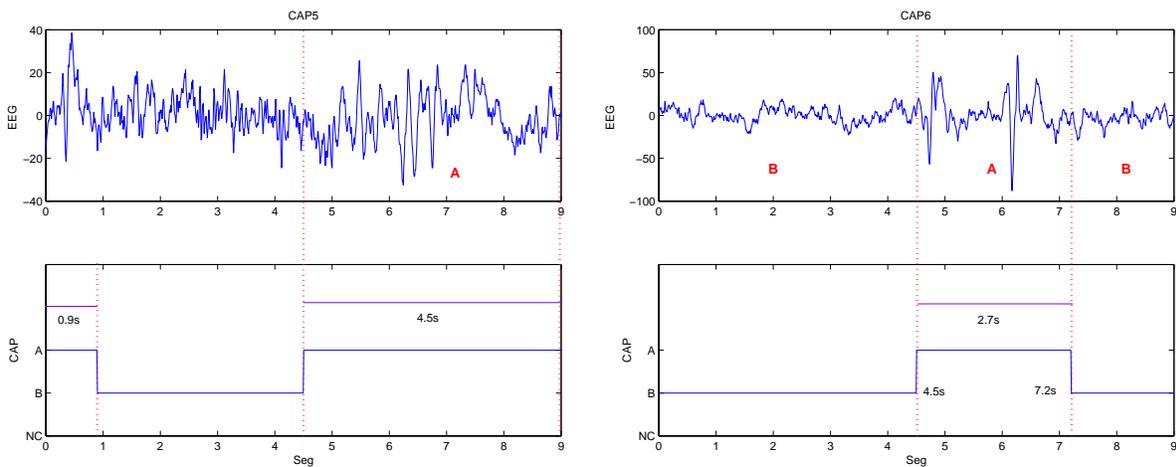


Figura 5.22: Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 5, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 6

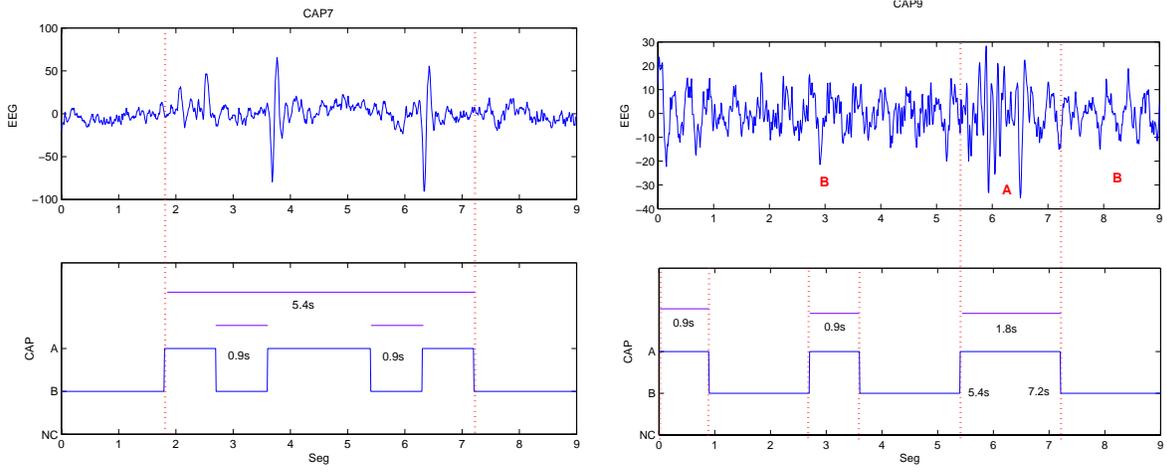


Figura 5.23: Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 7, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 9

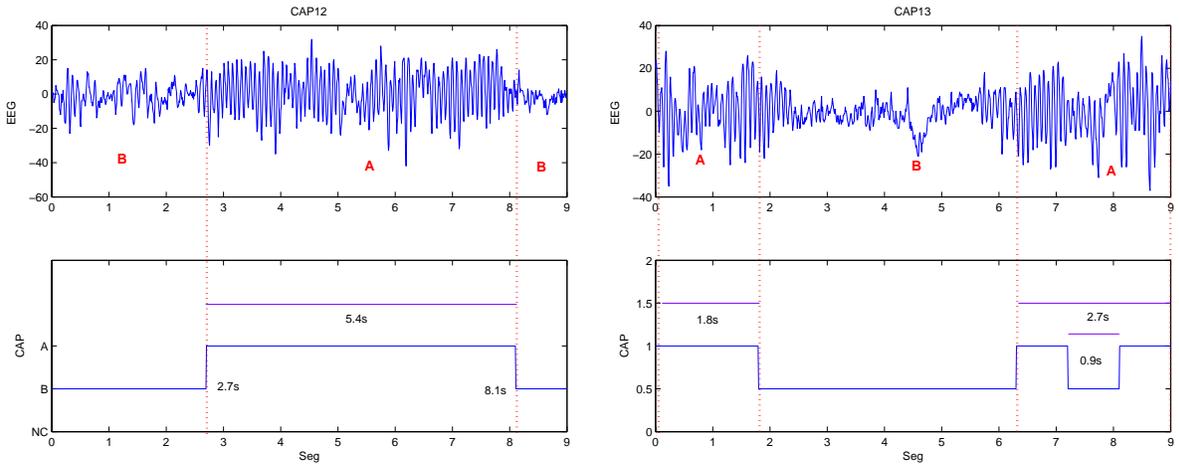


Figura 5.24: Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 12, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 13

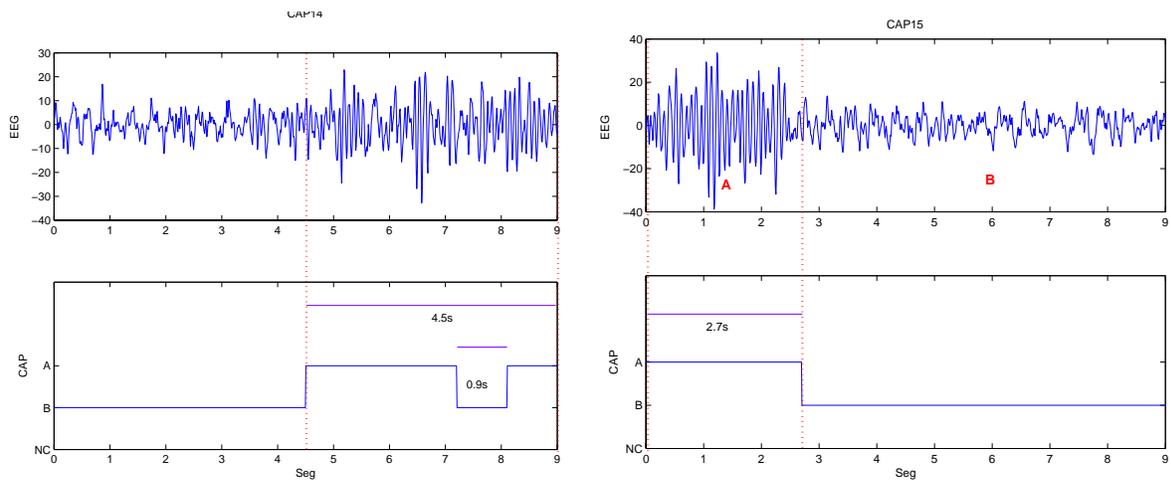


Figura 5.25: Izquierda: Identificación AR-Dist. Geométrica secuencia CAP 14, Derecha: Identificación AR-Dist. Geométrica secuencia CAP 15

Índice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	82.4	81.9	82.4	82.2
% Concordancia visual vs algoritmo	91.2	91.0	91.2	91.1

Cuadro 5.5: Identificación de secuencias CAP mediante Modelo Autorregresivo y distancia geométrica

5.6. Identificación de secuencias CAP mediante parámetros RLS

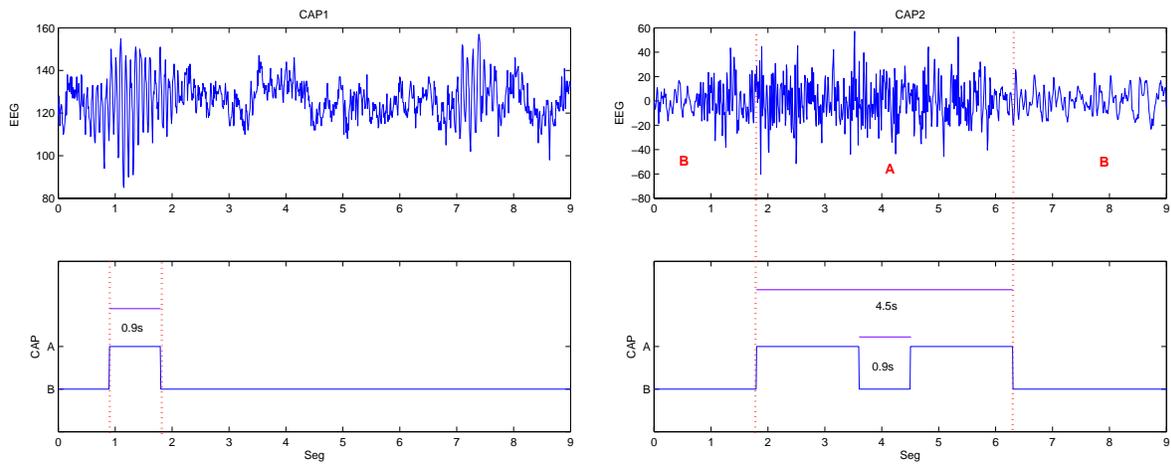


Figura 5.26: Izquierda: Identificación RLS secuencia CAP 1, Derecha: Identificación RLS secuencia CAP 2

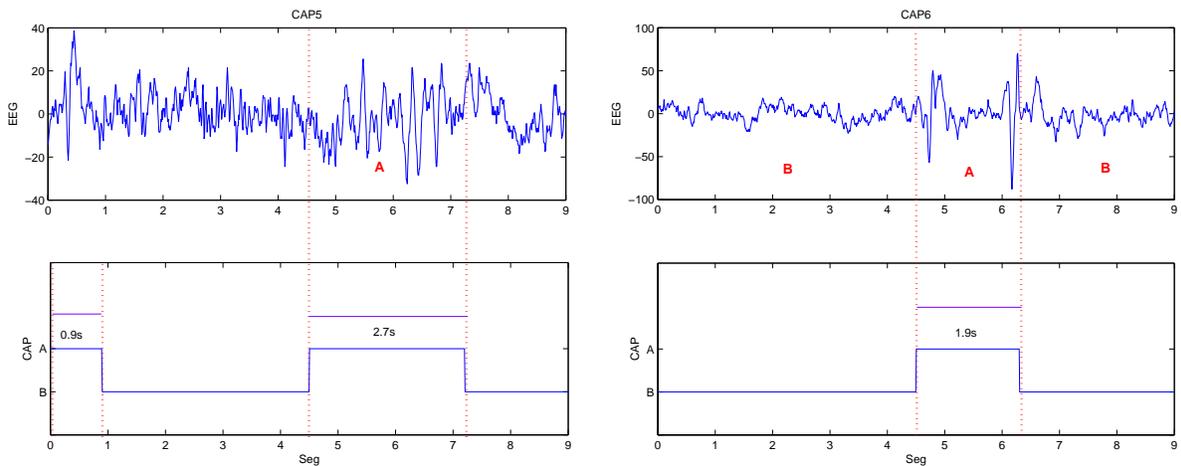


Figura 5.27: Izquierda: Identificación RLS secuencia CAP 5, Derecha: Identificación RLS secuencia CAP 6

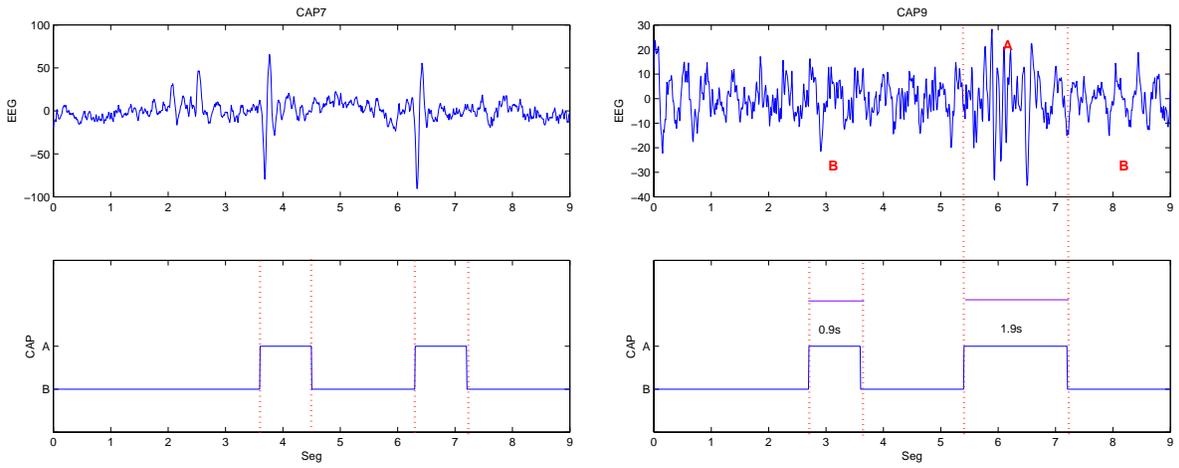


Figura 5.28: Izquierda: Identificación RLS secuencia CAP 7, Derecha: Identificación RLS secuencia CAP 9

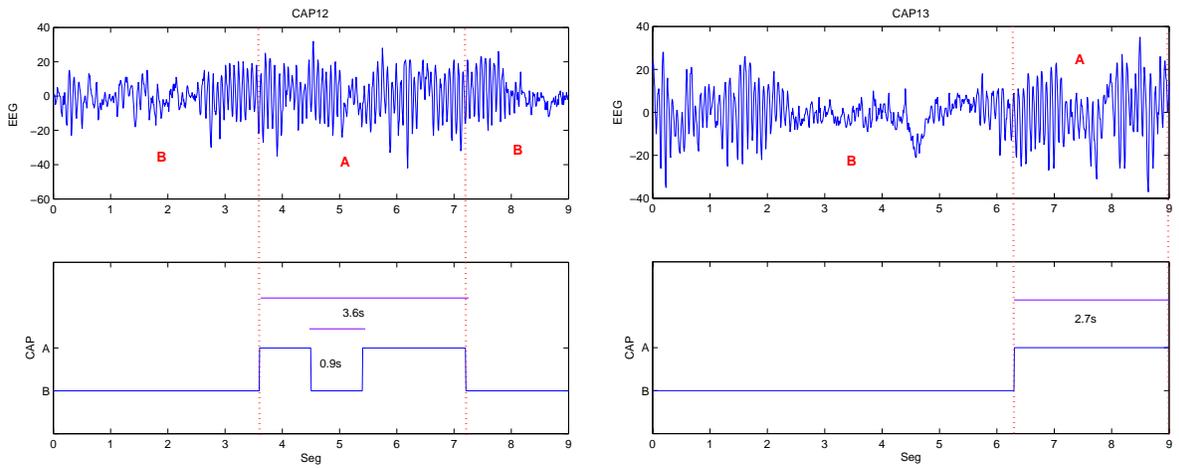


Figura 5.29: Izquierda: Identificación RLS secuencia CAP 12, Derecha: Identificación RLS secuencia CAP 13

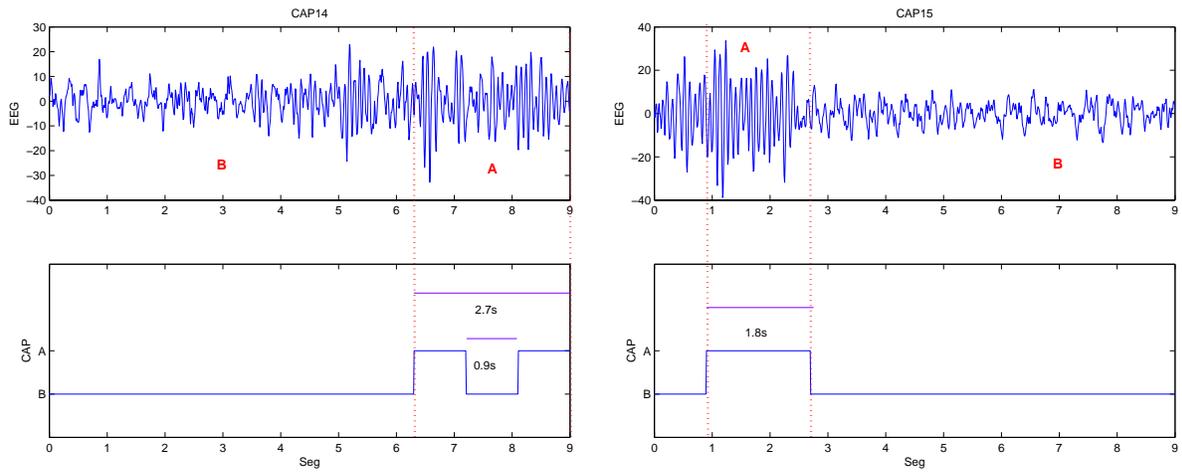


Figura 5.30: Izquierda: Identificación RLS secuencia CAP14, Derecha: Identificación RLS secuencia CAP 15

Indice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	84.3	84.1	83.8	83.9
%Concordancia visual vs algoritmo	90.2	91.0	90.9	90.7

