

# Métodos especiales para el realce en frecuencia de datos sísmicos post-stack

**Gabriel Ricardo Gelpi**

Director: Dr. Danilo Rubén Velis

Co-director: Dr. Daniel Omar Pérez



Facultad de Ciencias Astronómicas y Geofísicas  
Universidad Nacional de La Plata

Tesis presentada para optar por el grado de  
*Doctor en Geofísica*

2024



# Métodos especiales para el realce en frecuencia de datos sísmicos post-stack

Tesis presentada en cumplimiento de los requisitos  
para obtener el grado de

*Doctor en Geofísica*

por

Gabriel Ricardo Gelpi

en la

Facultad de Ciencias Astronómicas y Geofísicas

Universidad Nacional de La Plata

Director: Dr. Danilo Rubén Velis

Co-director: Dr. Daniel Omar Pérez

Jurado: - Dr. Luis Guarracino

- Dra. Patricia M. Gauzellino

- Dr. Roberto Henry Herrera



Facultad de Ciencias Astronómicas y Geofísicas  
Universidad Nacional de La Plata  
Paseo del Bosque s/n  
La Plata (1900)  
Argentina

## Agradecimientos

A mis directores, no sólo por el aprendizaje y guía durante este largo trayecto, sino también por estar siempre en los momentos claves.

Al jurado de esta Tesis por su tiempo y valiosas sugerencias/correcciones para mejorar este trabajo.

A todos en el Dpto. de Geofísica Aplicada por el cariño y los buenos momentos compartidos. Es un camino difícil sin todo ese apoyo.

A los profesores, por las charlas, consejos y buenos momentos compartidos.

Al observatorio por darme el espacio y recursos para poder llevar a cabo este trabajo de Tesis.

Al CONICET por su ayuda financiera.

A toda mi familia por el apoyo durante todos estos años. Particularmente a Naty y Emi, que me dieron la fuerza final para poder terminar este trabajo.



# Resumen

La caracterización sísmica del subsuelo es una parte fundamental en el proceso de búsqueda de hidrocarburos. Debido a diferentes procesos que ocurren en el medio como la atenuación y dispersión, hay una pérdida del contenido en frecuencia de las señales sísmicas, lo que lleva a una pérdida de la resolución que dificulta la interpretación de los datos. Una forma de mitigar este problema es mediante procesos como la deconvolución y el realce en frecuencias. La deconvolución busca mejorar el ancho de banda del dato y por ende su resolución. Esta operación busca remover el efecto de la ondícula sísmica con el fin de obtener una estimación de los coeficientes de reflexión que representan los cambios de impedancia acústica del subsuelo. La deconvolución depende de la ondícula, por lo que también es necesario contar con estrategias que permitan obtener una buena estimación de la misma. Por otro lado, para poder incrementar el ancho de banda es necesario contar con información *a priori* disponible.

En esta Tesis se presenta un conjunto de estrategias que apuntan a mejorar la resolución vertical del dato sísmico. En primer lugar, se presenta un nuevo método para obtener una estimación confiable de la ondícula, con énfasis en la estimación de la fase, cuando solo se cuenta con el dato sísmico. Dicho método asume fase constante y reflectividad de tipo *sparse-spike*. Luego, la fase óptima de la ondícula se obtiene buscando la rotación de fase que conduce al dato deconvolucionado con menor valor de la norma  $l_1$ . Posteriormente se presenta una nueva estrategia que permite realizar de manera automática el amarre de pozos, y también en simultáneo la estimación de la ondícula sísmica. Esto se lleva a cabo iterativamente mediante el ajuste de la fase y el perfil sísmico registrado de manera sincrónica, y en forma tal que mejore la correlación entre la traza sintética y la traza observada. El método hace uso de una función de ajuste para perturbar el perfil sísmico en cada iteración. Las ondículas estimadas con éstos métodos y la estrategia para el amarre de pozos se utilizan como punto de partida para un nuevo método de deconvolución. Dicho método permite realizar la deconvolución de manera consistente con información de pozos y extender el ancho de banda para mejorar su resolución. En este caso, se perturba una reflectividad *sparse* de manera iterativa aplicando una función de ajuste temporal que conduce a un error mínimo entre la traza sintética y observada. El modelo inicial se obtiene con la estrategia de amarre de pozos automático y la función que permite el ajuste se construye de manera similar a la de dicho método. El proceso se inicia deconvolucionando una traza inmediata a la posición del pozo y repitiendo el proceso para las trazas contiguas. Una vez que se tiene la solución *sparse* se la convoluciona con una ondícula de mayor ancho de banda para obtener una mejor resolución. La estabilidad y continuidad lateral se garantiza asumiendo que los *sparse-spikes* asociados a dos reflectividades próximas varían poco, tanto de amplitud como de posición. Estas estrategias fueron probadas satisfactoriamente utilizando datos sintéticos, pseudo-sintéticos y datos de campo.

# Índice general

Índice de figuras	ix
Índice de tablas	xiii
<b>1. Introducción general</b>	<b>1</b>
1.1. Contexto actual de los hidrocarburos y el rol de la Geofísica . . . . .	1
1.2. Motivación y dificultad del método sísmico . . . . .	2
1.3. Objetivos . . . . .	4
1.4. Organización de la Tesis. . . . .	5
<b>2. Resolución sísmica y realce en frecuencias</b>	<b>8</b>
2.1. Introducción . . . . .	8
2.2. Modelo convolucional. . . . .	9
2.3. Ondícula sísmica . . . . .	10
2.4. Resolución sísmica . . . . .	12
2.5. Resolución y ancho de banda . . . . .	13
2.6. Relevancia de la fase de la ondícula .. . . .	15
2.7. Realce en frecuencias. . . . .	18
2.8. Comentarios finales. . . . .	20
<b>3. Deconvolución sísmica</b>	<b>21</b>
3.1. Introducción . . . . .	21
3.2. Deconvolución sísmica . . . . .	22
3.3. Deconvolución de tipo <i>sparse-spike</i> . . . . .	23
3.4. Relación entre la norma $l_1$ y soluciones de tipo <i>sparse-spike</i> . . . . .	27
3.5. Conclusiones . . . . .	30
<b>4. Estimación de la ondícula sísmica</b>	<b>31</b>
4.1. Introducción . . . . .	31
4.2. Estimación de la ondícula sísmica mediante la maximización de la <i>curtosis</i> . . . . .	33
4.3. Estimación de la ondícula mediante la minimización de la <i>norma</i> . . . . .	34
4.4. Resultados numéricos .. . . .	36
4.4.1. Selección del parámetro de <i>trade-off</i> . . . . .	36
4.4.2. Análisis de sensibilidad .. . . .	37

4.4.3. Marmousi2 . . . . .	40
4.4.4. Datos de campo . . . . .	42
4.5. Discusión . . . . .	44
4.6. Conclusiones . . . . .	46
<b>5. Amarre de pozos y estimación de la fase de la ondícula sísmica</b>	<b>49</b>
5.1. Introducción . . . . .	49
5.2. Fundamentos del amarre de pozos . . . . .	51
5.3. Amarre de pozos y estimación de la fase automáticamente . . . . .	52
5.4. Resultados numéricos .. . . .	55
5.4.1. Dato pseudo-sintético .. . . .	55
5.4.2. Dependencia de los parámetros . . . . .	56
5.4.3. Análisis estadístico . . . . .	61
5.4.4. Datos de campo . . . . .	63
5.5. Amarre <i>blocky</i> de pozos .. . . .	66
5.5.1. Segmentación de perfiles de pozo . . . . .	68
5.5.2. Ejemplo de amarre <i>blocky</i> . . . . .	70
5.6. Discusión . . . . .	70
5.7. Conclusiones . . . . .	72
<b>6. Deconvolución <i>sparse-spike</i> basada en información de pozos y realce en frecuencias</b>	<b>73</b>
6.1. Introducción . . . . .	73
6.2. Sobre la deconvolución <i>sparse-spike</i> . . . . .	75
6.3. Deconvolución <i>sparse-spike</i> y realce en frecuencias. . . . .	76
6.4. Resultados numéricos .. . . .	79
6.4.1. Ejemplo sintético 1D . . . . .	79
6.4.2. Ejemplo sintético 2D . . . . .	82
6.4.3. Datos de campo . . . . .	88
6.5. Discusión y consideraciones . . . . .	90
6.6. Conclusiones . . . . .	95
<b>7. Conclusiones</b>	<b>97</b>
7.1. Contribuciones . . . . .	99
<b>Apéndice A. Algoritmos de optimización</b>	<b>101</b>
A.1. Introducción . . . . .	101
A.2. <i>Differentialevolution</i> . . . . .	102
A.3. <i>Very fast simulated annealing</i> ... . . . .	103
A.4. <i>Fast iterative shrinkage-thresholding algorithm</i> .. . . .	106
<b>Bibliografía</b>	<b>108</b>

# Índice de figuras

1.1.	Esquema ilustrativo del proceso de adquisición del dato sísmico y propagación de la energía en las distintas discontinuidades del subsuelo. . . . .	2
2.1.	a) Ondícula de Ricker. b) Espectro de amplitud de la ondícula de Ricker. c) Ondícula de Ormsby. d) Espectro de amplitud de la ondícula de Ormsby.	
2.2.	Resolución: Ilustración de un modelo de cuña con dos <i>spikes</i> de igual amplitud y polaridad (gris), y respuesta de la ondícula convolucionada con la reflectividad del modelo (negro) de subsuelo propuesto. . . . .	14
2.3.	Ilustración de la resolución en términos del ancho de banda. A mayor ancho de banda, mejora la distinción entre los eventos, particularmente cuando están muy próximos entre sí. . . . .	15
2.4.	Relevancia del contenido en frecuencias: ondículas de Ormsby con contenido en frecuencia bajo a), alto b) y combinación de ambos c). Paneles d)-f) muestran los respectivos espectros de amplitud. . . . .	16
2.5.	Comparación de ondículas de fase mínima y fase cero con igual contenido en frecuencia: a) conjunto de coeficientes de reflexión cada vez más cercanos entre sí hacia la derecha, b) sintético creado con ondícula de fase cero y c) sintético creado con ondícula de fase mínima. . . . .	17
3.1.	Ejemplo de deconvoluciones con diferentes regularizaciones: a) reflectividad, b) traza sintética, c) deconvolución con regularización cuadrática, d) deconvolución con regularización no cuadrática y e) reflectividad <i>sparse-spike</i> del panel d) convolucionada con una ondícula de mayor ancho de banda. . . . .	26
3.2.	Espectros de amplitud: de la traza sintética, del dato deconvolucionado con una regularización cuadrática $\eta^2$ , y del deconvolucionado con regularización no cuadrática $\eta$ y aplicado una ondícula de Ormsby. . . . .	27
3.3.	Distribuciones normal y laplaciana centradas en el origen. La primera asociada a las soluciones suaves de la deconvolución con regularización cuadrática y la segunda a soluciones de tipo <i>sparse-spike</i> mediante una regularización con norma $l_1$ (no cuadrática). . . . .	29

- 
- 4.1. Ejemplo sintético 1: a) modelo de reflectividad, b) traza con ruido y c) traza deconvolucionada utilizando la ondícula con la fase estimada mediante el método de la norma  $l_1$ . . . . . 37
- 4.2. Ejemplo sintético 1: Curvas de la norma  $l_1$  para los valores  $\lambda = 0.005, 0.01, 0.025, 0.05, 0.075$  y  $0.1$ . La flecha indica la dirección en la que crece  $\lambda$ . . . . . 38
- 4.3. Ejemplo sintético 2: Primera fila: probabilidad de encontrar la fase correcta dentro de una tolerancia de  $\pm 20^\circ$  utilizando los métodos de la norma  $l_1$  y el de la curtosis. Segunda fila: fases medias estimadas. Tercer fila: desvío estándar de las fases estimadas. . . . . 39
- 4.4. Ejemplo sintético 2: histogramas de las estimaciones de la norma  $l_1$  y la curtosis para  $BW = 40$  Hz y distintos valores de  $P$ . . . . . 41
- 4.5. Ejemplo sintético 3: prueba a) modelo de reflectividad extraído del Marmousi2, b) sección con  $BW = 30$  Hz, c) sección con  $BW = 80$  Hz. En ambos casos,  $S/N = 3$ . . . . . 42
- 4.6. Ejemplo sintético 3: desempeño de la norma  $l_1$  y la curtosis: a) dato libre de ruido, b)  $S/N = 15$  y c)  $S/N = 3$ . . . . . 43
- 4.7. Ejemplo sintético 3: deconvoluciones *sparse-spike* para los casos con  $BW = 30$  Hz (primer fila) y  $80$  Hz (segunda fila). . . . . 44
- 4.8. Ejemplo dato de campo: a) Sección sísmica; b) y c) deconvoluciones *sparse-spike* utilizando las ondículas estimadas mediante los métodos de la norma  $l_1$  y la curtosis, respectivamente. . . . . 45
- 4.9. Ejemplo dato de campo: regiones indicadas en los rectángulos blancos en la Figura 4.8: a) norma  $l_1$  y b) curtosis. Las flechas negras indican las principales diferencias entre las dos soluciones obtenidas. . . . . 46
- 4.10. Ejemplo dato de campo: ondículas estimadas en cada ventana de análisis utilizando a) la norma  $l_1$  y b) la curtosis. . . . . 47
- 4.11. Ejemplo dato de campo: a) traza 100; b) y c) deconvolución *sparse-spike* utilizando las ondículas estimadas por medio de los métodos de la norma  $l_1$  y la curtosis, respectivamente. . . . . 48
- 5.1. Ejemplo pseudo-sintético: a) en negro el perfil de velocidad original y en rojo el perfil perturbado; b) curva  $\rho(z)$  utilizada para perturbar el perfil de velocidad con  $M = 5$  y  $P = 0.15$ ; c) en negro la ondícula de Ricker de fase cero y en rojo con la fase rotada a  $-30$ ; d) en negro la traza sintética inicial asociada al dato de pozo y en rojo la traza observada. 57
- 5.2. Ejemplo pseudo-sintético: resultados con un cambio de velocidad de  $P = 0.15$  para diferente número de nodos. a) Perfiles de velocidad observados (negro) y perturbados (en colores), b) curva  $\rho(z)$ , y c) trazas sintéticas correspondientes. . . . . 59
- 5.3. Ejemplo pseudo-sintético: resultados con  $M = 10$  y distintos cambios de velocidad  $P$ . a) Perfiles de velocidad observados (negro) y perturbados (en colores), b) curva  $\rho(z)$ , y c) trazas sintéticas correspondientes. . . 60

5.4.	Ejemplo pseudo-sintético 3: Histogramas de las fases estimadas luego de las 100 realizaciones para los distintos pares de parámetros. . . . .	62
5.5.	Ejemplo pseudo-sintético 3: Resultado luego de 100 realizaciones utilizando $M = 3$ y $P = 0.05$ . a) Perfil de velocidad observado en negro y perturbado en rojo, b) curvas $\rho(z)$ , y c) sismogramas sintéticos calculados	64
5.6.	Ejemplo pseudo-sintético 3: Resultado luego de 100 realizaciones utilizando $M = 10$ y $P = 0.15$ . a) Perfil de velocidad observado en negro y perturbado en rojo, b) curvas $\rho(z)$ , y c) sismogramas sintéticos calculados	65
5.7.	Ejemplo dato de campo, Pozo A: a) Perfil de velocidad observado en negro y perturbado en rojo, b) curva $\rho(z)$ utilizando $M = 15$ y $P = 0.15$ , trazas observada en negro y sintética en rojo luego del c) amarre manual, d) el método propuesto y e) DTW con restricciones.. . . . .	67
5.8.	Ejemplo dato de campo, Pozo B: a) Perfil de velocidad observado en negro y perturbado en rojo, b) curva $\rho(z)$ utilizando $M = 10$ y $P = 0.1$ , trazas observada en negro y sintética en rojo luego del c) amarre manual, d) el método propuesto y e) DTW con restricciones.. . . . .	68
5.9.	Ejemplo dato de campo: Ondículas estadísticas estimadas (línea punteada) y con estimación de fase (línea continua) para a) pozo A y b) pozo B. . . . .	69
5.10.	Ejemplo dato de campo blocky: en gris el perfil observado, en negro el perfil observado <i>blocky</i> y en rojo el perfil perturbado luego del amarre, b) curva $\rho(z)$ con $M = 10$ y $P = 0.1$ , c) y d) en rojo trazas sintética y en negro traza observada antes y después de aplicar el método propues	71
6.1.	Dato sintético 1D. a) Reflectividad real (negro) e inicial (azul). b) Dato sin ruido. c) Dato con ruido ( $S/N=5$ ). . . . .	80
6.2.	Ejemplo sintético 1D. Media y desvío estándar del <i>misfit</i> vs. número de nodos (100 realizaciones). . . . .	81
6.3.	Ejemplo sintético 1D. a) Reflectividad real (negro) y estimada promedio luego de 100 realizaciones (rojo). b) Desvío estándar. c) Trazas observadas y promedio estimado (rojo).. . . . .	82
6.4.	Ejemplo sintético 1D. Función de deformación estimada (gris), real (rojo) y función de deformación promedio (azul) para $K_0 = 6$ (100 realizaciones). Las barras negras muestran los desvíos estándar para cada nodo. . . . .	83
6.5.	Ejemplo sintético 2D. a) Sección reflectiva real. b) En negro, reflectividad inicial en la posición del pozo (ubicada en la primera traza), y en rojo, la ondícula utilizada. c) y d) Datos con ruido gaussiano $S/N=5$ y $S/N=1$ , respectivamente. . . . .	84
6.6.	Ejemplo sintético 2D. Arriba: Reflectividades estimadas usando $K_0 = 10$ , $d = 3$ y a) $\lambda = 0.005$ , b) $\lambda = 0.05$ y c) $\lambda = 0.5$ , para el caso de $S/N=5$ . Abajo: idem para el caso de $S/N=1$ . . . . .	86
6.7.	Ejemplo sintético 2D. Misfit traza a traza para los tres valores del parámetro de <i>trade-off</i> considerados para los datos con a) $S/N=5$ y b) $S/N=1$ . . . . .	87