Cuadro 5.6: Identificación de secuencias CAP mediante parámetros RLS

5.7. Identificación de secuencias CAP mediante espectrograma

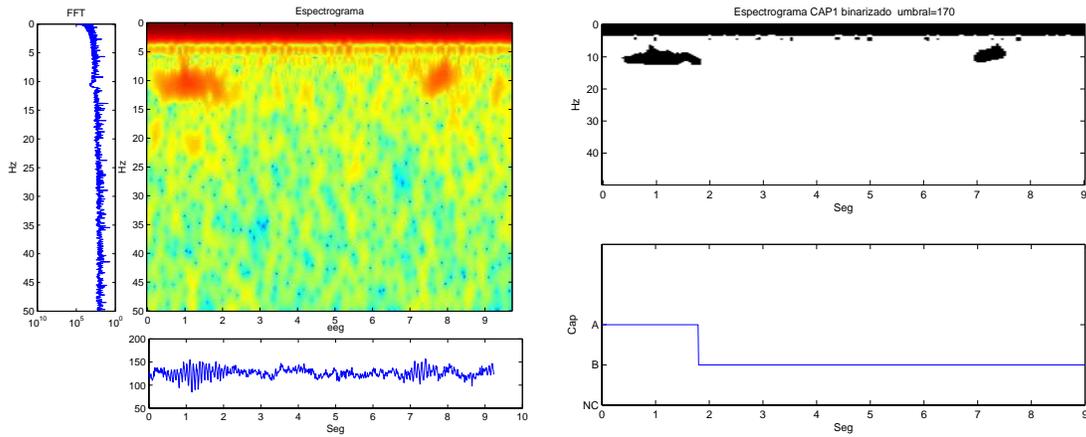


Figura 5.31: Izquierda:Espectrograma secuencia 1 NPF=256; ventana=50. Derecha: Identificación CAP umbral=170

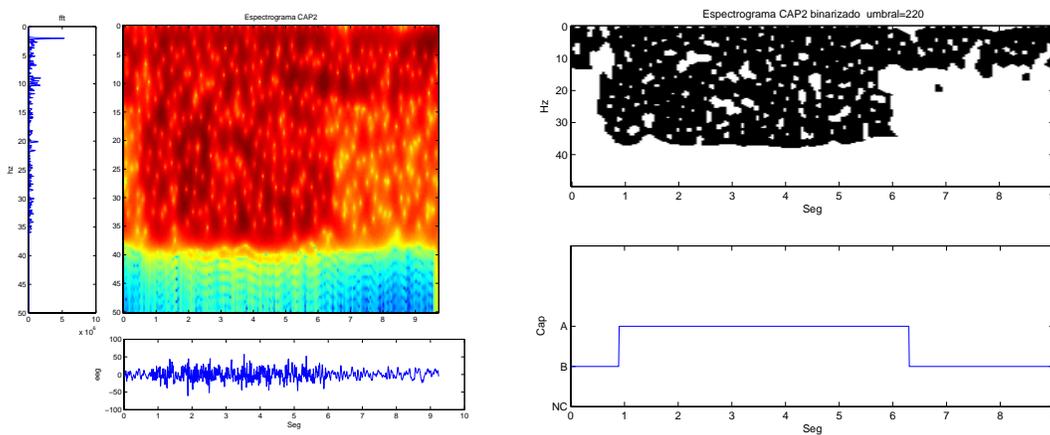


Figura 5.32: Izquierda:Espectrograma secuencia 2 NPF=256; ventana=50. Derecha: Identificación CAP umbral=220

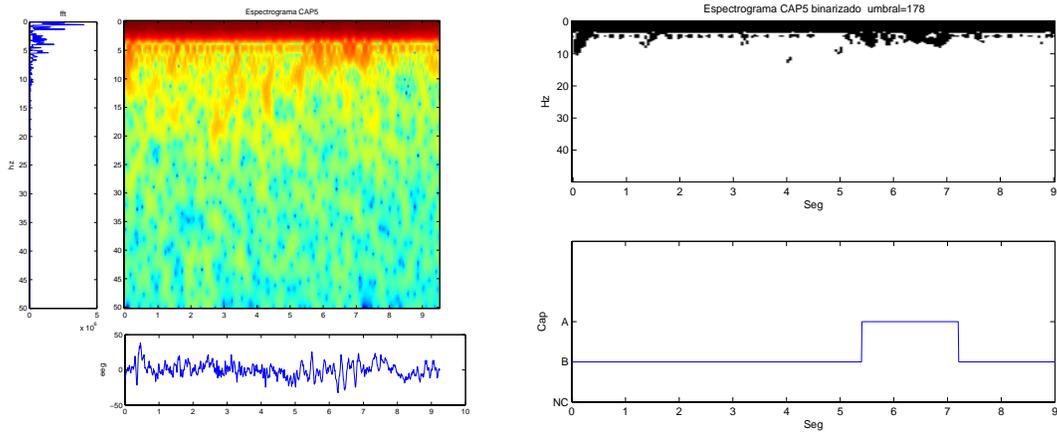


Figura 5.33: Izquierda:Espectrograma secuencia 5 NPF=256; ventana=50. Derecha: Identificación CAP umbral=178

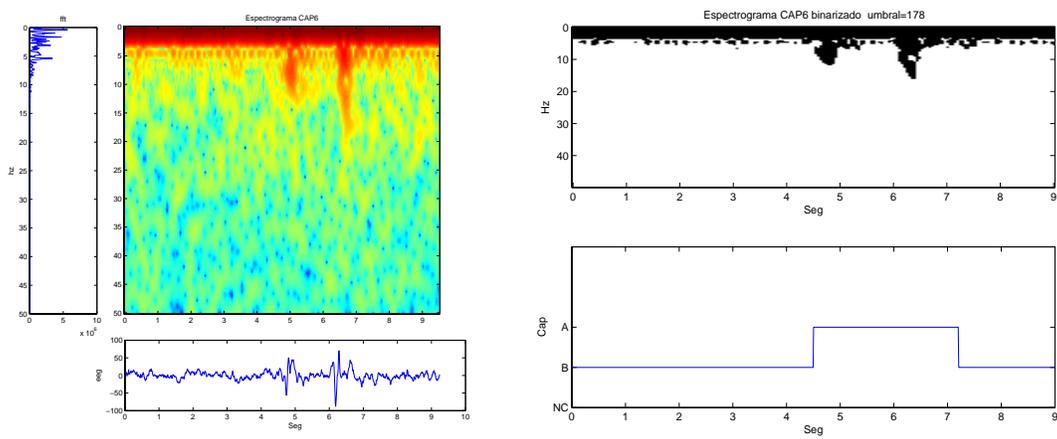


Figura 5.34: Izquierda:Espectrograma secuencia 6 NPF=256; ventana=50. Derecha: Identificación CAP umbral=178

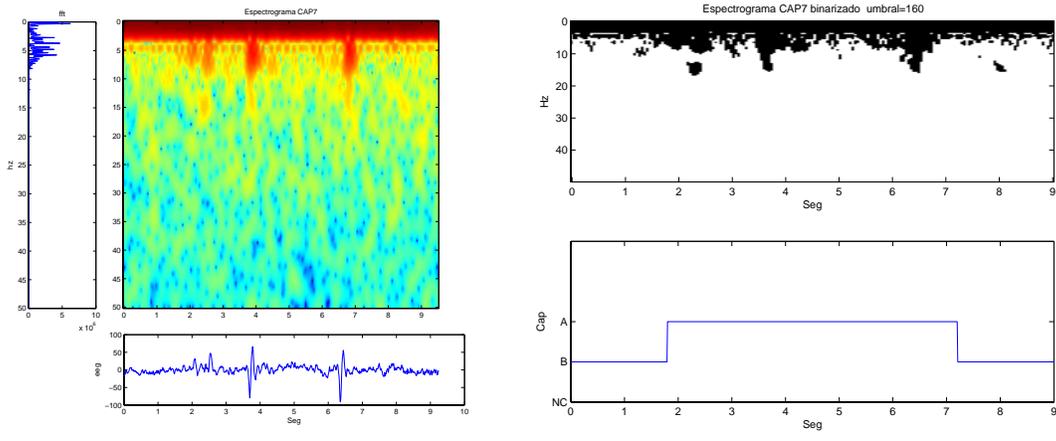


Figura 5.35: Izquierda:Espectrograma secuencia 7 NPF=256; ventana=50. Derecha: Identificación CAP umbral=160

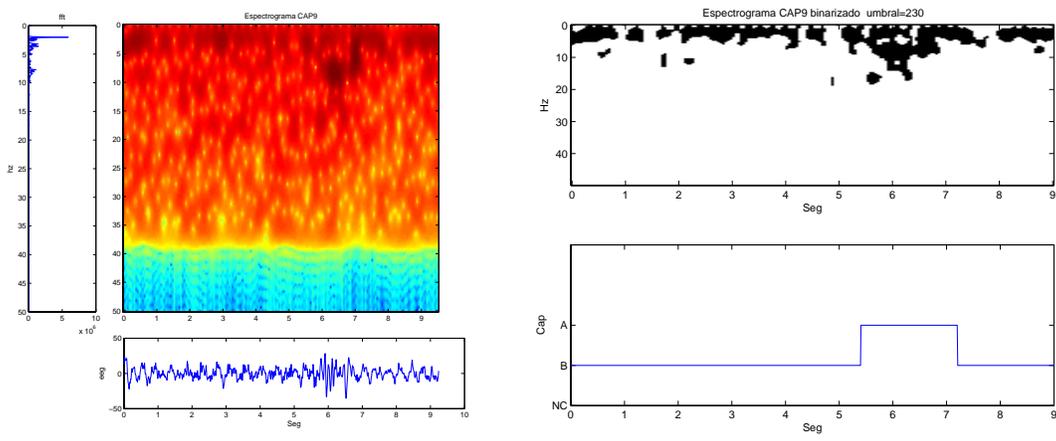


Figura 5.36: Izquierda:Espectrograma secuencia 9 NPF=256; ventana=50. Derecha: Identificación CAP umbral=230

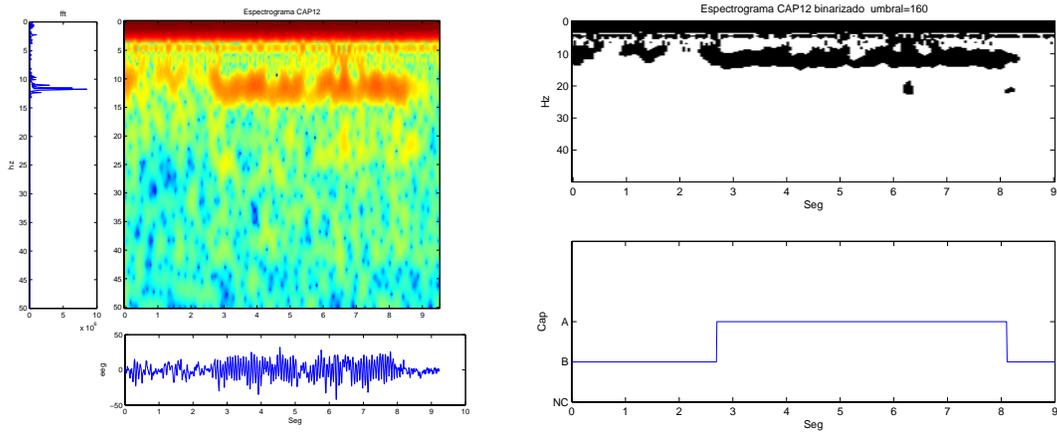


Figura 5.37: Izquierda:Espectrograma secuencia 12 NPF=256; ventana=50. Derecha: Identificación CAP umbral=160

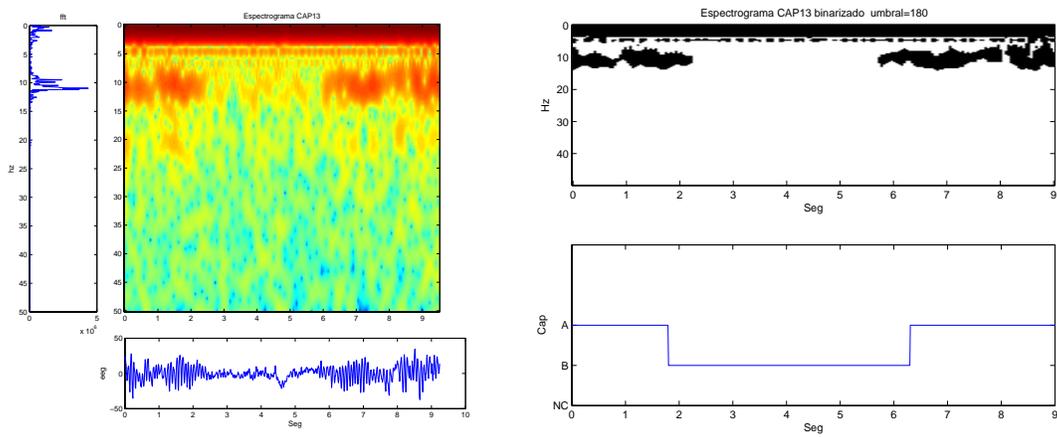


Figura 5.38: Izquierda:Espectrograma secuencia 13 NPF=256; ventana=50. Derecha: Identificación CAP umbral=180

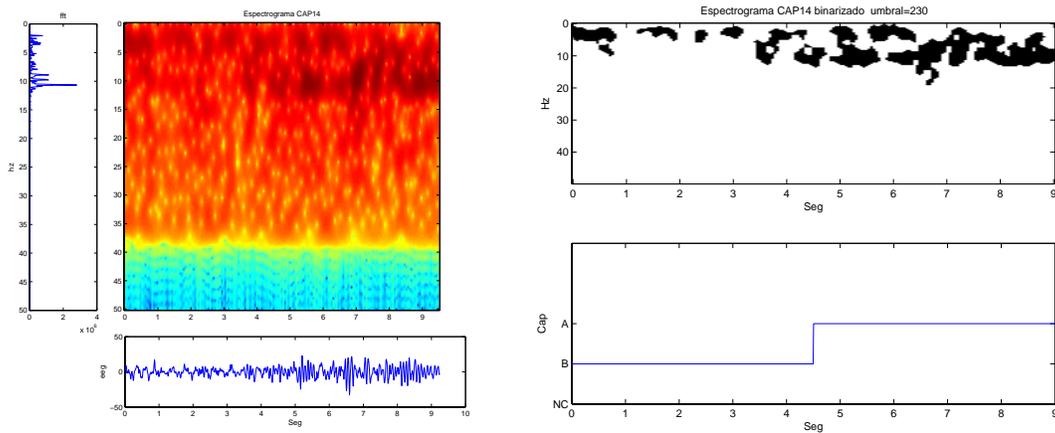


Figura 5.39: Izquierda:Espectrograma secuencia 14 NPF=256; ventana=50. Derecha: Identificación CAP umbral=230

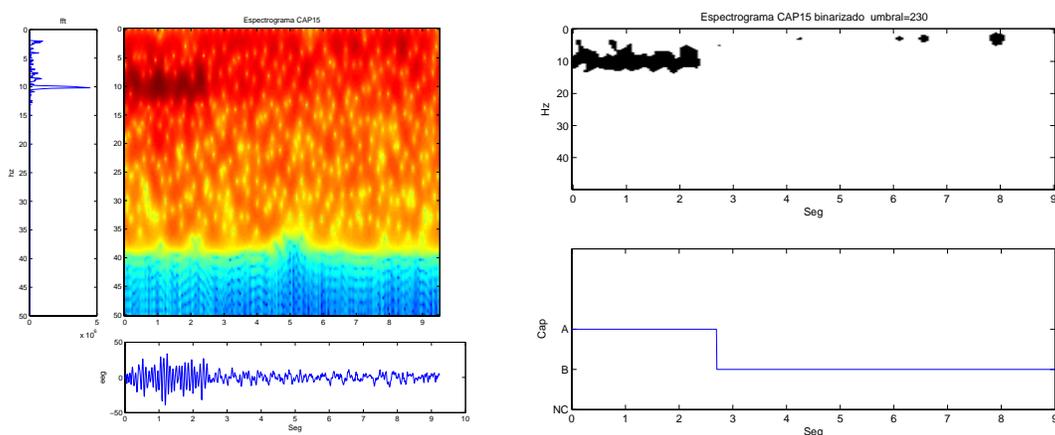


Figura 5.40: Izquierda:Espectrograma secuencia 15 NPF=256; ventana=50. Derecha: Identificación CAP umbral=230

Indice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	88.0	87.7	88.2	88
%Concordancia visual vs algoritmo	93.9	93.8	94.1	94

Cuadro 5.7: Identificación de secuencias CAP mediante espectrograma

5.8. Identificación de secuencias CAP mediante Distribución Wigner - Ville

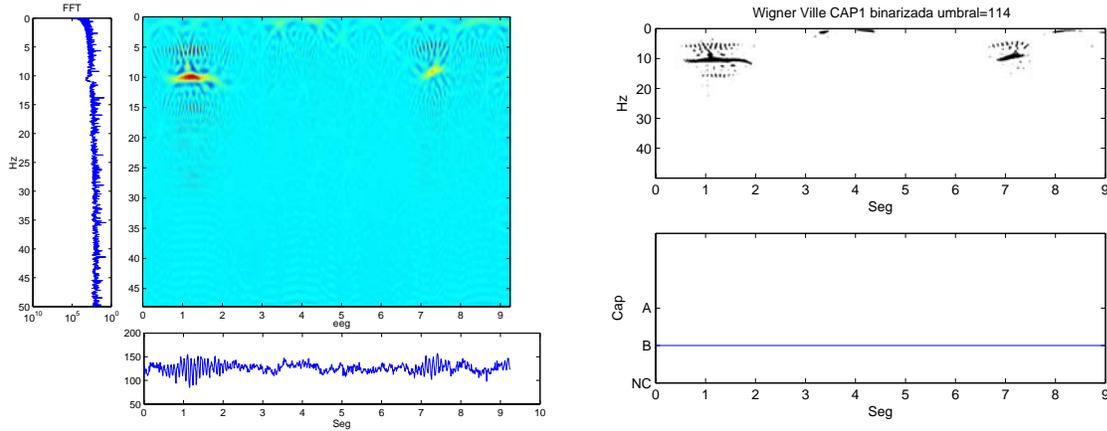


Figura 5.41: Izquierda: Distribución Wigner - Ville secuencia 1 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=114