---

6.8. Ejemplo sintético 2D. Reflectividades estimadas para los datos con S/N=5 al utilizar una ondícula de Ricker de 30 Hz con tres rotaciones de fase constante. . . . .	88
6.9. Ejemplo de dato de campo. a) Perfil de velocidad observado. b) Perfiles de velocidad <i>blocky</i> y perturbado (negro y verde respectivamente). c) Reflectividad <i>sparse</i> inicial obtenida a partir del perfil perturbado. d) Ondícula estimada y las dos ondículas de Ormsby utilizadas para el realce en frecuencias. e) Amarre: Trazas sintética (negro), <i>inline</i> (rojo) y <i>crossline</i> (verde). . . . .	89
6.10. Ejemplo de dato de campo. a) Dato observado. b) Reflectividad estimada. c) y d) Datos con realce en frecuencia utilizando las dos ondículas de Ormsby consideradas. . . . .	91
6.11. Ejemplo de dato de campo. Ventana ampliada de la <i>crossline</i> . a) Dato observado, b) y c) Datos con realce en frecuencias usando las ondículas de Ormsby consideradas. . . . .	92
6.12. Ejemplo de dato de campo. Ventana ampliada de la <i>crossline</i> . Imagen de la reflectividad obtenida usando a) método propuesto y b) el método propuesto por Pérez et al. (2013). . . . .	93
6.13. Ejemplo de dato de campo. a) Ondículas estimadas y de Ormsby utilizadas para los realces en frecuencia. b) y c) Espectro de amplitud promedio correspondiente al dato observado y los realces en frecuencia de las <i>inline</i> y <i>crossline</i> . . . . .	94
A.1. Diagrama de flujo del algoritmo VFSA (Velis, 1998). . . . .	105

# Índice de tablas

4.1. Ejemplo sintético 1: fases óptimas $\hat{\phi}$ (en grados) para distintos valores del parámetro de <i>trade-off</i> $\lambda$ . . . . .	38
4.2. Ejemplo dato de campo: fases estimadas por cada método en cada ventana solapada (en grados).. . . . .	47
5.1. Ejemplo pseudo-sintético: Coeficientes de correlación y fases estimadas para diferentes números de nodos y un cambio de velocidad fijo $\beta = 0.15$ . 58	
5.2. Ejemplo pseudo-sintético: Coeficientes de correlación y fases estimadas para diferentes cambios de velocidad y un número fijo de nodos $M = 10$ . 58	
5.3. Ejemplo pseudo-sintético 3: coeficientes de correlación promedio luego de 100 realizaciones para los distintos pares de parámetros. En todos los casos, el desvío estándar estuvo en el orden de 0.001. . . . .	61

# Capítulo 1

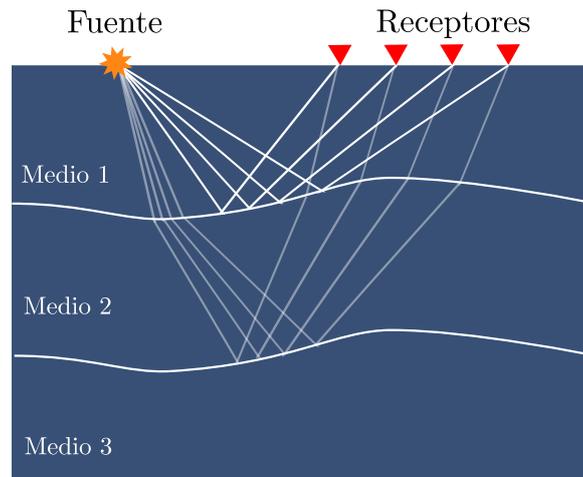
## Introducción general

### 1.1. Contexto actual de los hidrocarburos y el rol de la Geofísica

El petróleo y el gas natural son pilares fundamentales de la economía moderna. La creciente demanda energética global y las proyecciones futuras continúan situando a los combustibles fósiles como la principal fuente de energía en el mundo (Chengzao, 2017). Según el reporte de la Agencia Internacional de Energía de los Estados Unidos (IEA, 2023), se proyecta un incremento sostenido en la demanda de estos recursos hasta alcanzar un máximo alrededor del año 2030, dependiendo de la región, y manteniéndose en niveles altos hasta 2050. Este aumento es especialmente notable en regiones como China y países emergentes.

Estas proyecciones resaltan la necesidad de incorporar nuevas reservas de hidrocarburos en los próximos años. Sin embargo, la búsqueda de nuevos reservorios rentables es cada vez más desafiante desde los puntos de vista geológico y técnico, ya que muchos de ellos se encuentran en regiones remotas con condiciones ambientales difíciles (Tarbuck y Lutgens, 2005). A lo largo del tiempo, se ha avanzado significativamente desde las primeras teorías de reservorios, como la "teoría del reservorio anticlinal" (Ashburner y White, 1885), que promovió el descubrimiento y desarrollo de muchos campos de hidrocarburos a nivel mundial (Tarbuck y Lutgens, 2005; Chengzao, 2017). Este panorama exige la incorporación de nuevas tecnologías y la adaptación continua del conocimiento en las geociencias para la exploración y producción de hidrocarburos (Chengzao, 2017).

En este contexto, la geofísica de exploración desempeña un papel fundamental mediante el uso de técnicas que permiten la observación indirecta del subsuelo. Entre estas técnicas se incluyen métodos potenciales, eléctricos, electromagnéticos y sísmicos (Udías y Mezcuca, 1986; Lillie, 1999). A través de estas herramientas, es posible identificar y delinear cuerpos o estructuras de interés geológico. Dentro de este conjunto de métodos, la sísmica de reflexión se destaca como una de las más relevantes para identificar objetivos potenciales en el subsuelo. Este método, que data de la década de 1920 (Robinson y Treitel, 2008), se ha convertido en una herramienta clave en



**Figura 1.1.** Esquema ilustrativo del proceso de adquisición del dato sísmico y propagación de la energía en las distintas discontinuidades del subsuelo.

la industria de los hidrocarburos para el estudio detallado de grandes volúmenes del subsuelo, facilitando tanto la interpretación geológica como los estudios ingenieriles, tales como la ubicación y desarrollo de pozos de exploración o producción (Yilmaz, 2001).

La caracterización sísmica del subsuelo es, por lo tanto, esencial para el análisis de las estructuras geológicas y otros rasgos relacionados con los recursos potenciales de hidrocarburos. El método sísmico de reflexión permite obtener imágenes detalladas del subsuelo registrando en superficie las ondas sísmicas que se propagan a través del medio terrestre y se reflejan en las discontinuidades geológicas. En la Figura 1.1, se presenta un esquema básico de este proceso, basado en la teoría de rayos y un diseño estándar de fuente y receptores.