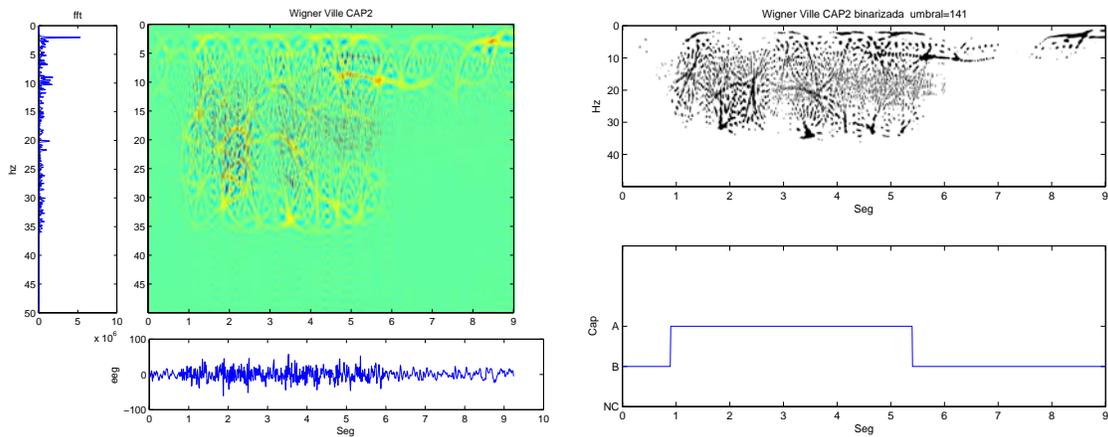


Figura 5.42: Izquierda: Distribución Wigner - Ville secuencia 2 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=141

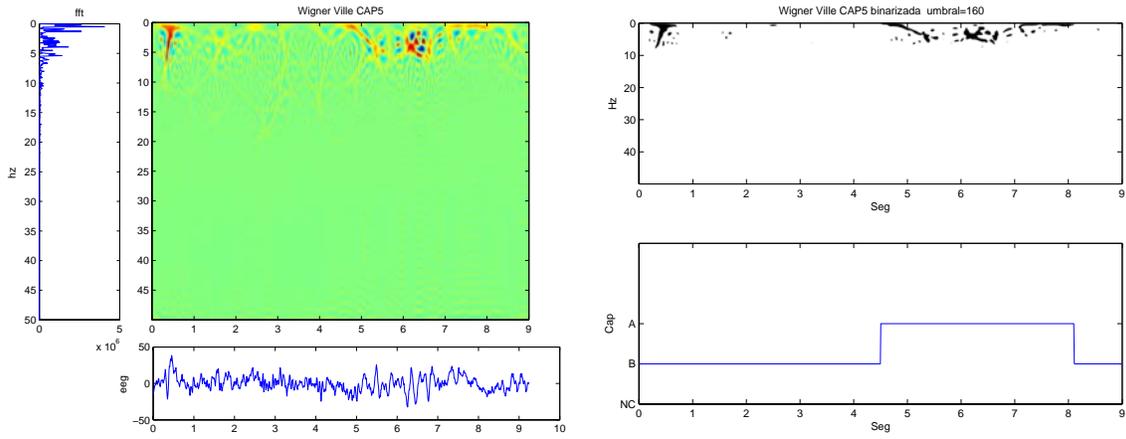


Figura 5.43: Izquierda: Distribución Wigner - Ville secuencia 5 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=160

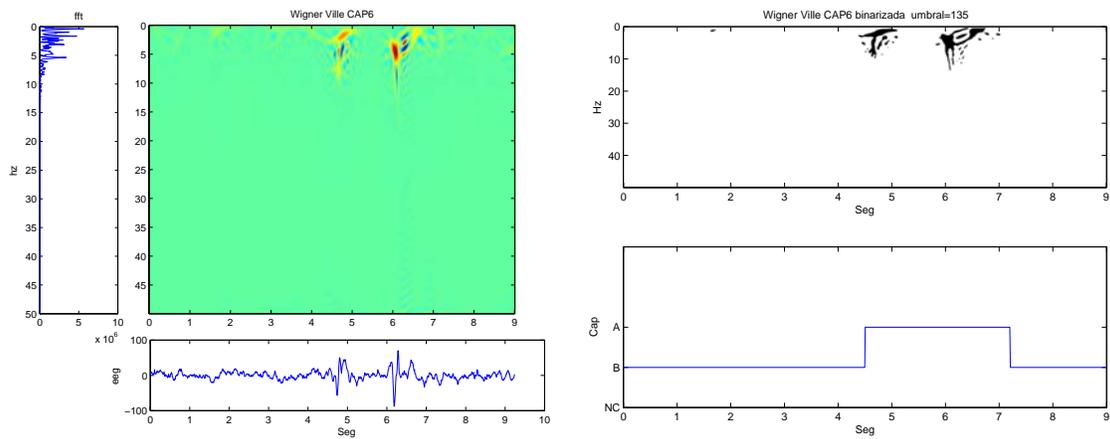


Figura 5.44: Izquierda: Distribución Wigner - Ville secuencia 6 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=135

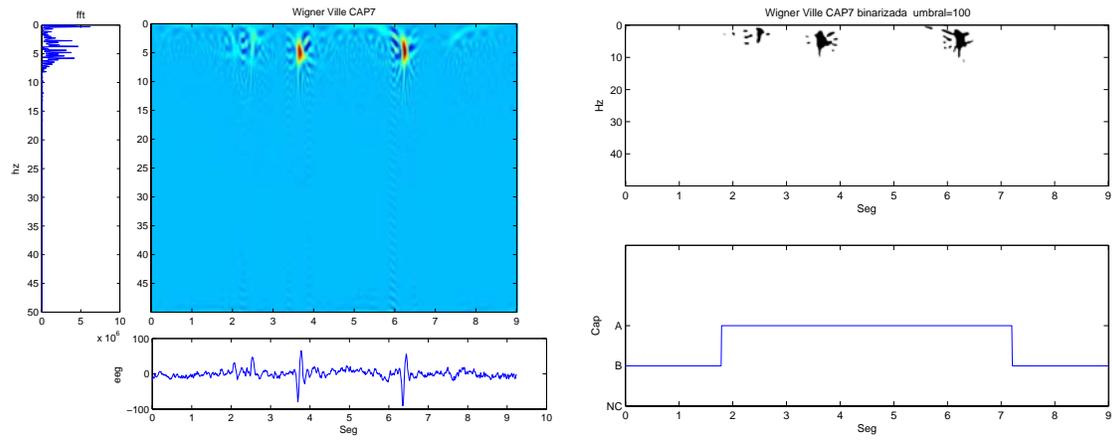


Figura 5.45: Izquierda: Distribución Wigner - Ville secuencia 7 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=100

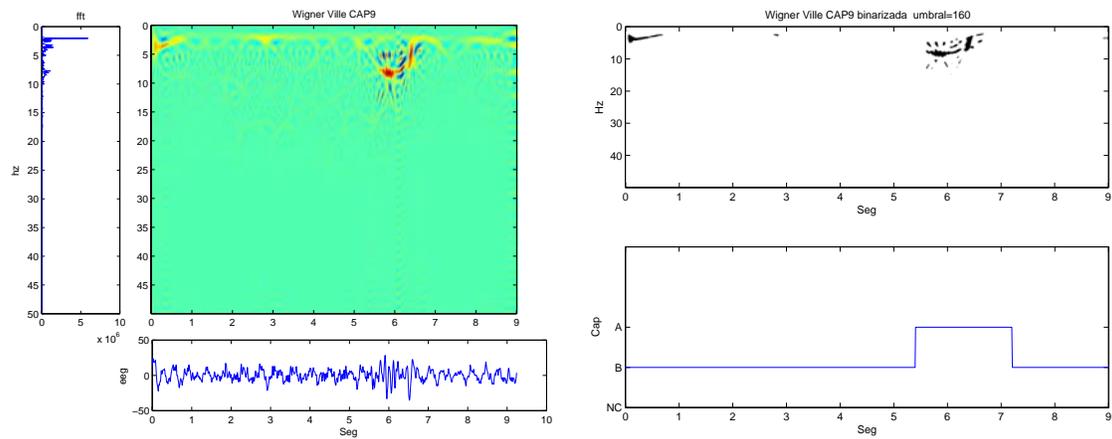


Figura 5.46: Izquierda: Distribución Wigner - Ville secuencia 9 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=160

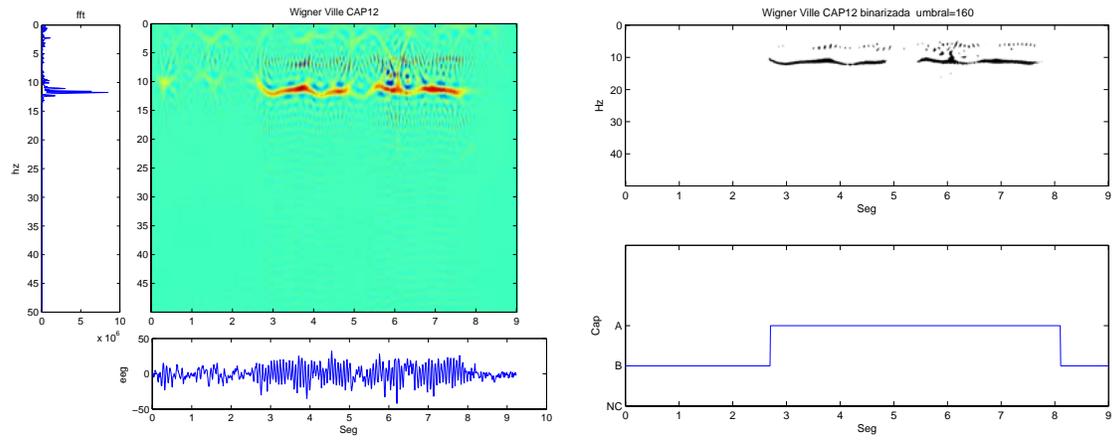


Figura 5.47: Izquierda: Distribución Wigner - Ville secuencia 12 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=160

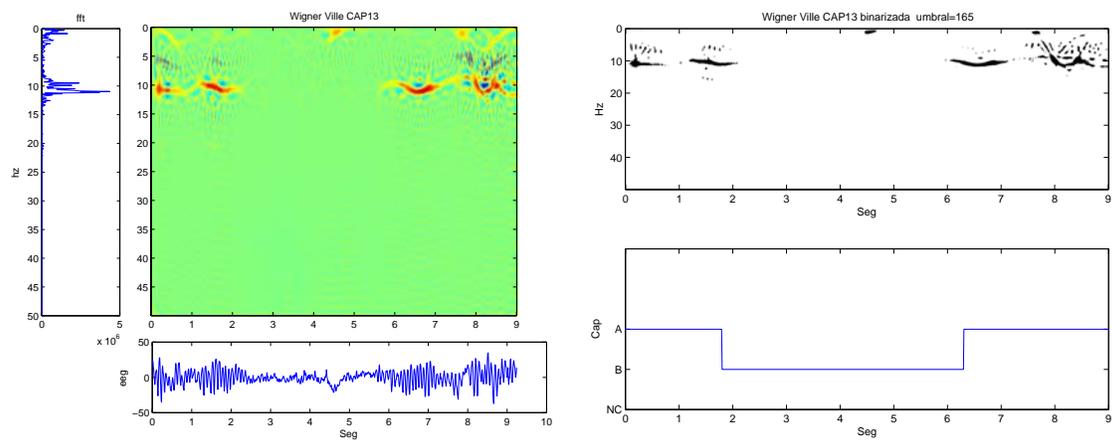


Figura 5.48: Izquierda: Distribución Wigner - Ville secuencia 13 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=165

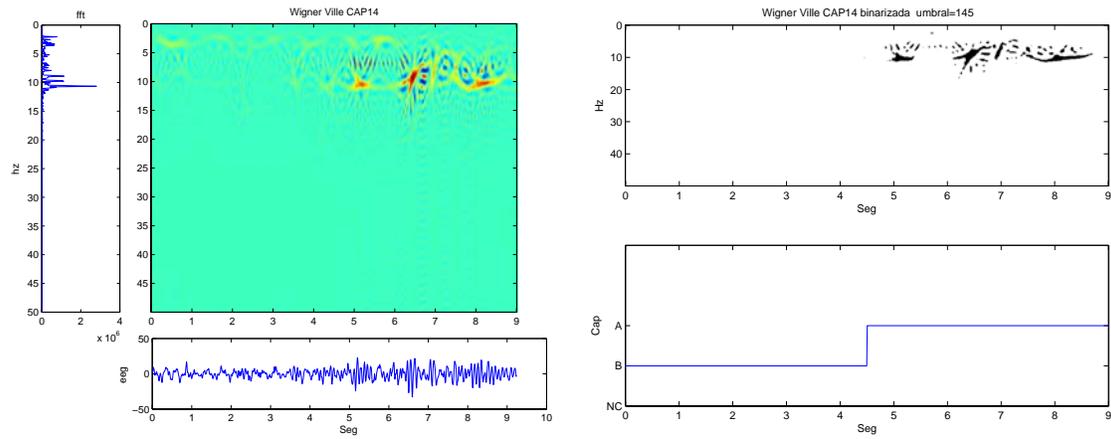


Figura 5.49: Izquierda: Distribución Wigner - Ville secuencia 14 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=145

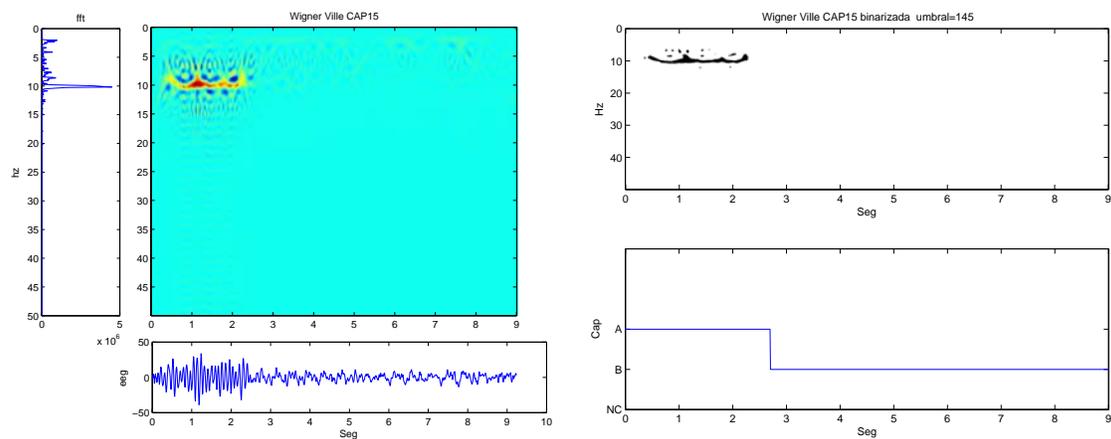


Figura 5.50: Izquierda: Distribución Wigner - Ville secuencia 15 NPF=1024; N=32; NPT=1024. Derecha: Identificación CAP umbral=145

Indice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	85.1	84.9	84.9	85
%Concordancia visual vs algoritmo	92.6	92.5	92.5	92.5

Cuadro 5.8: Identificación de secuencias CAP mediante distribución Wigner - Ville

5.9. Identificación de secuencias CAP mediante Distribución Choi William

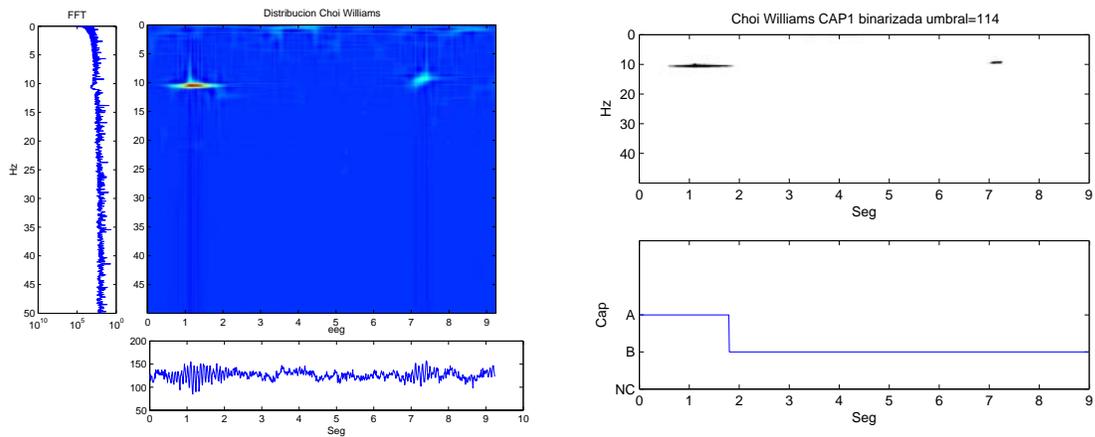


Figura 5.51: Izquierda:Distribución Choi - Williams secuencia 1 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=114

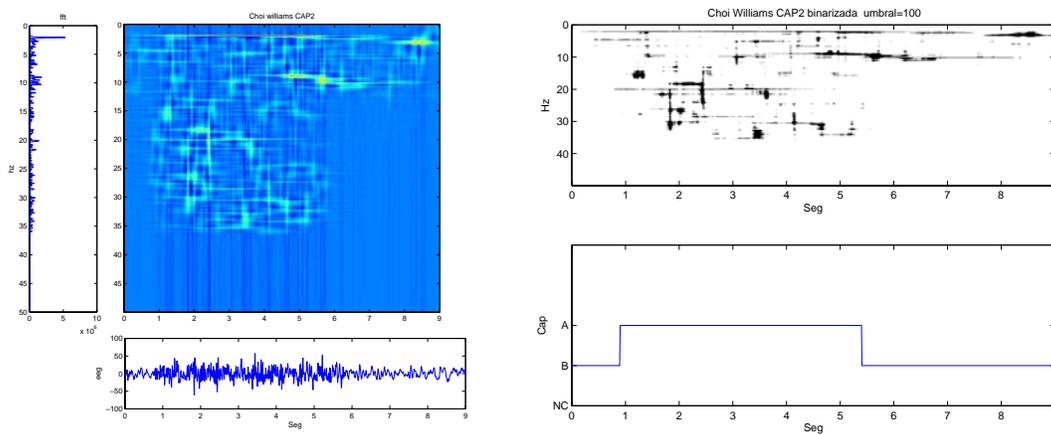


Figura 5.52: Izquierda:Distribución Choi - Williams secuencia 2 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=100

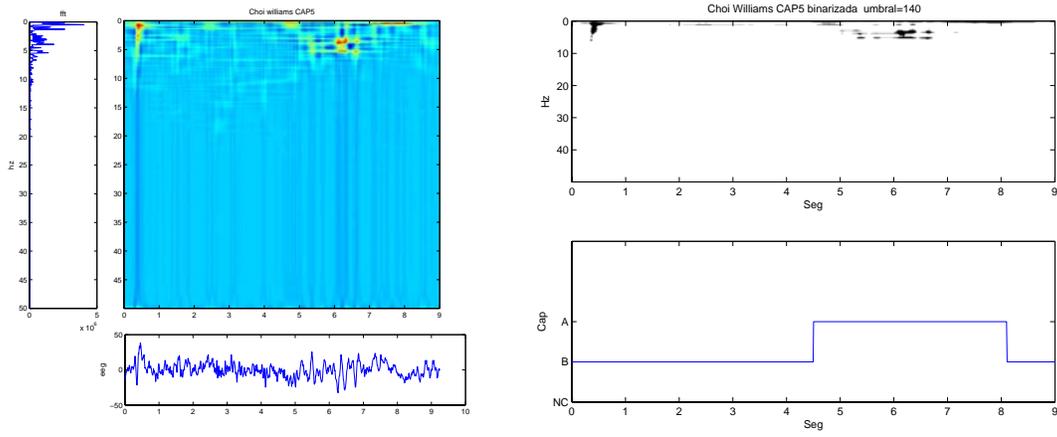


Figura 5.53: Izquierda: Distribución Choi - Williams secuencia 5 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=140

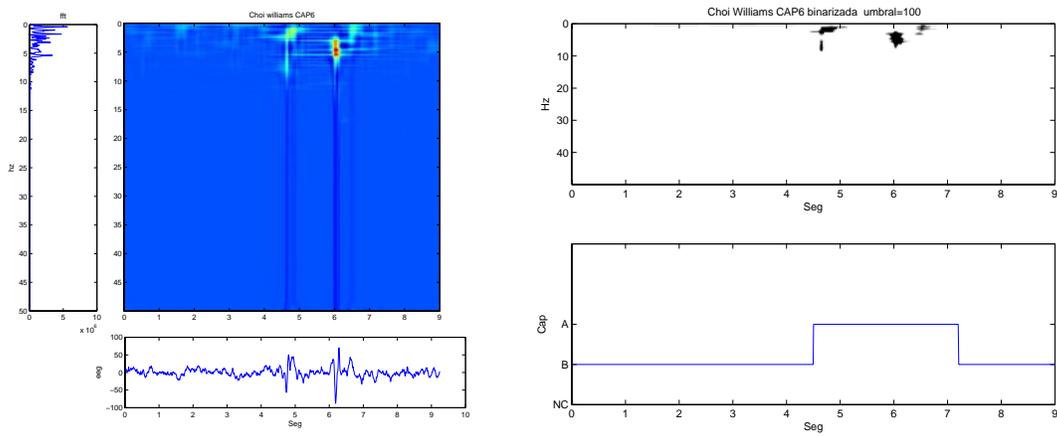


Figura 5.54: Izquierda: Distribución Choi - Williams secuencia 6 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=100

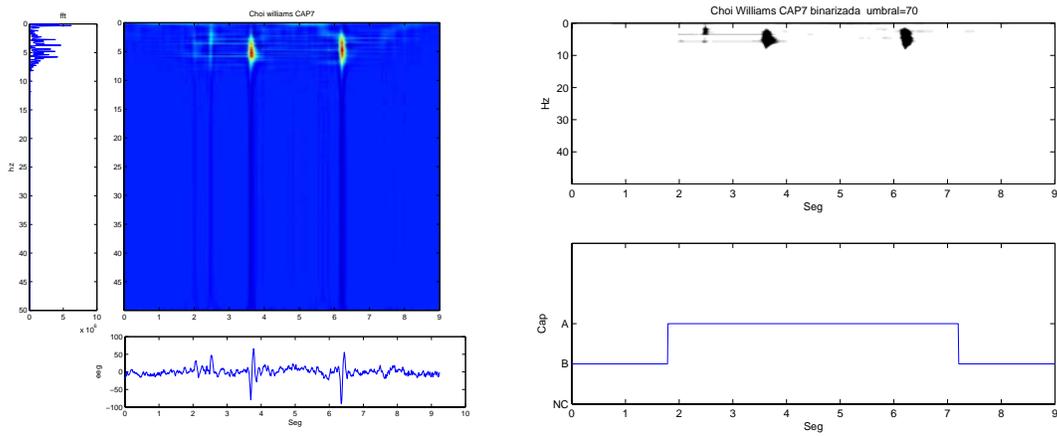


Figura 5.55: Izquierda:Distribución Choi - Williams secuencia 7 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=70

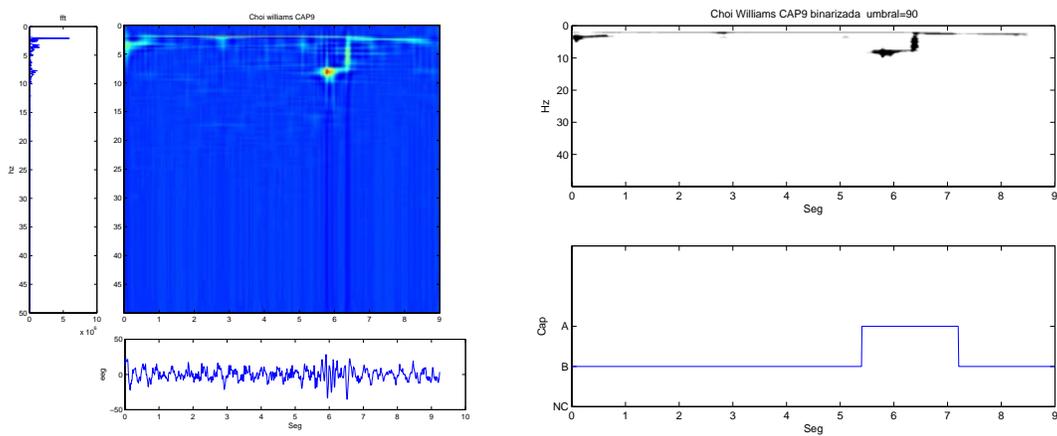


Figura 5.56: Izquierda:Distribución Choi - Williams secuencia 9 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=90

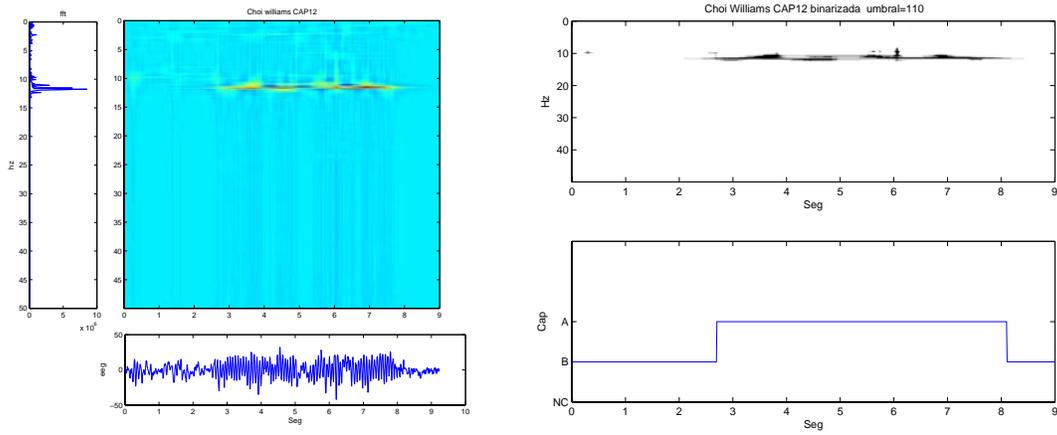


Figura 5.57: Izquierda:Distribución Choi - Williams secuencia 12 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=110

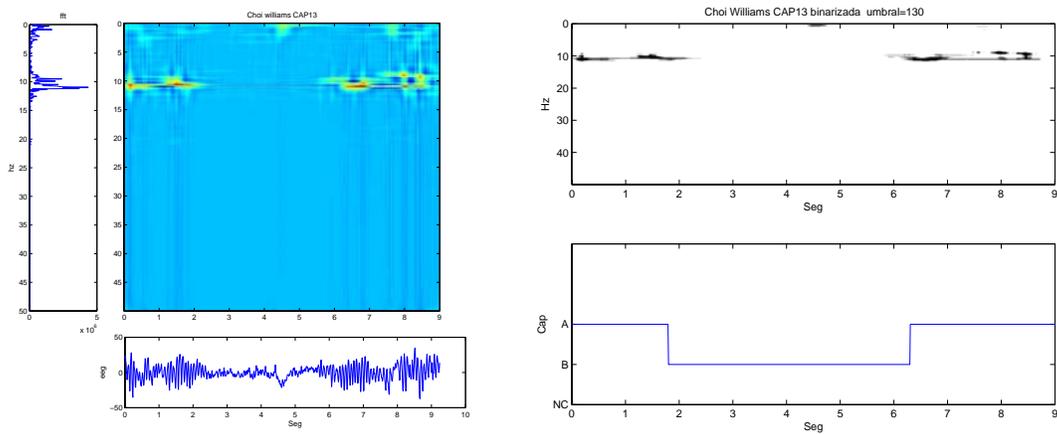


Figura 5.58: Izquierda:Distribución Choi - Williams secuencia 13 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=130

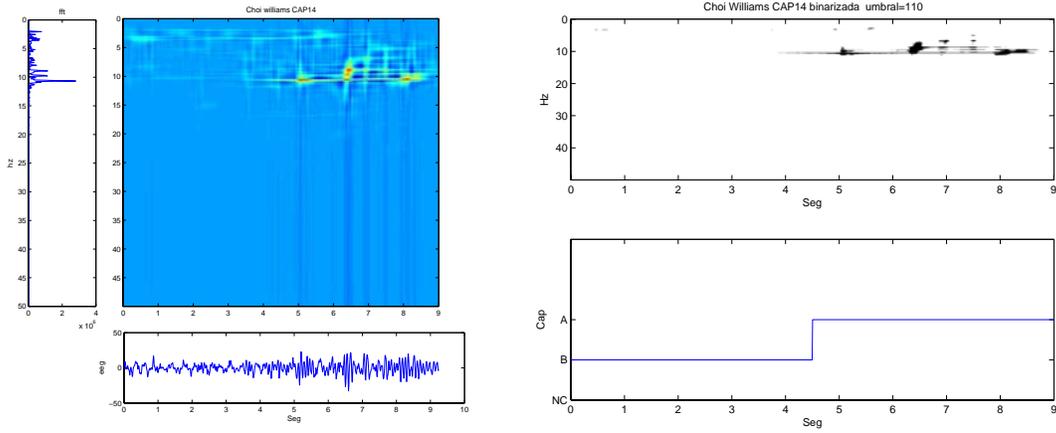


Figura 5.59: Izquierda: Distribución Choi - Williams secuencia 14 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=110

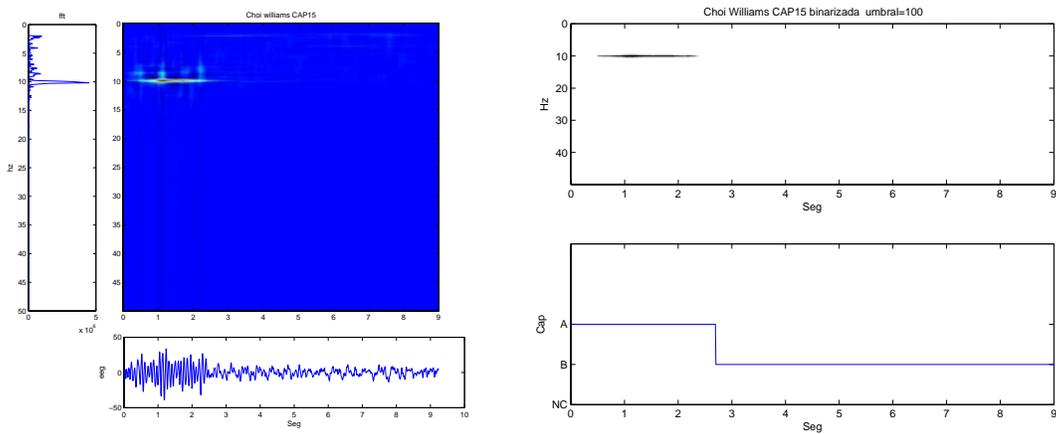


Figura 5.60: Izquierda: Distribución Choi - Williams secuencia 15 $M=1024$; $N=1024$; $NPF=1024$; $\sigma=40$. Derecha: Identificación CAP umbral=100

Índice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	84.8	83.9	85.0	84.6
%Concordancia visual vs algoritmo	92.4	92.0	92.5	92.3

Cuadro 5.9: Identificación de secuencias CAP mediante distribución Choi Williams

5.10. Identificación de secuencias CAP mediante Distribución Bessel

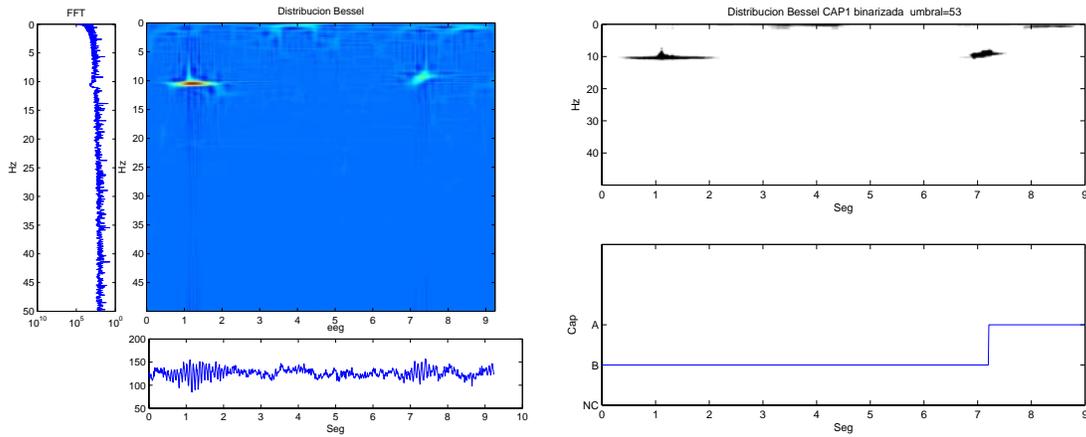


Figura 5.61: Izquierda:Distribución Bessel secuencia 1 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=53

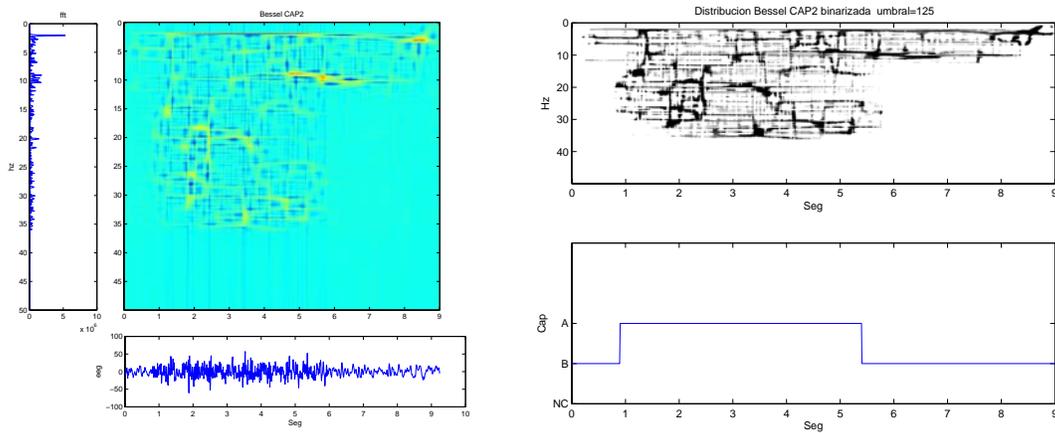


Figura 5.62: Izquierda:Distribución Bessel secuencia 2 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=125