Estas ondas sísmicas penetran en el subsuelo mediante fuentes de energía, como explosivos o dispositivos mecánicos y son registradas en la superficie por sensores conocidos como geófonos en operaciones terrestres, o hidrófonos cuando el trabajo se realiza en cuerpos de agua. A medida que la energía se propaga por el interior de la Tierra, se refleja y refracta en las diversas discontinuidades geológicas, y parte de esta energía es captada por los sensores en superficie. Una vez que finaliza la adquisición de los datos, el procesamiento de estos permite generar imágenes detalladas del subsuelo, listas para su interpretación.

## 1.2. Motivación y dificultad del método sísmico

Si bien el método sísmico tiene grandes ventajas para el estudio del subsuelo, también presenta ciertas limitaciones. Una de las principales dificultades al interpretar los datos sísmicos es el ancho de banda limitado que posee, lo cual impide la caracterización de estructuras o rasgos geológicos por debajo de ciertos espesores. Esto ocurre porque,

a medida que las ondas viajan por el subsuelo, se ven afectadas por fenómenos como la atenuación y la dispersión, que alteran su contenido en frecuencias (Futterman, 1962; Kjartansson, 1979; Wang, 2009). El medio terrestre actúa como un filtro que atenúa principalmente las altas frecuencias (Shearer, 2019). Como consecuencia, las imágenes obtenidas tienen una resolución limitada, lo que dificulta su interpretación. Este problema se agrava cuando los reservorios presentan espesores menores y/o geometrías más complejas.

Para superar estas limitaciones, es necesario recurrir a procesos y técnicas especiales que mejoren la capacidad de identificar estructuras importantes, como capas delgadas, *pinch-outs*, lentes, fallas, entre otras, todas ellas de gran relevancia en la caracterización de reservorios. Cualquier esfuerzo por mejorar la resolución de los datos sísmicos es siempre bien recibido (Mamasani et al., 2017).

En las diferentes etapas del método sísmico, se busca preservar o mejorar la resolución sísmica (Yilmaz, 2001; Robinson y Treitel, 2008; Herron, 2011; Torben Hoy, 2013). En la bibliografía reciente se destacan avances significativos en el diseño de adquisiciones y el desarrollo de nuevas tecnologías para sensores y fuentes sísmicas, tanto en operaciones marinas (*off-shore*) como terrestres (*on-shore*) (Monterey, 2020). Estos avances en la adquisición de datos permiten obtener registros con un mayor ancho de banda, lo que se traduce en imágenes de mejor resolución y facilita la interpretación geológica (Kroode et al., 2013).

Una vez adquiridos los datos, es necesario recurrir a técnicas de procesamiento avanzadas para mejorar la resolución. Entre estas técnicas se encuentran aquellas basadas en el realce de frecuencias, cuyo objetivo es incrementar el ancho de banda efectivo de la señal sísmica (Soldo et al., 2008; Kumar et al., 2008; Wang, 2009). La manera en que estas técnicas extienden el contenido en frecuencias da lugar a una gran variedad de métodos, ampliamente documentados en la bibliografía (Wiggins, 1978; Oldenburg et al., 1983; Walden, 1985; Hargreaves y Calvert, 1991; Sacchi et al., 1994; Blache-Fraser y Neep, 2004; Puryear y Castagna, 2008; Velis, 2008; Pérez et al., 2024).

Un desafío común en estas propuestas es que el contenido de altas frecuencias ya no está presente en los datos, ya que ha sido filtrado por el medio. Por lo tanto, para recuperar esta información, es necesario recurrir a criterios empíricos o modelos que describan la traza sísmica esperada, basándose en información *a priori* disponible. Una forma habitual de incorporar esta información *a priori* es a través de los datos de pozos.

La vinculación entre los datos de pozos y los datos sísmicos está estrechamente relacionada con la resolución sísmica. Este proceso combina dos tipos de datos complementarios: los datos sísmicos, que tienen una amplia cobertura areal pero una resolución relativamente baja y los datos de pozos, que tienen una alta resolución vertical pero una distribución espacial más limitada. El amarre de pozos o *wellog* permite relacionar las imágenes sísmicas con las mediciones de los pozos (por ejemplo, perfiles sónicos y de densidad), lo que permite extrapolar información detallada de los pozos hacia las líneas sísmicas 2D o los cubos 3D (Herron, 2011; Zhou, 2014).

Entre los métodos de realce de frecuencias, se destacan aquellos que utilizan filtros inversos para restaurar el contenido de alta frecuencia perdido, como los filtros inversos  $Q$ . Además, existen métodos empíricos que trabajan en dominios matemáticos diferentes al del tiempo o las frecuencias (Sajid y Ghosh, 2014). Otro de los métodos más estudiados y aplicados para mejorar la resolución sísmica es la deconvolución. Esta técnica busca remover el efecto de la ondícula sísmica del dato, mejorando el ancho de banda de la señal y, por ende, su resolución (Robinson y Treitel, 2002; Cary, 2006; Mamasani et al., 2017).

Aunque estas técnicas permiten mejorar la resolución al incrementar el ancho de banda de la señal, las soluciones obtenidas aún tienen un límite en cuanto a su capacidad para aumentar la resolución. En muchos casos, la mejora lograda puede no ser suficiente para interpretar adecuadamente las secciones sísmicas (Babasafari et al., 2019). Existen otras estrategias que apuntan a extender el espectro mediante métodos basados en el concepto de mínima entropía (Wiggins, 1978; Walden, 1985; Sacchi et al., 1994) o deconvolución de alta resolución basados en soluciones *sparse-spike* (Oldenburg et al., 1983; Debeye y van Riel, 1990; Velis, 2008; Brown y Thorne, 2013; Kazemi y Sacchi, 2014). Estos métodos permiten extender el espectro más allá del ancho de banda original de los datos observados. La estimación precisa de la ondícula sísmica, tanto en amplitud como en fase, es clave para el éxito de estos métodos (Ulrych et al., 1995; Sacchi et al., 1996; Velis y Ulrych, 1996; Sacchi y Ulrych, 2000). El ajuste correcto de la fase permite mejorar el desempeño de las técnicas de realce en frecuencias y aumentar la resolución sísmica.

Dado el interés continuo de la industria en este tipo de tecnologías, se hace evidente la necesidad de desarrollar herramientas eficientes y eficaces para el realce de frecuencias de los datos sísmicos, con aplicaciones directas en la exploración y desarrollo de yacimientos de hidrocarburos. Además, es importante destacar que la sísmica de reflexión no se limita solo a la etapa de exploración, sino que también juega un rol crucial en las etapas de desarrollo y producción (Wang, 2009).

### 1.3. Objetivos

El objetivo general de esta tesis es diseñar nuevos algoritmos y herramientas computacionales que incrementen el ancho de banda efectivo de las señales sísmicas, mejorando su resolución vertical y temporal. Esto permitirá realizar interpretaciones más precisas de los datos sísmicos, proporcionando herramientas novedosas para la caracterización del subsuelo con fines de exploración y desarrollo de yacimientos de hidrocarburos. Un objetivo fundamental a mediano y largo plazo es contribuir al desarrollo de tecnologías en Argentina a través de *software* alternativo al comercial, con aplicación directa al estudio de reservorios convencionales y no convencionales de hidrocarburos.

Entre los objetivos específicos, se encuentra el desarrollo de algoritmos para aumentar el ancho de banda de los datos sísmicos poststack con un enfoque particular en la estimación y calibración de la fase de la ondícula sísmica. Además, se trabajará en

nuevas técnicas para la vinculación automática entre la información de pozos y los datos sísmicos (*well-ties*), lo que facilitará el proceso de amarre. Por último, se desarrollará un algoritmo para la estimación de series de coeficientes de reflexión *sparse-spike*, utilizando información proveniente de pozos, que permitirá generar soluciones 2D y 3D con una buena continuidad lateral y que incorpore de manera coherente la información *a priori*.

## 1.4. Organización de la Tesis

Esta tesis se organiza en siete capítulos y un apéndice, además de una sección de referencias bibliográficas. Cada capítulo presenta los conceptos claves, los fundamentos de los métodos propuestos y ejemplos que demuestran su alcance, limitaciones y rendimiento. En todos los casos, los resultados obtenidos se contrastan con métodos publicados y utilizados en la industria para validar su efectividad. Se incluye también una discusión y las conclusiones principales. En el apéndice se describen los algoritmos de optimización utilizados en la tesis.