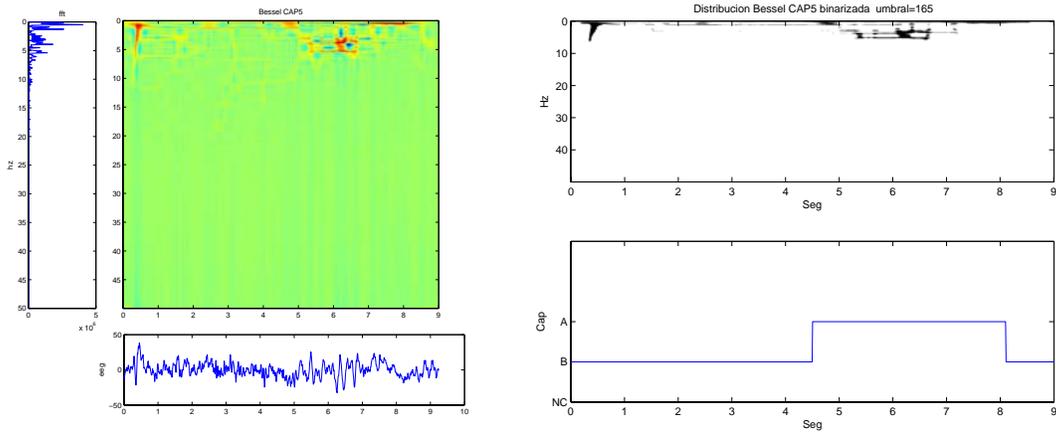


Figura 5.63: Izquierda:Distribución Bessel secuencia 5 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=165

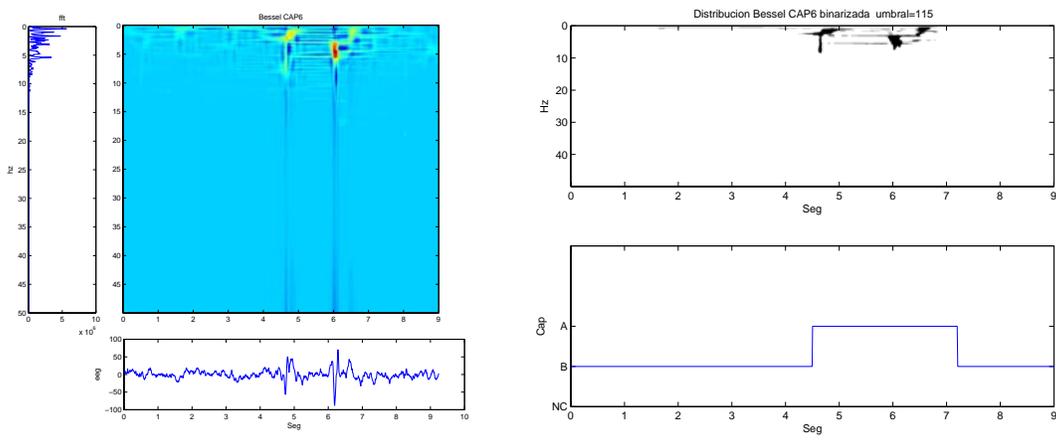


Figura 5.64: Izquierda:Distribución Bessel secuencia 6 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=115

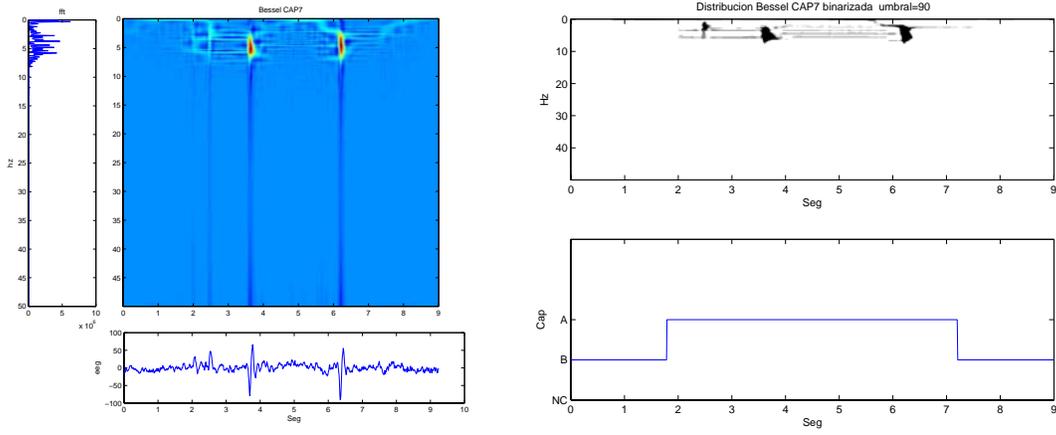


Figura 5.65: Izquierda:Distribución Bessel secuencia 7 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=90

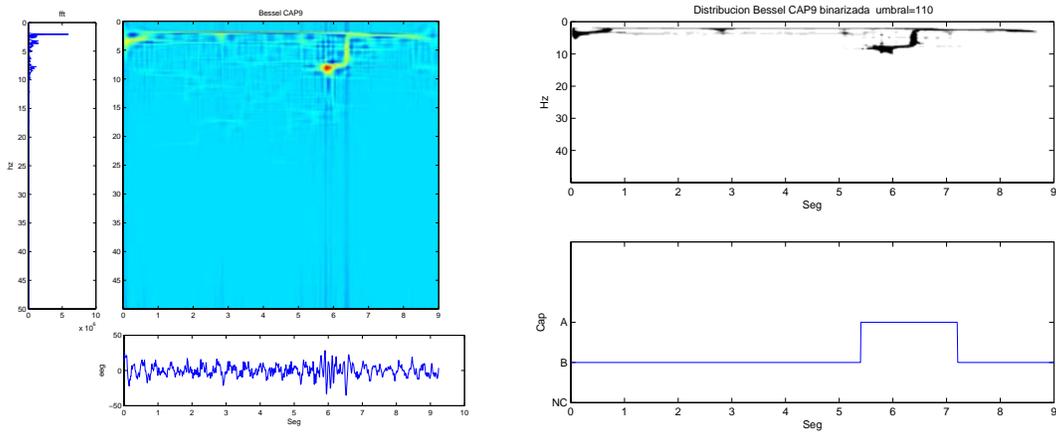


Figura 5.66: Izquierda:Distribución Bessel secuencia 9 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=110

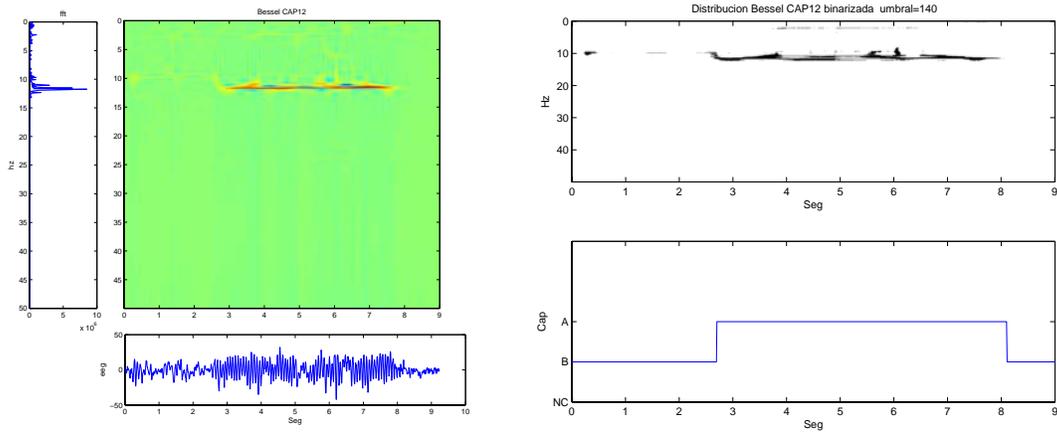


Figura 5.67: Izquierda: Distribución Bessel secuencia 12 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=140

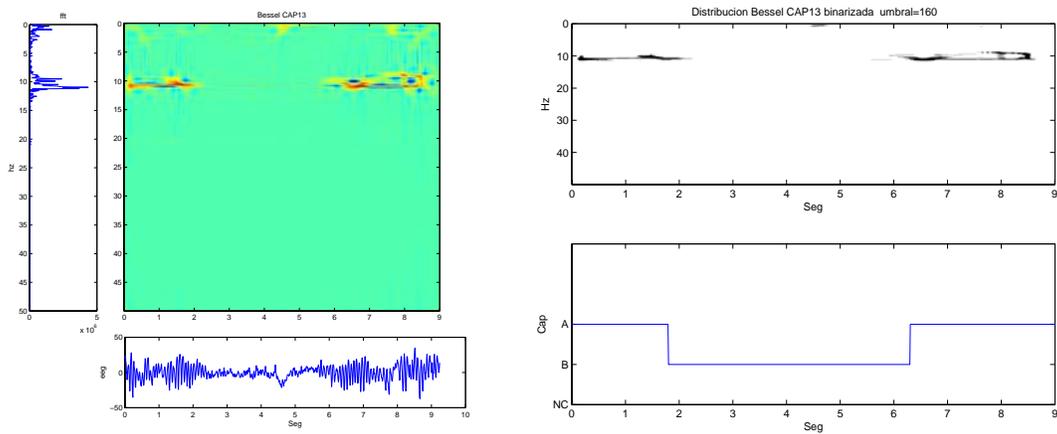


Figura 5.68: Izquierda: Distribución Bessel secuencia 13 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=160

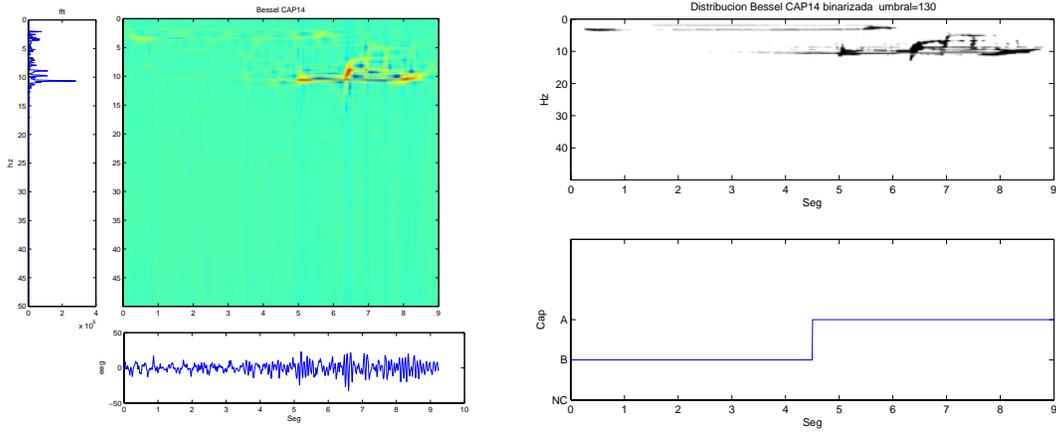


Figura 5.69: Izquierda: Distribución Bessel secuencia 14 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=130

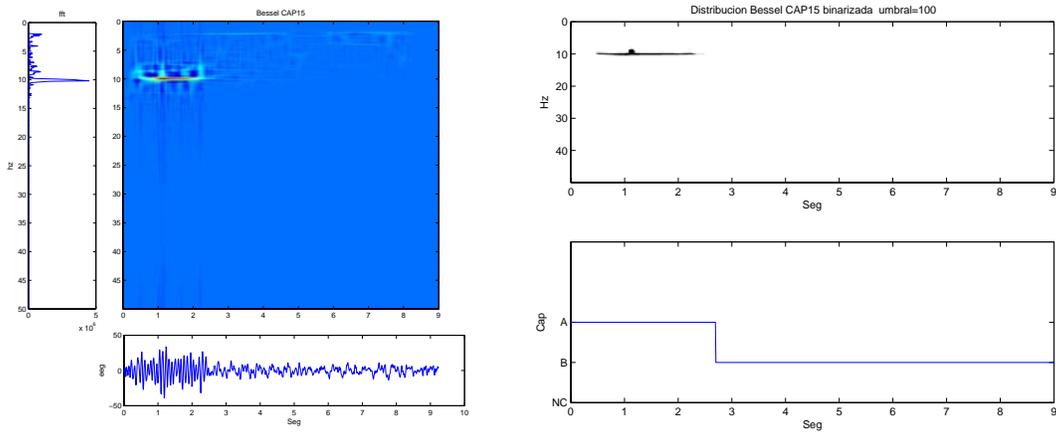


Figura 5.70: Izquierda: Distribución Bessel secuencia 15 $M=1024$; $N=1024$; $NPF=1024$; $NPT=1024$; $\alpha=0.5$. Derecha: Identificación CAP umbral=100

Índice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identific. Sec. Correctas	85.9	85.2	85.1	85.4
%Concordancia visual vs algoritmo	92.9	92.6	92.6	92.7

Cuadro 5.10: Identificación de secuencias CAP mediante distribución Bessel

5.11. Identificación de secuencias CAP mediante Transformada Haar

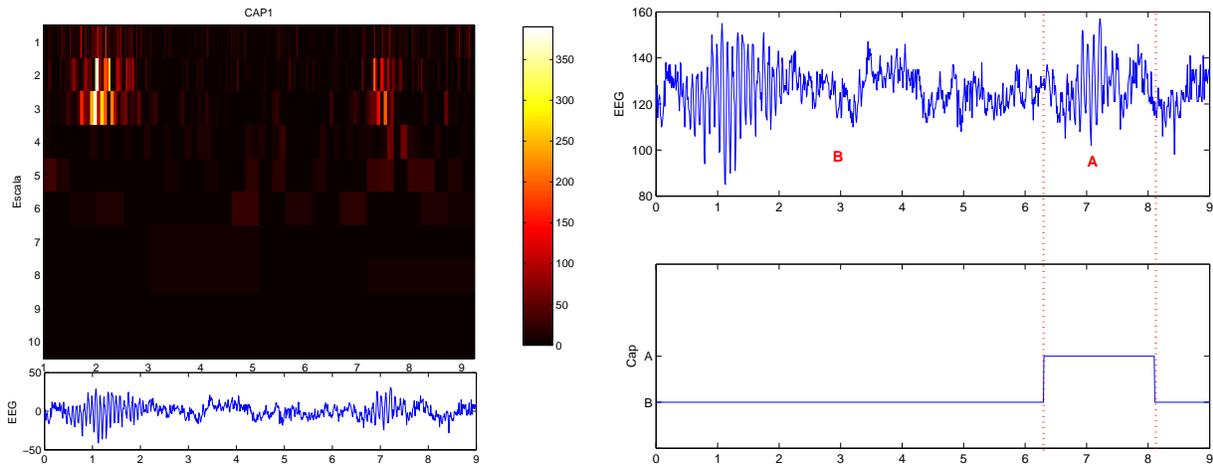


Figura 5.71: Izquierda: Escalograma Haar secuencia 1 , Derecha: Identificación CAP

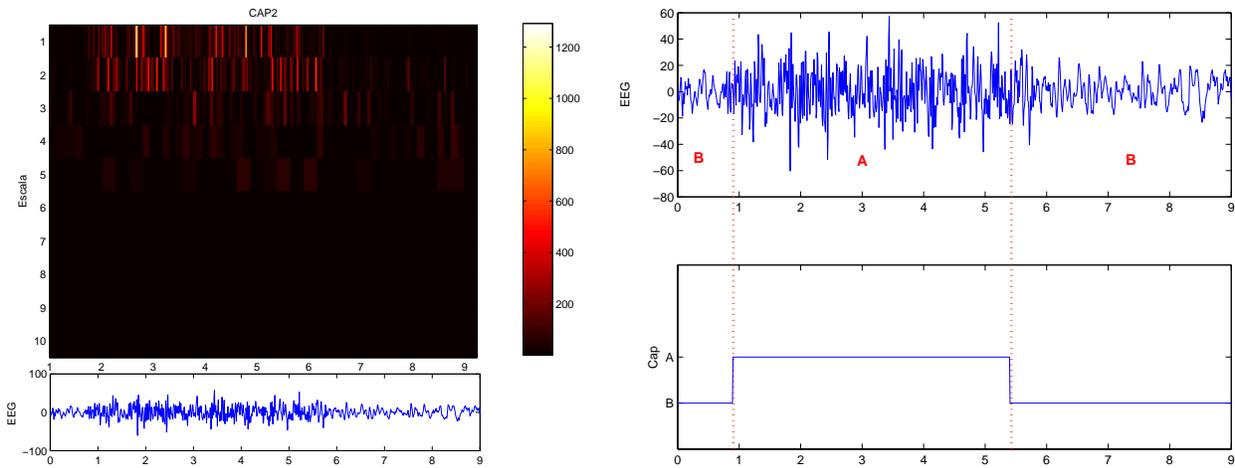


Figura 5.72: Izquierda: Escalograma Haar secuencia 2 , Derecha: Identificación CAP

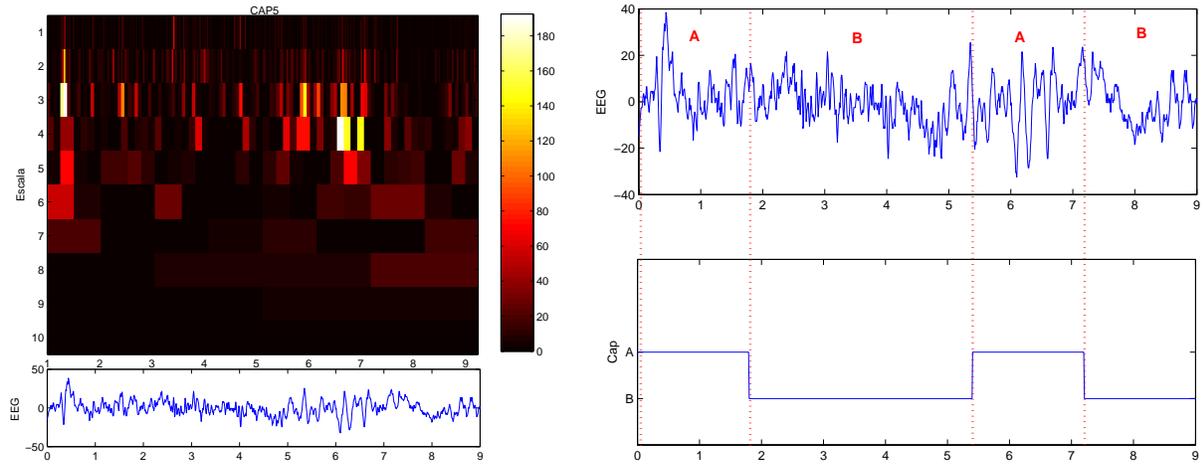


Figura 5.73: Izquierda: Escalograma Haar secuencia 5 , Derecha: Identificación CAP