### Capítulo 2

En este capítulo se introducen los conceptos básicos necesarios para comprender la resolución sísmica. Se revisa el modelo convolucional, que describe cómo se genera la señal sísmica a partir de la ondícula y la reflectividad de subsuelo. Además, se discuten aspectos como la relación entre resolución y ancho de banda, que es crucial para interpretar la información geológica obtenida a través de la sísmica de reflexión. También se aborda el rol fundamental de la ondícula sísmica en la resolución, así como su fase y su impacto en la calidad de las imágenes sísmicas. Finalmente, se presenta una descripción general de los métodos de realce en frecuencias, destacando su aplicación tanto en la bibliografía como en la industria a través de *software* comercial.

### Capítulo 3

En este capítulo se introduce la técnica de deconvolución sísmica, una de las herramientas más importantes para mejorar la resolución sísmica, especialmente la vertical. Se analiza en detalle el problema de la deconvolución, mostrando cómo diferentes enfoques de regularización (cuadráticos y no cuadráticos) pueden afectar la calidad de los resultados. Se presenta el método de deconvolución *sparse-spike*, que busca soluciones con alta resolución y pocos eventos. Mediante ejemplos numéricos se compara el rendimiento de las diferentes técnicas, destacando cómo la deconvolución no cuadrática permite una mejor recuperación de la reflectividad. Todos los resultados obtenidos se comparan con métodos publicados previamente para validar la efectividad del enfoque propuesto.

## Capítulo 4

Este capítulo propone un nuevo enfoque para la estimación de la ondícula sísmica, en el que se enfatiza el ajuste de la fase sin requerir información *a priori* de datos de pozos. Se describe el método en detalle, incluyendo las hipótesis necesarias para su aplicación. A través de ejemplos con datos sintéticos 1D y 2D, se demuestra la eficacia del método para ajustar la fase de la ondícula y mejorar la resolución del dato sísmico. Además, se muestra su aplicación a datos de campo, donde se comparan los resultados obtenidos con el método clásico de la curtosis, validando así su rendimiento frente a otros enfoques ya establecidos.

## Capítulo 5

En este capítulo se presenta una estrategia novedosa para realizar el amarre automático de pozos y la estimación de la fase de la ondícula sísmica. El método propuesto permite optimizar simultáneamente el perfil sónico y la fase de la ondícula, logrando una correlación óptima entre los datos sísmicos y los datos de pozos. Se describe el algoritmo en detalle, incluyendo el uso de optimización global mediante Evolución Diferencial. A través de ejemplos con datos sintéticos y de campo se demuestra la robustez del método, comparando los resultados obtenidos con otros enfoques automáticos de amarre de pozos, como el *Dynamic Time Warping*. El capítulo concluye con una extensión del método para trabajar con perfiles *blocky*, lo cual es fundamental para la deconvolución en el Capítulo 6.

## Capítulo 6

Este capítulo presenta un nuevo método de deconvolución sísmica y realce en frecuencias, que incorpora información *a priori* proveniente de pozos para mejorar la coherencia lateral y la resolución del dato sísmico. Se describe en detalle el enfoque, que utiliza una estrategia iterativa para ajustar la reflectividad sísmica de cada traza en base a la información disponible de pozos. El método permite obtener una deconvolución *sparse-spike* consistente, lo que resulta en una mejor continuidad lateral y un mayor control sobre el contenido de frecuencias altas. Se presentan ejemplos con datos sintéticos 1D y 2D, así como con datos de campo, y se comparan los resultados con otras técnicas de deconvolución, validando las mejoras alcanzadas en términos de resolución y coherencia.

## Capítulo 7

En este último capítulo se presentan las conclusiones generales de la tesis, resumiendo las principales contribuciones científicas y tecnológicas. Se destaca el impacto de los algoritmos desarrollados y su aplicabilidad en la exploración y desarrollo de yacimientos de hidrocarburos. Además, se detallan las contribuciones científicas, incluyendo presentaciones en congresos nacionales e internacionales, publicaciones en revistas con

referato, y el desarrollo de herramientas computacionales para la implementación de las estrategias presentadas a lo largo de la tesis.

# Capítulo 2

## Resolución sísmica y realce en frecuencias

### 2.1. Introducción

Se puede pensar en la resolución como una medida de la mínima separación, ya sea espacial o temporal, entre dos eventos sísmicos de manera tal que puedan ser distinguidos entre sí. Encontrar la forma de incrementar la resolución es de gran importancia, ya que permite obtener información geológica estructural y estratigráfica más detallada (Kahoo y Gholtashi, 2015). Este objetivo ha sido perseguido durante muchos años, con esfuerzos tanto por parte de la academia como de la industria petrolera (Soldo et al., 2008).

Desde el punto de vista de la adquisición, los últimos avances en la investigación y desarrollo de nuevas tecnologías, como los geófonos y diseños de adquisición, permiten obtener datos sísmicos de mayor ancho de banda. Posteriormente, mediante el procesamiento de estos datos, se obtienen imágenes sísmicas con un mayor grado de resolución (Kroode et al., 2013). Uno de los problemas en esta etapa es que los costos financieros asociados a estos avances son superiores a los de una adquisición tradicional. Por otro lado, existen muchos datos ya registrados que podrían generar nuevo valor a partir de su reprocesamiento utilizando flujos de trabajo y algoritmos más recientes y más innovadores.

Cuando se presentan estas dos cuestiones, el problema ligado a la resolución pasa a abordarse durante la etapa de procesamiento. En esta instancia, la deconvolución es un paso relevante ya que permite mejorar el ancho de banda de la señal registrada, facilitando la tarea del intérprete. Sin embargo, no es el único método que apunta a mejorar la resolución a partir de extender o incrementar el ancho de banda efectivo de los datos sísmicos (Kumar et al., 2008). El problema inmediato que aparece en este tipo de estrategias es que una parte de las altas frecuencias fue absorbida por el medio a medida que la señal se propagó por él (Robinson y Treitel, 2008; Wang, 2009). Por lo tanto, para poder recuperar esta información es necesario recurrir a hipótesis de la solución buscada o algún otro tipo de información adicional del problema. A

modo de ejemplo, algunos autores proponen incorporar información *a priori*, como la proveniente de pozos exploratorios.

Las distintas estrategias para recuperar esta porción del espectro que ya no está en el dato han dado lugar a los diversos métodos que se pueden encontrar en la bibliografía o en *software* comercial. Estos métodos, como veremos más adelante, son bien variados y van desde la deconvolución *spike* o filtros que intentan remover el efecto de la absorción del subsuelo (filtros inversos) hasta estrategias puramente matemáticas, con poco sentido geofísico, que buscan ayudar en la interpretación de las imágenes del subsuelo (Young et al., 2005; Kumar et al., 2008; Stark et al., 2009).

A lo largo de este capítulo se presentan conceptos básicos y definiciones relevantes relacionadas con la resolución sísmica. Se describen a modo de repaso los temas de modelo convolucional, la ondícula sísmica (pieza fundamental para la resolución vertical), la relación entre resolución y ancho de banda, y se ofrece una breve descripción de los métodos que permiten incrementar el contenido en frecuencia de los datos observados.

## 2.2. Modelo convolucional

A medida que las ondas sísmicas se propagan por el subsuelo e interactúan con las discontinuidades que separan las diferentes capas que lo conforman, parte de su energía se transmite a través de las capas y parte se refleja, regresando a la superficie. La señal registrada en la superficie, correspondiente a la porción de energía reflejada, constituye el dato observado, denominado sismograma o traza sísmica. El porcentaje de energía que se transmite y se refleja depende del valor del coeficiente de reflexión que caracteriza a cada discontinuidad, por lo que es natural caracterizar el subsuelo a través de una serie de coeficientes de reflexión de diferente amplitud. En esta serie, también conocida como reflectividad del subsuelo, es habitual referirse a estos coeficientes como *spikes*.

Por su parte, las ondas generadas en la superficie por alguna fuente (explosivos, cañón de aire o la caída de un peso) son representadas matemáticamente a través de una ondícula sísmica. De esta forma, se puede representar una traza mediante el modelo convolucional como:

$$s(t) = r(t) * w(t) + n(t), \quad (2.1)$$

donde  $s(t)$  es el sismograma o traza sísmica,  $r(t)$  la serie de coeficientes de reflexión,  $w(t)$  es la ondícula sísmica y  $n(t)$  el ruido aditivo. Este modelo se basa en las siguientes hipótesis (Yilmaz, 2001):

1. El subsuelo está compuesto por capas horizontales y paralelas de propiedades elásticas constantes.
2. Las ondas sísmicas son ondas compresionales planas que inciden de forma normal sobre las discontinuidades que separan las diferentes capas que forman el subsuelo.

Además, bajo estas circunstancias no se tiene conversiones de modo de la onda ni reflexiones múltiples.

### 3. La ondícula es estacionaria.

En la práctica, como es de esperarse, estas hipótesis no se cumplen estrictamente. Por ejemplo, la primera hipótesis no se cumple en lugares donde la geología presenta cierta complejidad estructural o hay grandes variaciones laterales de las propiedades físicas del medio. La segunda hipótesis establece que las trazas del dato sísmico deben ser de *offset* cero, algo experimentalmente imposible. Por otro lado, las ondas que se propagan por el subsuelo se ven afectadas por fenómenos de atenuación y dispersión, que se manifiestan en cambios en la forma y amplitud de la ondícula. Esto es equivalente a decir que la ondícula no es estacionaria. Si se quiere ser más exhaustivos, también se deberían contemplar los efectos de atenuación y dispersión debidos a la transmisión a través de las discontinuidades y reflexiones múltiples que no están siendo consideradas (Robinson y Treitel, 2002). A pesar de todas estas dificultades, es posible procesar el dato observado y realizar ciertas consideraciones adicionales (Yilmaz, 2001) para que todos estos fenómenos que nos apartan de las hipótesis mencionadas sean corregidos y el modelo convolucional resulte de utilidad.

## 2.3. Ondícula sísmica

La ondícula sísmica es el vínculo entre los datos sísmicos y la geología (Henry, 1997). Esta observación es inmediata al observar la ecuación 2.1. La idea de ondícula sísmica proviene del modelo convolucional establecido en el campo de la sismología (Zhou, 2014). Desde un punto de vista matemático, una ondícula  $w(t)$  es generalmente definida como una función que cumple con dos propiedades:

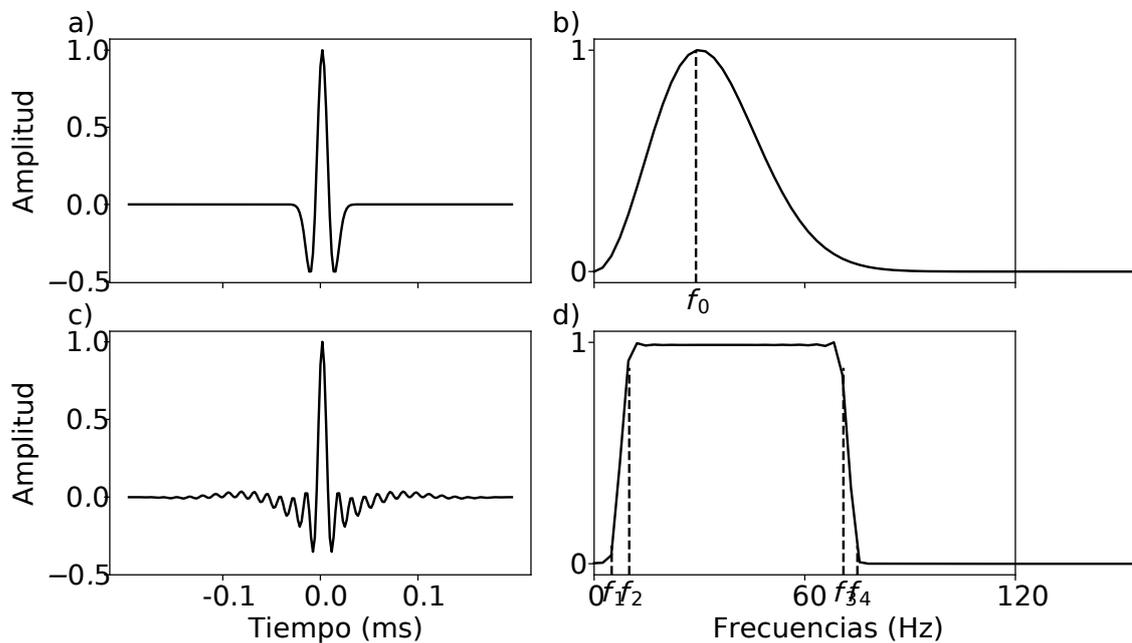
1. Causalidad:  $w(t) = 0$  si  $t < 0$ , es decir, la ondícula es nula antes del tiempo cero.
2. Estabilidad:  $\int_{-\infty}^{\infty} |w(t)|^p < \infty$ , lo que implica que su energía es finita.

Esta última condición está ligada a la duración de la ondícula, la cual no puede ser infinita.

En la bibliografía pueden encontrarse distintas ondículas teóricas utilizadas durante las etapas de procesamiento e interpretación de datos sísmicos. A continuación, se presentan dos de las ondículas comúnmente utilizadas en el flujo de trabajo sísmico y que serán empleadas a lo largo de este trabajo de Tesis.

### Ondícula de Ricker

En la Figura 2.1a se muestra una ondícula de Ricker en el dominio del tiempo. Se puede observar que es una ondícula simétrica respecto del tiempo de origen 0. Esta ondícula tiene la característica de ser de fase cero y presentar dos lóbulos laterales. Esta



**Figura 2.1.** a) Ondícula de Ricker. b) Espectro de amplitud de la ondícula de Ricker. c) Ondícula de Ormsby. d) Espectro de amplitud de la ondícula de Ormsby.

señal teórica fue introducida por Ricker en el año 1940 (Ricker, 1940), y su expresión se deriva de la segunda derivada de la distribución gaussiana de media cero:

$$w(t) = \frac{h}{1 - 2(\pi f_0 t)^2} \exp \left[ -\frac{h}{2(\pi f_0 t)^2} \right], \quad (2.2)$$

donde  $f_0$  es la frecuencia pico o frecuencia central que define de manera única a la ondícula de Ricker. En la Figura 2.1b puede verse el espectro de amplitud de esta ondícula cuyo máximo se sitúa en  $f = f_0$ , con  $f_0 = 30$  Hz en este caso.

### Ondícula de Ormsby

La ondícula de Ormsby también es una ondícula de fase cero definida como el resultado de aplicar un filtro trapezoidal a un impulso unitario. A diferencia de la de Ricker, esta ondícula presenta varios lóbulos laterales simétricos respecto de su valor máximo en el tiempo de origen. Esta ondícula queda definida a partir de cuatro frecuencias  $f_1$ ,  $f_2$ ,  $f_3$  y  $f_4$  que deben ser seleccionadas. Estos valores de frecuencia definen el espectro de amplitud de la ondícula, y si se toma la transformada de Fourier inversa, se obtiene su expresión:

$$w(t) = \frac{\pi f_4^2}{f_4 - f_3} \text{sinc}^2(\pi f_4 t) - \frac{\pi f_3^2}{f_4 - f_3} \text{sinc}^2(\pi f_3 t) - \frac{\pi f_2^2}{f_2 - f_1} \text{sinc}^2(\pi f_2 t) - \frac{\pi f_1^2}{f_2 - f_1} \text{sinc}^2(\pi f_1 t) \quad (2.3)$$

donde *sinc* es la función seno cardinal,  $f_1$  es la frecuencia baja de corte,  $f_2$  la frecuencia baja de paso,  $f_3$  la frecuencia alta de paso y  $f_4$  la frecuencia alta de corte. En la Figura 2.1c y 2.1d se muestra esta ondícula en el dominio del tiempo y de las frecuencias, respectivamente. Se puede observar que en el rango  $f_3 - f_4$  el espectro es plano y que los rangos  $f_1 - f_2$  y  $f_3 - f_4$  definen las bandas de transición del espectro. Al poder definir estos valores, se tiene control de los lóbulos laterales, ya que quedan determinados por la pendiente del espectro de amplitud.