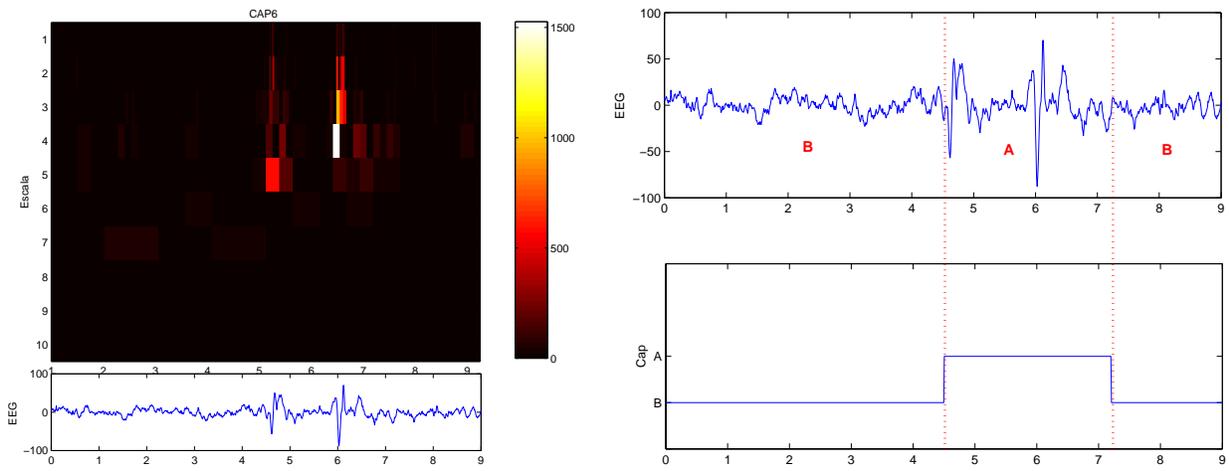


Figura 5.74: Izquierda: Escalograma Haar secuencia 6 , Derecha: Identificación CAP

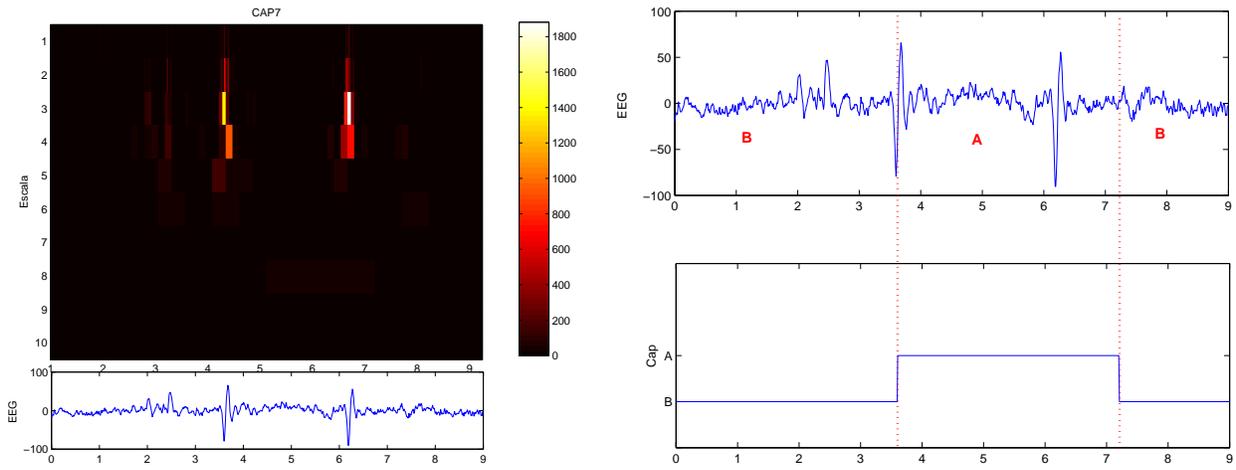


Figura 5.75: Izquierda: Escalograma Haar secuencia 7 , Derecha: Identificación CAP

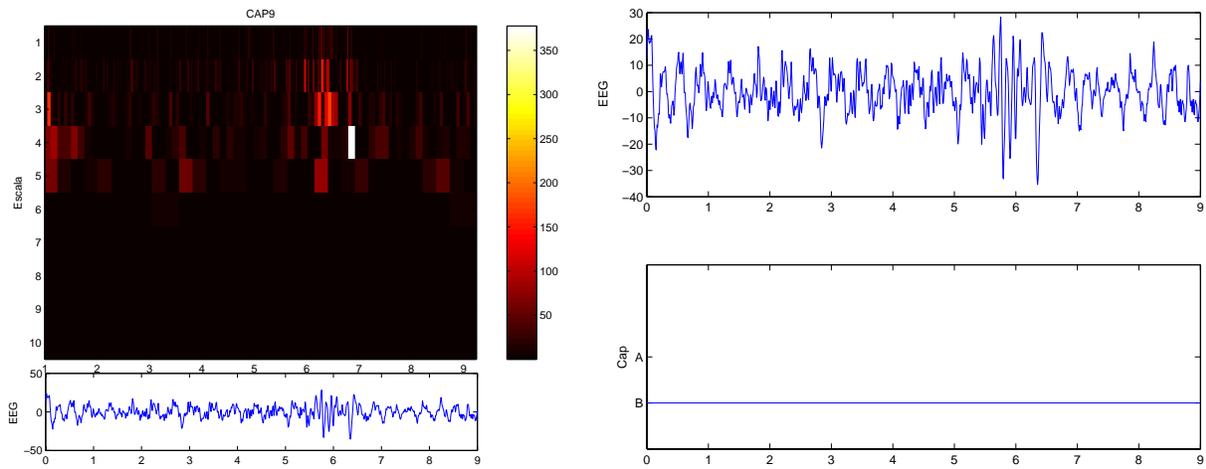


Figura 5.76: Izquierda: Escalograma Haar secuencia 9 , Derecha: Identificación CAP

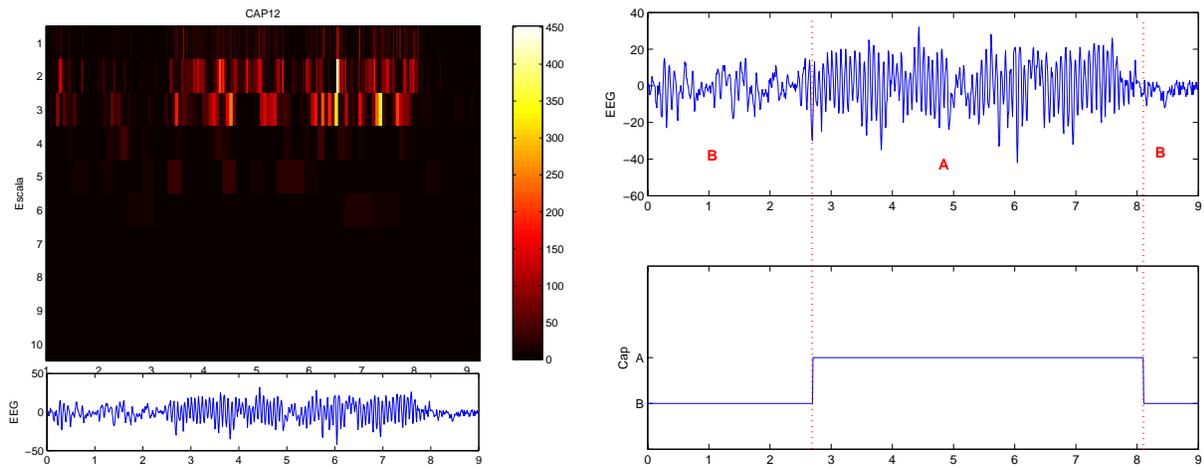


Figura 5.77: Izquierda: Escalograma Haar secuencia 12 , Derecha: Identificación CAP

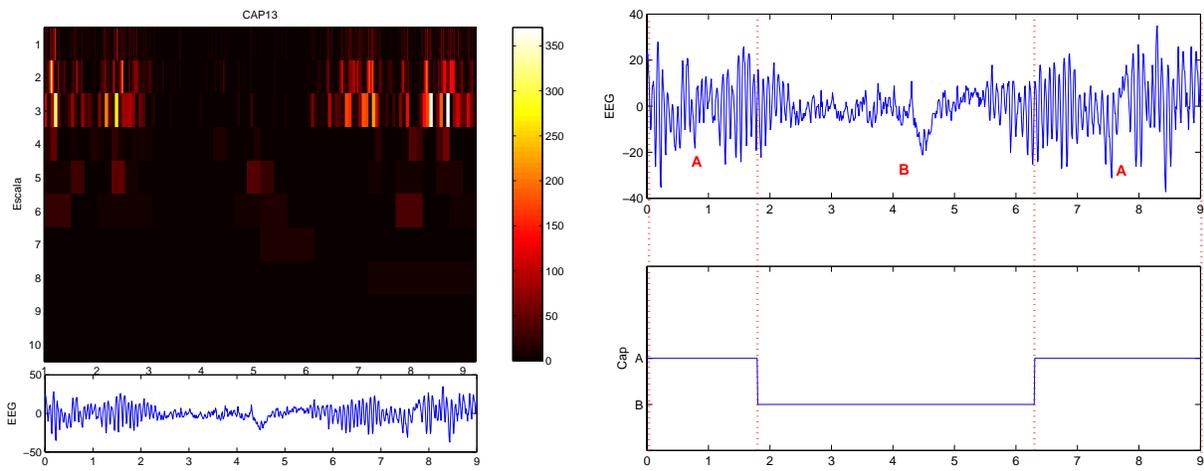


Figura 5.78: Izquierda: Escalograma Haar secuencia 13 , Derecha: Identificación CAP

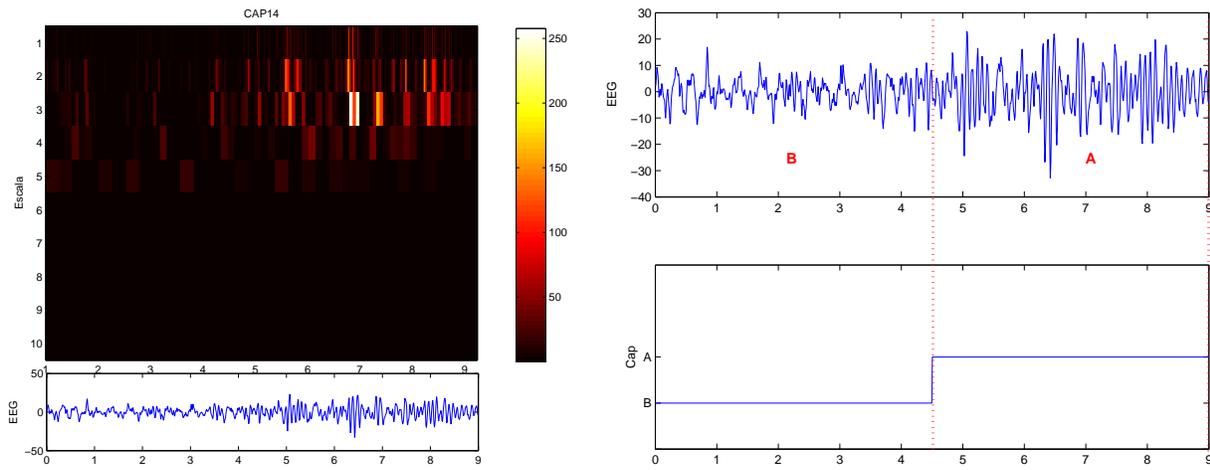


Figura 5.79: Izquierda: Escalograma Haar secuencia 14 , Derecha: Identificación CAP

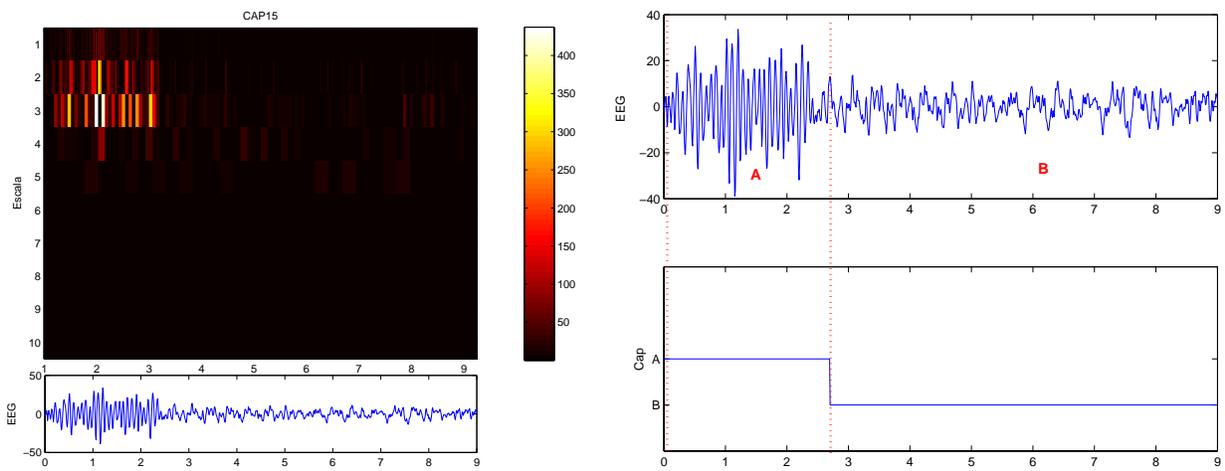


Figura 5.80: Izquierda: Escalograma Haar secuencia 15 , Derecha: Identificación CAP

Indice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identif. Sec. Correctas	84.1	84.4	85.1	84.5
%Concordancia visual vs algoritmo	92.1	92.2	92.6	92.3

Cuadro 5.11: Identificación de secuencias CAP mediante transformada Haar

5.12. Identificación de secuencias CAP mediante transformada Daubechies 4

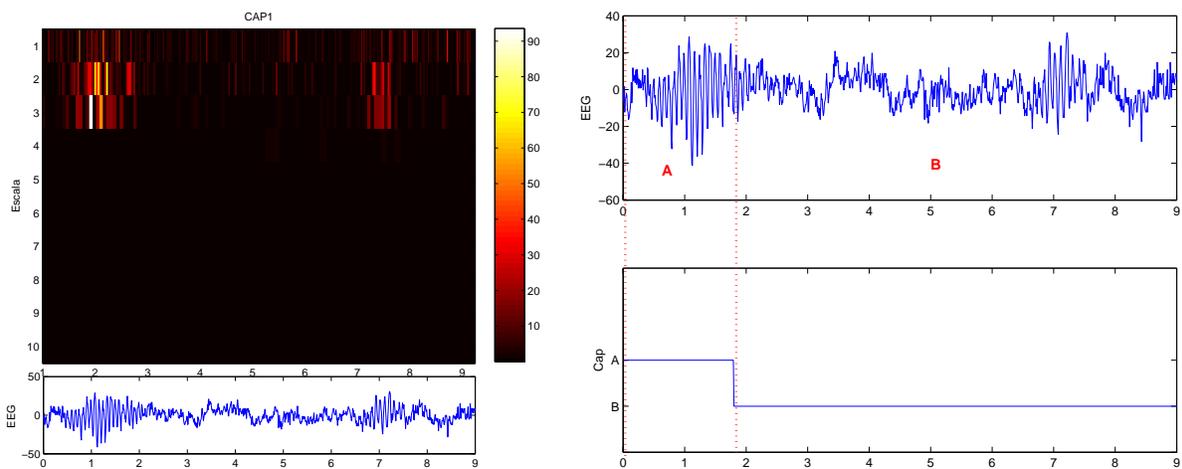


Figura 5.81: Izquierda: Escalograma Daubechies 4 secuencia 1 , Derecha: Identificación CAP

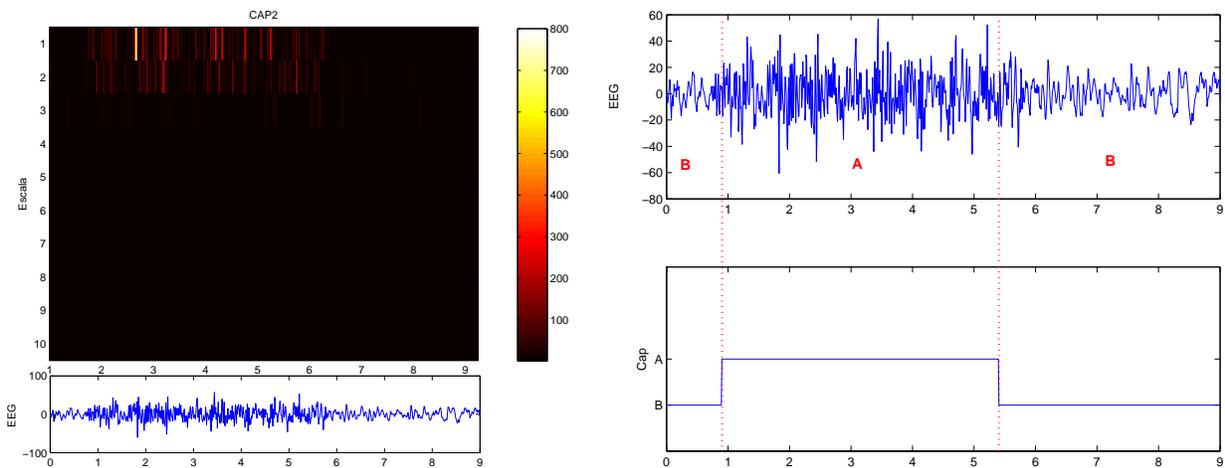


Figura 5.82: Izquierda: Escalograma Daubechies 4 secuencia 2 , Derecha: Identificación CAP