## 2.4. Resolución sísmica

El modelo de traza presentado en la ecuación 2.1 muestra que una sección sísmica es una interacción compleja entre la ondícula y la reflectividad del subsuelo. A modo de ejemplo de esta complejidad, puede pensarse en la interferencia constructiva y destructiva de los distintos frentes de onda debido a la presencia de las distintas fuentes sísmicas y las inhomogeneidades del subsuelo.

Dado que el dato sísmico es de banda limitada, la resolución es principalmente un problema de ancho de banda en el dominio de las frecuencias de la señal (Kallweit y Wood, 1982; Robinson y Treitel, 2008; Zhou, 2014). Esto implica que existe un límite para el cual es posible resolver estructuras geológicas delgadas que sean de interés. Usualmente se consideran dos tipos de resolución: vertical y horizontal (Sheriff y Geldart, 1995; Yilmaz, 2001; Herron, 2011). La clave en el primer tipo de resolución es la longitud de onda dominante, la cual se encuentra íntimamente relacionada con la velocidad de propagación y la frecuencia principal. Por su parte, la resolución horizontal también se ve influenciada por la longitud de onda y la velocidad de propagación de la señal, y queda delimitada en la zona de Fresnel (Lindsey, 1989). Este último tipo de resolución tiene como objetivo cuantificar la capacidad de resolver características del subsuelo en la dirección perpendicular a la dirección de propagación de la onda sísmica. Mediante técnicas de procesamiento como la migración sísmica, es posible mejorar este tipo de resolución (Lindsey, 1989; Herron, 2011).

### Resolución vertical

La resolución vertical define la capacidad de resolver dos eventos cercanos en el dato sísmico en la dirección de propagación de la onda, que típicamente es la dirección vertical. Dado que la mayoría de los reservorios son pequeños en su dimensión vertical en comparación con la horizontal, la resolución vertical es a la que normalmente se le

presta mayor atención (Kallweit y Wood, 1982; Simm y Bacon, 2014). En lo que sigue de esta Tesis, al hablar de resolución, se hará referencia a la resolución vertical.

En la bibliografía pueden encontrarse diversos criterios para definir la resolución. En cada caso, los límites teóricos de resolución se relacionan con parámetros medibles en la ondícula sísmica (Kallweit y Wood, 1982; Herron, 2011). A modo de ejemplo, a partir de una analogía con la óptica física, se tiene el criterio de Rayleigh, que establece como límite de la resolución un cuarto de la longitud de onda predominante. Ricker (1953) mostró que el límite de la resolución puede determinarse mediante la segunda derivada de la ondícula sísmica, marcando como límite de la resolución un cuarto de la longitud de onda de la frecuencia predominante. Más tarde, Widess (1973) realizó un estudio donde analizó la forma de la onda obtenida al convolucionar una ondícula con dos *spikes* de igual amplitud pero distinta polaridad. En él, observó que el límite de resolución se tiene en la octava parte de la longitud de onda de la frecuencia predominante de la ondícula.

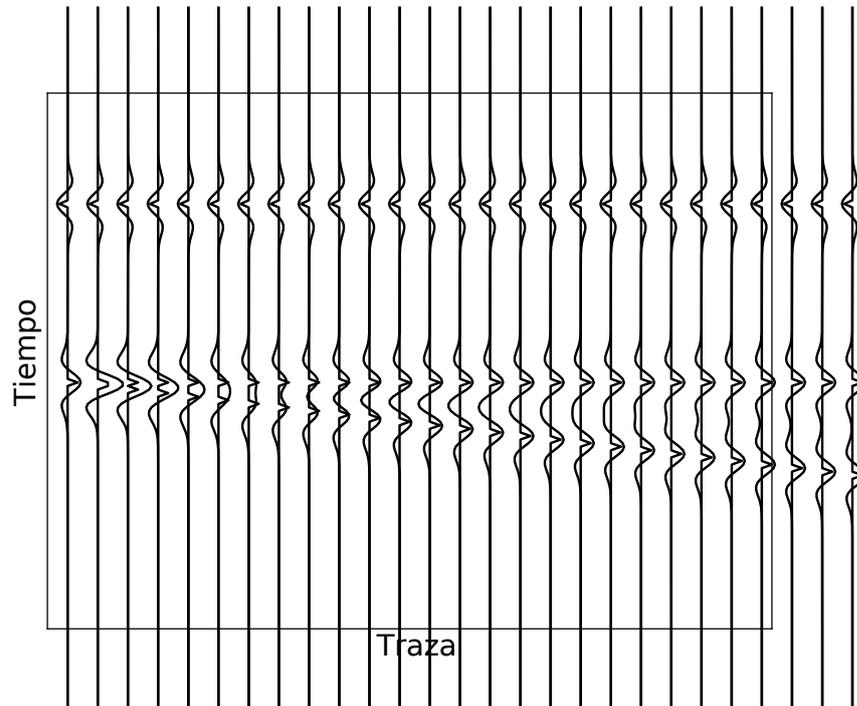
Como resultado de estos estudios, se entiende que, si se conoce la ondícula o se tiene una estimación confiable de la misma, el límite de resolución puede ser establecido. En la Figura 2.2 se muestra un modelo de subsuelo conocido como cuña, donde dos reflectores con la misma polaridad se acercan entre sí hasta convertirse en uno solo. También se muestra la respuesta sísmica al convolucionar una ondícula conocida (Ricker) con dichos *spikes*. Este tipo de estructura permite analizar la respuesta sísmica a la cuña, permitiendo, por ejemplo, determinar el espesor de la capa para el cual la amplitud sísmica de la interferencia es máxima (espesor de *tuning*) y también permite ver los distintos patrones de interferencia que suceden entre el techo y base de la estructura geológica. Se puede observar que previo al espesor de *tuning*, la respuesta de la ondícula al techo y base están separadas (se dice que el espesor está resuelto). Luego de este punto, la respuesta no cambia, pero sí decae su amplitud y ya no se pueden distinguir techo y base.

## 2.5. Resolución y ancho de banda

La medición de una señal observada se ve afectada no solo por cuestiones prácticas como la capacidad del instrumental de adquisición, sino también por ciertos principios fundamentales. Uno de ellos es que una señal compacta en el dominio del tiempo tiene un espectro de amplitud ancho, mientras que una señal de ancho de banda acotado en frecuencias tiene una representación ancha en el dominio del tiempo. Esta relación recíproca entre el ancho de banda y la duración temporal de la señal recibe el nombre de principio de incertidumbre de Gabor (Gabor, 1946). Matemáticamente, esta relación se expresa como:

$$\sigma_t \sigma_f \geq \frac{1}{4\pi}. \quad (2.4)$$

donde  $\sigma_t$  y  $\sigma_f$  son el desvío standard de las estimaciones en tiempo y frecuencia respectivamente.

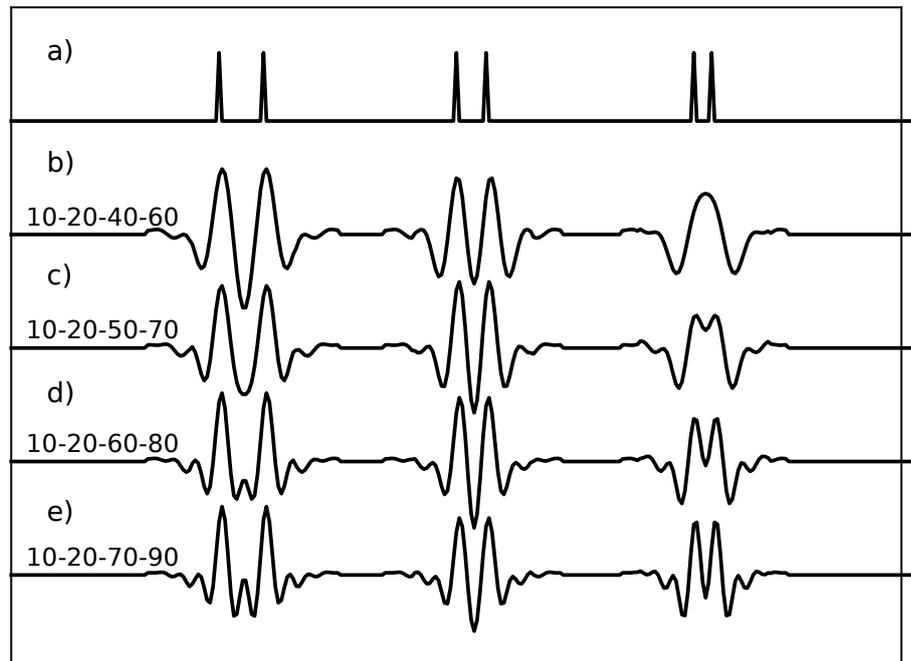


**Figura 2.2.** Resolución: Ilustración de un modelo de cuña con dos *spikes* de igual amplitud y polaridad (gris), y respuesta de la ondícula convolucionada con la reflectividad del modelo (negro) de subsuelo propuesto.