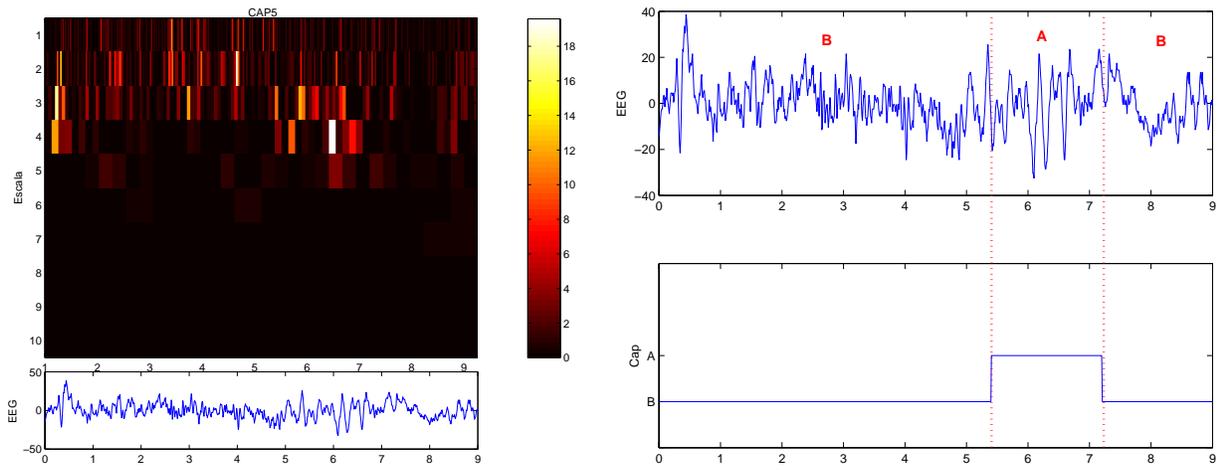


Figura 5.83: Izquierda: Escalograma Daubechies 4 secuencia 5 , Derecha: Identificación CAP

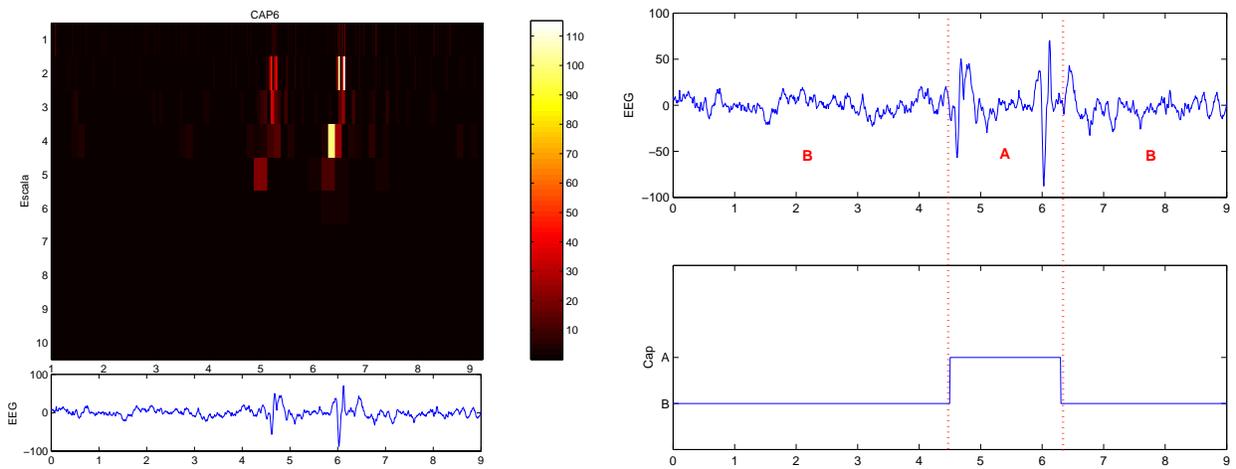


Figura 5.84: Izquierda: Escalograma Daubechies 4 secuencia 6 , Derecha: Identificación CAP

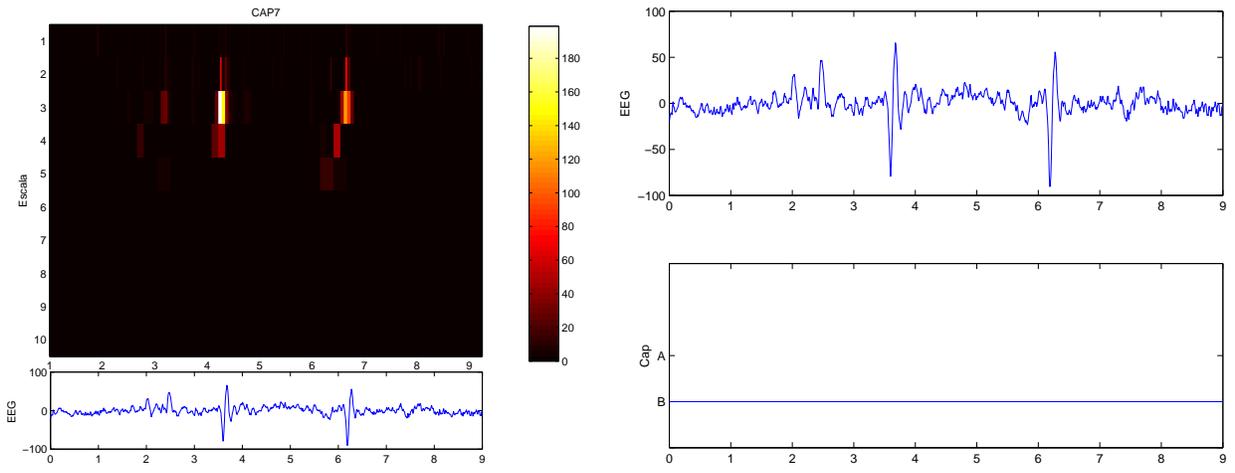


Figura 5.85: Izquierda: Escalograma Daubechies 4 secuencia 7 , Derecha: Identificación CAP

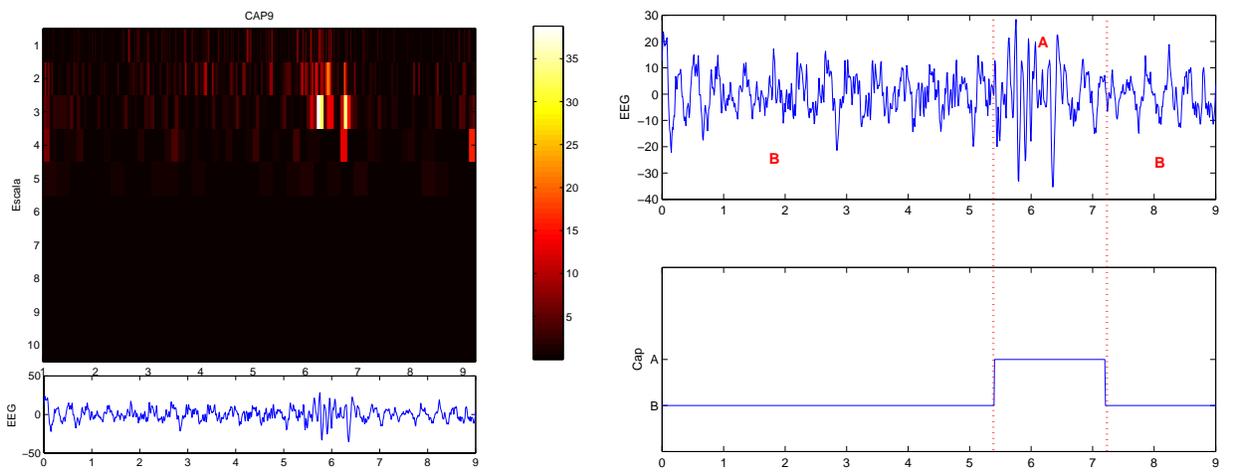


Figura 5.86: Izquierda: Escalograma Daubechies 4 secuencia 9 , Derecha: Identificación CAP

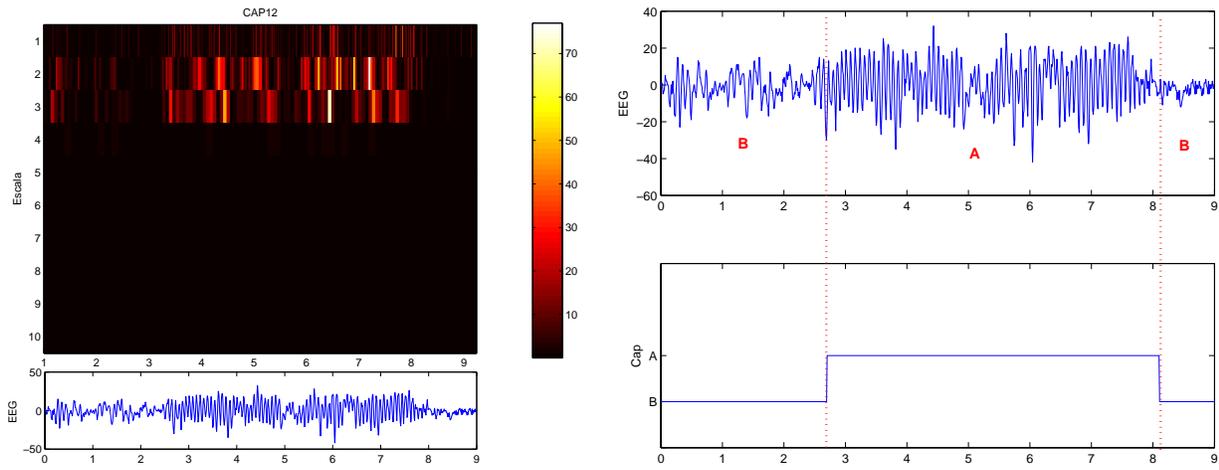


Figura 5.87: Izquierda: Escalograma Daubechies 4 secuencia 12 , Derecha: Identificación CAP

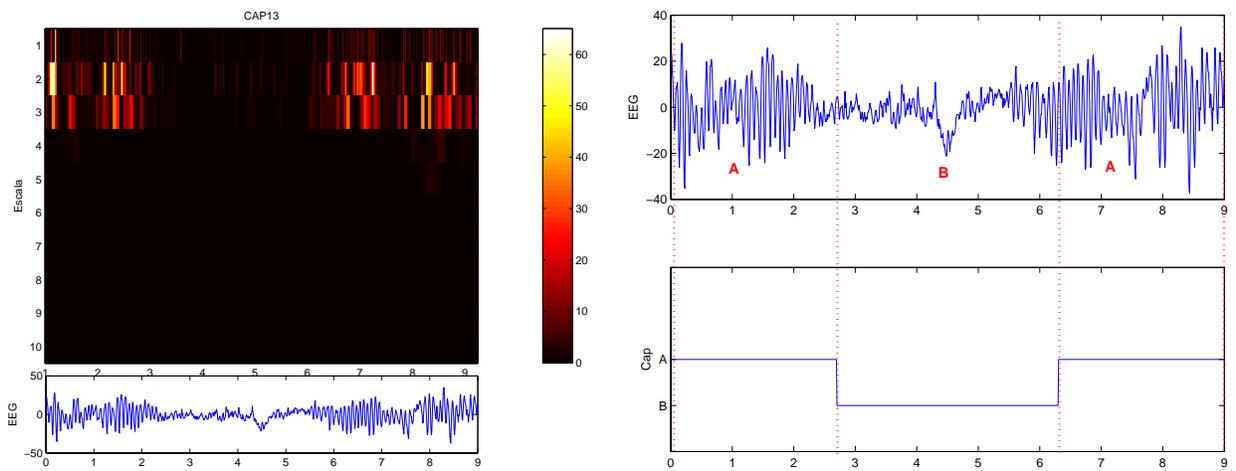


Figura 5.88: Izquierda: Escalograma Daubechies 4 secuencia 13 , Derecha: Identificación CAP

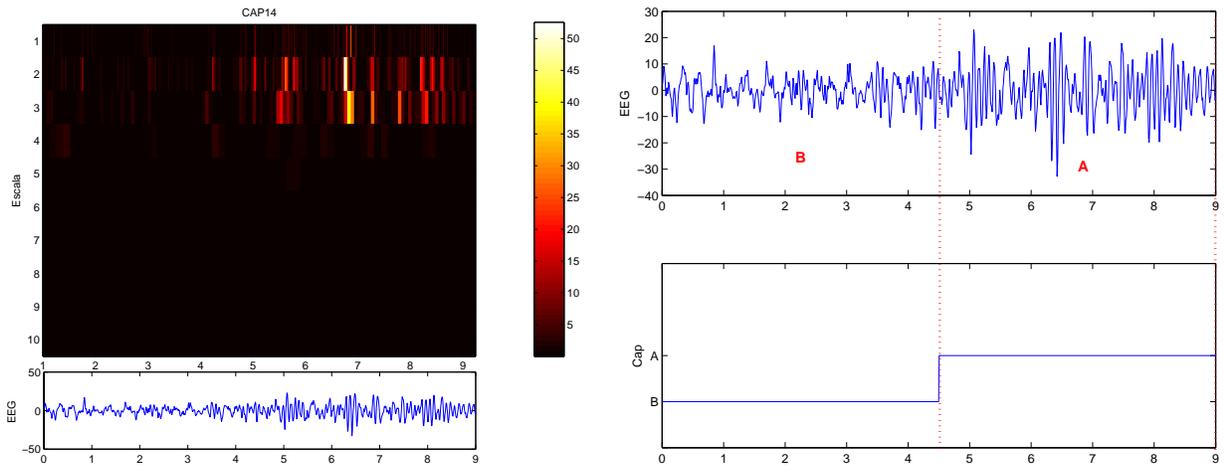


Figura 5.89: Izquierda: Escalograma Daubechies 4 secuencia 14 , Derecha: Identificación CAP

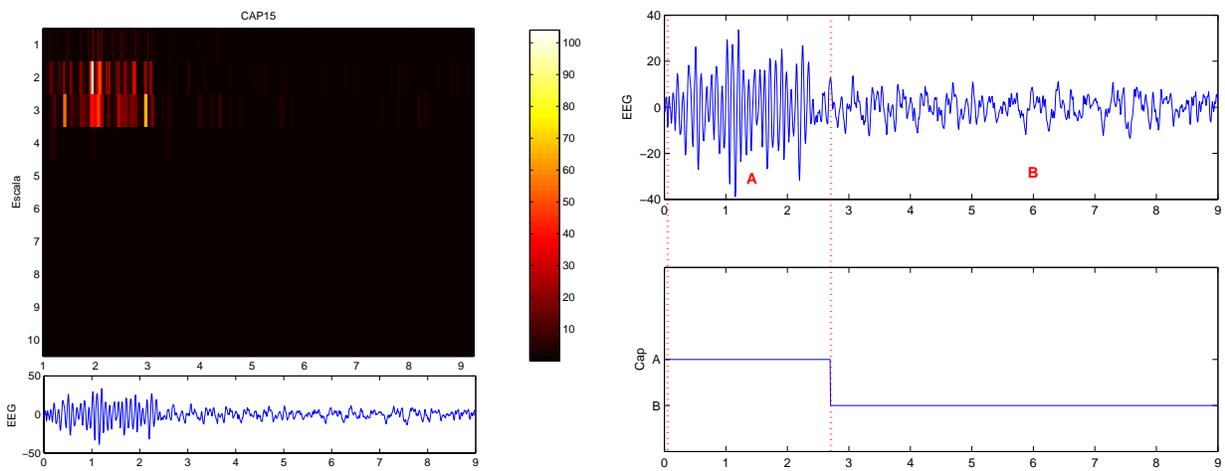


Figura 5.90: Izquierda: Escalograma Daubechies 4 secuencia 15 , Derecha: Identificación CAP

Indice	1a Clasific.	2a Clasific.	3a Clasific.	Promedio
% Identifc. Sec. Correctas	83.5	84.9	84.3	84.2
%Concordancia visual vs algoritmo	91.8	92.5	92.2	92.2

Cuadro 5.12: Identificación de secuencias CAP mediante Transformada Daubechies 4

5.13. Resumen de Resultados

Algoritmo	%Correcto	%Concordancia
Est. Temporales	85.1	92.5
Potencia EEG	84.5	92.2
Coef. Correlación	83.9	91.9
Dist. Geométrica	82.4	91.2
Dist. Espectral	83.7	91.8
RLS	84.3	90.2
Espectrograma	88	93.9
Wigner - Ville	85.1	92.6
Choi - Williams	84.8	92.4
Bessel	85.9	92.9
Haar	84.1	92.1
Daubechies	83.5	91.8

Cuadro 5.13: Resumen de Resultados de la primera clasificación

Algoritmo	%Correcto	%Concordancia
Est. Temporales	84.7	92.3
Potencia EEG	84.4	92.2
Coef. Correlación	83.0	91.5
Dist. Geométrica	81.9	91
Dist. Espectral	82.7	91.4
RLS	84.1	91
Espectrograma	87.7	93.8
Wigner - Ville	84.9	92.5
Choi - Williams	83.9	92
Bessel	85.2	92.6
Haar	84.4	92.2
Daubechies	84.9	92.5

Cuadro 5.14: Resumen de Resultados de la segunda clasificación

Algoritmo	%Correcto	%Concordancia
Est. Temporales	84.1	92.1
Potencia EEG	85	92.5
Coef. Correlación	83.7	91.9
Dist. Geométrica	82.4	91.2
Dist. Espectral	83	91.5
RLS	83.8	90.9
Espectrograma	88.2	94.1
Wigner - Ville	84.9	92.5
Choi - Williams	85	92.5
Bessel	85.1	92.6
Haar	85.1	92.6
Daubechies	84.3	92.2

Cuadro 5.15: Resumen de Resultados de la tercera clasificación

Algoritmo	%Correcto	%Concordancia	Tiempo Calc.
Est. Temporales	84.4	92.2	0.38
Potencia EEG	84.5	92.3	0.53
Coef. Correlación	83.5	91.8	0.51
Dist. Espectral	82.2	91.1	0.50
Dist. Geométrica	83.1	91.6	0.43
RLS	81.4	90.7	0.24
Espectrograma	88	94	0.56
Wigner - Ville	85	92.5	7.24
Choi - Williams	84.6	92.3	277.45
Bessel	85.4	92.7	76.28
Haar	84.5	92.3	1.04
Daubechies	84.2	92.2	1.34

Cuadro 5.16: Resumen de resultados promedio de la 3 clasificaciones y tiempo promedio de cada algoritmo en segundos por secuencia

Conclusiones y Perspectivas

Las características discriminantes de las secuencias CAP varían tanto en tiempo como en frecuencia, pensando en ello, se implementaron en JAVA y Matlab© 12 algoritmos del procesamiento digital de señales los cuales pueden ser separados como algoritmos de análisis en el dominio del tiempo, algoritmos de análisis en el dominio de la frecuencia y algoritmos tiempo frecuencia. En total se trabajó con 101 secuencias CAP obtenidas mediante una primera inspección visual hecha a un registro de 8 horas de sueño perteneciente a un sujeto sano. A cada una de las 101 secuencias se aplicaron los 12 métodos. Adicionalmente se realizaron 2 calificaciones de las mismas secuencias seleccionadas ayudadas por el sistema automático de calificación de sueño ALICE 4 y se se compararon los resultados de cada algoritmo y cada clasificación de acuerdo a dos criterios establecidos por Lima y Rosa en [29]: La identificación correcta de las secuencias CAP y la concordancia entre la identificación automática y la identificación visual. Así mismo, de manera complementaria, se analizó el tiempo de cálculo de cada algoritmo en una computador con procesador Xeon© de 3 GHz y 1 GB de memoria.

La idea general propuesta para la identificación de secuencias CAP se basa en que la señal de EEG conserva parámetros característicos para cada estado, si la señal cambia de estado, este cambio se refleja en estos parámetros. Los parámetros que utilizamos en este trabajo fueron: Potencia, coeficientes de correlación, parámetros AR, parámetros RLS, espectros y distribuciones tiempo - frecuencia.

En cuanto a los algoritmos de análisis en el tiempo, prácticamente encontramos el mismo desempeño. Con el procedimiento de análisis de potencia de la señal EEG identificamos correctamente el 84.5 % de las secuencias CAP, con un porcentaje de concordancia del 94.3 % en 0.53 segundos por secuencia; usando estadísticas temporales identificamos el 84.4 %, con 92.2 % de concordancia en 0.38 segundos por secuencia. En este sentido podemos decir que es mejor utilizar el método de potencia, ya que la concordancia entre las clasificaciones visual y automática es mayor que aquella obtenida con el método de estadísticas temporales, además de que el tiempo de procesamiento se reduce en un 28.3 %. Esto es válido porque a menudo las secuencias CAP aumentan en potencia respecto a la potencia de fondo del EEG, sin embargo hay que considerar que los artefactos en la señal EEG pueden conducir a datos falsos, por lo que es importante un buen prefiltrado para el empleo del método de análisis de potencia. Ambos algoritmos superaron en porcentaje de detección al método de los coeficientes de correlación y distancia de Chebyshev, el cual obtuvo un 83.5 % de identificaciones

correctas y un 91.8 % de concordancia en 0.51 segundos por secuencia. En vista de lo anterior proponemos al método de potencia como el mejor método de análisis en el tiempo estudiado en este trabajo.

En cuanto a los métodos paramétricos de modelado, consideramos un modelo todo polo basado en el modelado autorregresivo, y un modelo todo cero basado en el modelo obtenido mediante los mínimos cuadrados recursivos. Con el primero hicimos una comparación de coeficientes mediante dos distancias: distancia geométrica y distancia espectral. La comparación mediante distancia geométrica reportó un 82.2 % de secuencias identificadas correctamente con un 91.1 % de concordancia en 0.43 segundos por secuencia; por otro lado, la comparación realizada con la distancia espectral identificó el 83.1 % de las secuencias CAP acompañado de un 91.6 % de concordancia en 0.50 segundos por secuencia. Cabe señalar que el orden escogido para el modelo AR fue obtenido mediante dos criterios: AIC y MDL. En la implementación del algoritmo RLS encontramos una mejora respecto al modelado AR, ya que se obtuvo un 83.9 % de secuencias CAP identificadas correctamente; sin embargo, obtuvimos una menor concordancia, ya que esta fue del 90.7 %, casi un 1 % menor de concordancia. El algoritmo RLS necesito un tiempo de cálculo de 0.24 segundos por secuencia, lo que representa una reducción del tiempo de cálculo de 48.4 % respecto a el modelado autorregresivo.

Las representaciones tiempo - frecuencia obtenidas fueron consideradas como imágenes en escala de 256 niveles de gris, las cuales posteriormente fueron binarizadas pensando en que la secuencia CAP es una secuencia de dos niveles y pudiera haber una relación entre un resultado binario asociado a una secuencia binaria. El resultado de esta binarización permitió destacar las zonas de la señal donde existía una mayor concentración de potencia, una reducción significativa en el tamaño de los datos originales y la identificación CAP de forma casi visual. No siendo este nuestro objetivo y aunque este resultado puede ser ya de gran ayuda, utilizamos las TFR binarizadas para hacer la identificación automática. El desempeño de la identificación CAP a través de TFRs depende de los umbrales de binarización, los cuales en este trabajo fueron obtenidos de manera heurística para cada una de las secuencias CAP y para cada algoritmo tiempo - frecuencia, de manera que la binarización destacara lo mejor posible a la secuencia CAP. Bajo este respecto consideramos la necesidad de continuar con una investigación más profunda sobre un método automático para la selección de un umbral óptimo, así como la adecuación de otros algoritmos de imagenología como detección de bordes, identificación de textura, thinning, etc. En base a los resultados obtenidos encontramos que en secuencias CAP de bajas frecuencias, el umbral es bajo, mientras que para secuencias CAP de alta frecuencia, los umbrales altos se ajustan mejor. El resultado de la evaluación de los algoritmos tiempo - frecuencia muestra que el mejor algoritmo fue el espectrograma con un 88 % de secuencias cap identificadas y 94 % de concordancia en 0.56 segundos por secuencia; en segundo lugar tenemos la distribución Bessel con 85.4 % de identificación correcta y 92.7 % de concordancia en 76.28 segundos por secuencia, seguido por la distribución Wigner - Ville con el 85 % de secuencias identificadas correctamente y 92.5 % de concordancia en 7.24 segundos por secuencia. y finalmente, el algoritmo con el peor desempeño de este trabajo en

el sentido de tiempo de cálculo fue la distribución Choi - Williams quien obtuvo el 84.6 % de secuencias identificadas con 92.3 % de concordancia en 277.45 segundos por secuencia. En este rubro, no se justifica la utilización de las TFRs por la cantidad de tiempo necesaria para su cálculo cuando vimos que la diferencia de desempeño en cuanto a concordancia y secuencias correctas varía en promedio un 0.68 % para la concordancia y un 1.99 % para las secuencias identificadas correctamente.

En cuanto a los métodos tiempo - escala, se implementaron la transformada Haar y la transformada Daubechies 4. La primera obtuvo un porcentaje de identificación correcta de 84.5 % con concordancia de 92.3 % en 1.04 segundos por secuencia; en tanto que con la transformada Daubechies 4 obtuvimos un 84.2 % y 92.2 % de concordancia, en 1.34 segundos por secuencia.

De forma global, observamos que no existen diferencias significativas entre los algoritmos, por lo que podemos decir que si se cuenta con equipos de computo con gran capacidad de memoria y velocidad de procesamiento podemos recurrir a los algoritmos más pesados como los algoritmos tiempo - frecuencia, aunque su uso pudiera ser enfocado más a la simulación o investigación en el laboratorio; sin embargo, métodos más simples pudieran ser utilizados en implementaciones en tiempo real, sin perder significativamente eficiencia en nuestra identificación. De manera particular, el mejor algoritmo en cuanto desempeño y tiempo de cálculo es el espectrograma, sin embargo sacrificando un poco el porcentaje de secuencias detectadas correctamente, podemos considerar al algoritmo basado en potencia como un buen candidato para la implementación en sistemas de procesamiento de recursos limitados, como podría ser un sistema portátil.

Bibliografía

- [1] *Time-frequency distributions for timbre morphing: The wigner distribution versus the stft*, Proceedings of the SBCMIV (4th Symposium of Brazilian Computer Music), 1997.
- [2] M. Akay, *Time frequency and wavelets in biomedical signal processing*, IEEE Press, 1998.
- [3] R. Alcántara, *Implantation d'algorithmes rapides sur des processeurs de traitement du signal*, Ph.D. thesis, Ecole Nationale Des Telecommunications, 1986.
- [4] R. Alcántara, *Apuntes de la materia de procesamiento digital de señales aleatorias.*, 2003.
- [5] G. Baura, *System theory and practical applications of biomedical signals*, IEEE Press, 2002.
- [6] H. Berger, *Über des elektrenkephalogramm des menschen*, Archiv. für Psychiatre und Nervenkrankheiten (1929), no. 87.
- [7] C. Guerrero and et al., *Time-frequency eeg analysis in epilepsy: What is more suitable?*, IEEE International Symposium on Signal Processing and Information Technology, 2005.
- [8] L. Cohen, *Time-frequency distributions-a review*, Proceedings of the IEEE **77** (1989).
- [9] L. Cohen, *Time - frequency analysis*, Prentice Hall, EUA, 1995.
- [10] M. Corlay, *Estudio comparativo e implementación de métodos tiempo frecuencia*, Tesis de Maestría, Facultad de Ingeniería, UNAM, 1996.
- [11] T. Pérez, *Relación entre la transformada de ondículas y la teoría de bancos de filtros*, Revista Técnica de Ingeniería . Facultad de Ingeniería. Universidad del Zulia Venezuela. **21** (1998), no. 2.
- [12] L. Escobar, *Algoritmos de filtrado adaptable : implementación, evaluación, comparación y aplicaciones en telecomunicaciones*, Tesis de Maestría, División de Estudios de Posgrado de la Facultad de Ingeniería. Universidad Nacional Autónoma de México, 1997.
- [13] T. Fays and J. Knott, *Fundamentals of eeg technology basic concepts and methods*, Raven Press, New York, 1983.

- [14] R. Ferria and et al, *Inter-rater reliability of sleep cyclic alternating pattern (cap) scoring and validation of a new computer-assisted cap scoring method*, Clinical Neurophysiology **1** (2004), no. 12.
- [15] G. Garcia and T. Ebrahimi, *Joint time-frequency-space classification of eeg in a brain computer interface application*, Tech. report, Swiss Federal Institute of Technology, 2003.
- [16] R. Gonzalez and P. Wintz, *Digital image processing*, Addison-wesley, 1987.
- [17] E. González, *Estudio y comparación de algoritmos de filtrado adaptable para la igualación de canal*, Tesis de Maestría, División de Estudios de Posgrado de la Facultad de Ingeniería. Universidad Nacional Autónoma de México, 1997.
- [18] A. Gray and J. Markel, *Distance measures for speech processing*, IEEE Transactions on Acoustics, Speech, and Signal Processing (1976), no. 5.
- [19] J. Gutiérrez, *Caracterización de espigas epilépticas puntiformes*, Ph.D. thesis, División de Estudios de Posgrado de la Facultad de Ingeniería. Universidad Nacional Autónoma de México, 2002.
- [20] S. Haykin, *Adaptive filter theory*, Prentice Hall, New York, 1992.
- [21] M. Hernandez, *Análisis comparativo de algoritmos para reducción de ruido en señales utilizando wavelets*, Escuela de Ingeniería, Departamento de Ingeniería Electrónica. Universidad de las Américas, Puebla, 2003.
- [22] E. Niedermeyer and F. Lopes da Silva, *Electroencephalography. basic principles, clinical applications and related fields*, 2a ed., Urban and Schwarzenberg, Munich, 1987.
- [23] C. Radar J. Proakis and et al., *Advanced digital signal processing*, Macmillam Publishing Company, 1992.
- [24] H. Jasper, *The ten twenty electrode system of the international federation.*, EEG Journal (1958), no. 10.
- [25] J.P. Kaipio and P.A. Karjalainen, *Simulation of non stationary eeg*, Tech. report, University of Kuopio Department of Applied Physics, Finland, 1994.
- [26] X. Kong and et al., *Detection of eeg changes via a generalized itakura distance*, in IEEE Proceedings 30 Nov. 2 (1997).
- [27] R. Largo and C. Munteanu, *Cap event detection by wavelets and ga tuning*, Intelligent Signal Processing, 2005 IEEE International Workshop on **1** (2005), no. 3.
- [28] B. Leprettre and N. Martin, *Extraction of pertinent subsets from time frequency representations for detection and recognition purposes*, Signal Processing (2002), no. 82.

- [29] J. Lima and A Rosa, *Maximum likelihood based classification for the microstructure of human sleep*, Tech. report, Institute for Systems and Robotics, 1998.
- [30] J. Lima and A. Rosa, *Classification of microstructure of human sleep using eeg modeling*, Tech. report, Institute for Systems and Robotics Lisbon Portugal, 1999.
- [31] M. Maggioni, *Discretization of continuous wavelet transforms.*, Ph.D. thesis, Washington University, St.Louis., 2002.
- [32] N Martins, *Modelação estocástica do eeg em tempo discreto*, Master's thesis, Instituto Superior Técnico, 1997.
- [33] N Martins and A Rosa, *Eeg non-stationary spectrum analysis and feature extraction*, IEEE - Systems Man and Cybernetics (1996).
- [34] N Martins and A Rosa, *Selective linear prediction for rhythmic activity modeling*, Tech. report, Instituto Superior Técnico, 1997.
- [35] R Palaniappan and et al., *Autoregressive spectral analysis and model order selection criteria for eeg signals*, TENCON 2000. Proceedings **2** (2000).
- [36] G Pfurtscheller and R Cooper, *Frequency dependence of the trasmission of the eeg from cortex to scalp*, Electroenceph. Clin. Neuroph. (1975), no. 38.
- [37] A. Rechtschaffen and A. Kales, *A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects*, Brain Information Service/Brain Research Institute. University of California at Los Angeles, 1968.
- [38] E. Ledesma, *Reporte de resultados de la evaluación de algoritmos de identificación de secuencias cap*, 06.
- [39] L. Romero, *Sistema de clasificación automática de señales eeg por medio de métodos paramétricos*, Master's thesis, División de Estudios de Posgrado de la Facultad de Ingeniería. Universidad Nacional Autónoma de México, 1989.
- [40] A. Rosa, *Optimal detection of k-complexes based on a stochastic model of the sleep eeg*, Ph.D. thesis, IST-IdTL, Lisbon, 1989.
- [41] A Rosa, A; Fred and et al., *Stochastic model of awake and sleep eeg*, Tech. report, IST-CAPS, Technical University of Lisbon, Portugal, 1998.
- [42] A. Rosa, L Parrino, and M. Terzano, *Automatic detection of cyclic alternating pattern (cap) sequences in sleep: Preliminary results*, Clinic Neurophysiology (1999), no. 4.
- [43] A. Rosa, *Unified simulation model of the scalp eeg*, Tech. report, Technical University of Lisbon, 1995.

- [44] A. Rosado, *Desarrollo de técnicas de detección de fibrilación ventricular basadas en algoritmos tiempo-frecuencia*, Ph.D. thesis, Universidad de Valencia. España, 2000.
- [45] J. Sauvola and T. Seppanen, *Adaptive document binarization*, Document Analysis and Recognition, 1997., Proceedings of the Fourth International Conference on **1** (1997).
- [46] Qin Shuren and Ji Zhong, *Extraction of features in eeg signals with the non-stationary signal analysis technology*, Proceedings of the 26th Annual International Conference of the IEEE EMBS (2004).
- [47] K Susmáková, *Human sleep and sleep eeg*, Measurement Science **4** (2004).
- [48] M. Terzano and L.Parrino, *Origin and significance of the cyclic alternating pattern (cap)*, Sleep Medicine Reviews (2000), no. 1.
- [49] M. Terzano and L. Parrino, *Functional relationship between micro- and macrostructure of sleep*, Raven Press. New York, 1991.
- [50] M Terzano and L Parrino, *Clinical applications of cyclic alternating pattern*, Physiology and Behavior **54** (1993).
- [51] M. Terzano, L. Parrino, and A. Sherieri, *Atlas, rules, and recording techniques for the scoring of cyclic alternating pattern (cap) in human sleep*, Sleep Medicine (2001), no. 2.
- [52] W.J. Williams and et al., *Analysis in electrophysiology signals in epilepsy*, IEEE Engineering in Medicine and Biology (1995).
- [53] C. Zepeda, *Sistema de clasificación de señales eeg utilizando el ambiente de programación visual khoros*, Benemérita Universidad de Puebla, 1995.
- [54] Jz. Zhong and Qin Shuren, *Detection of eeg basic rhythm feature by using band relative intensity ratio(brir)*, Proceedings of the 2003 IEEE International Conference on Acoustics, Speech, and Signal Processing (2003), no. 10.