Llevando este principio al método sísmico, el principio de incertidumbre brinda una relación entre la resolución temporal y el ancho de banda de los datos sísmicos. Esto es, si se requiere una mejor resolución temporal, será necesario un mayor ancho de banda. De esta manera, datos con un gran contenido en frecuencia nos permitirán distinguir en una traza sísmica dos eventos muy próximos entre sí. A mayor ancho de banda, mejor será la distinción de los eventos. Por el contrario, si los eventos se encuentran superpuestos, estamos ante un problema de bajo contenido en frecuencias y la interpretación del dato sísmico podría verse limitada.

A modo de ejemplo, en la Figura 2.3 se muestran tres pares de coeficientes de reflexión, siendo estos más cercanos entre sí hacia la derecha (figura superior). Luego, se muestran los datos sintéticos al convolucionar dichos coeficientes con ondículas de Ormsby de distinto ancho de banda, aumentando hacia la parte inferior de la figura. Se puede ver cómo para la misma separación entre coeficientes, la resolución mejora al usar ondículas con mayor ancho de banda. Y, al igual que se observa en la Figura 2.2, para un mismo ancho de banda, se puede observar cómo interactúan los lóbulos laterales comprometiendo la distinción de los reflectores, a excepción del caso donde la distancia entre coeficientes es mayor.

En la práctica, el rango de frecuencias del dato sísmico convencional usualmente se encuentra comprendido entre 10 y 70 Hz aproximadamente (Tellier, 2015; Babasafari et al., 2019). Existen excepciones donde la señal se ve fuertemente afectada por diversos



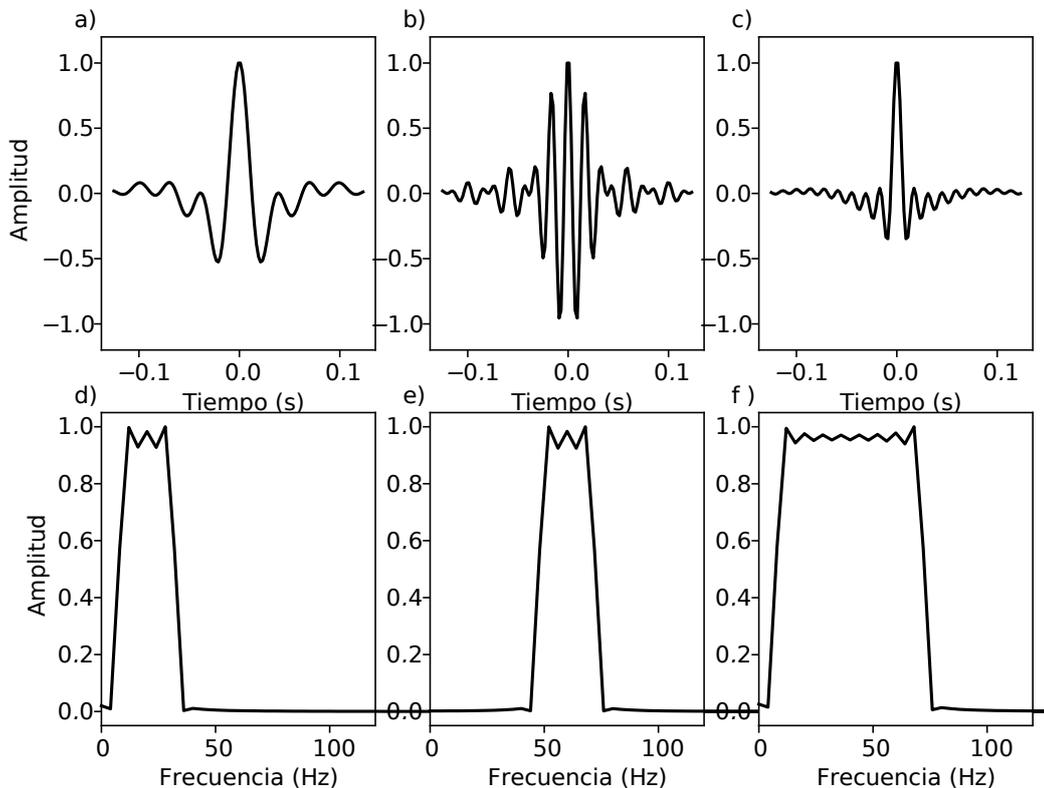
**Figura 2.3.** Ilustración de la resolución en términos del ancho de banda. A mayor ancho de banda, mejora la distinción entre los eventos, particularmente cuando están muy próximos entre sí.

factores y el rango de frecuencias es menor, lo cual se ve reflejado en imágenes donde hay una mayor dificultad para interpretar ciertas estructuras.

Un punto importante a señalar es que, para tener una buena resolución en la imagen sísmica, se debe contar tanto con altas como con bajas frecuencias. Hay un malentendido común de que solo se necesitan frecuencias altas para mejorar la resolución (Yilmaz, 2001). En la Figura 2.4a-2.4b se observan dos ondículas con el mismo ancho de banda, pero la primera con frecuencias más bajas que la segunda. La Figura 2.4c muestra la ondícula con la combinación de los dos rangos de frecuencias. Las Figuras 2.4d-2.4f muestran los respectivos espectros de amplitud. Se puede ver que la presencia de los lóbulos laterales cuando solo se tienen frecuencias altas no es mejor que en el caso del panel a. No obstante, sí se observa una mejora al tener un mayor contenido en frecuencia al combinar los anchos de banda de las dos ondículas (panel c), reforzando este concepto.

## 2.6. Relevancia de la fase de la ondícula

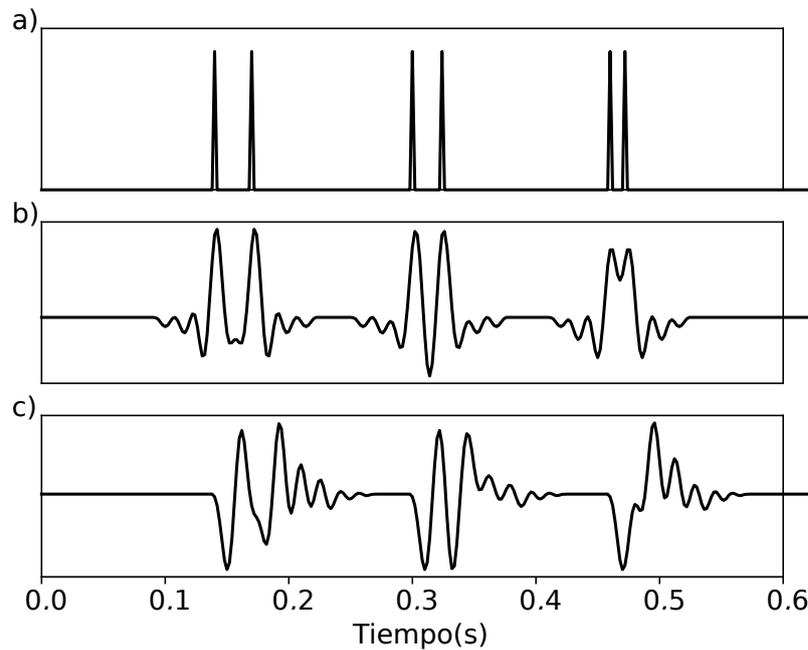
Si bien el ancho de banda está relacionado con la resolución sísmica, la fase de la ondícula también está vinculada y es un punto fundamental para mejorarla (Schoenberger, 1974; Zhou, 2014). El conocimiento de la fase se vuelve crucial a la hora de realizar una interpretación detallada de capas finas y/o reflectores cercanos (Herron,



**Figura 2.4.** Relevancia del contenido en frecuencias: ondículas de Ormsby con contenido en frecuencia bajo a), alto b) y combinación de ambos c). Paneles d)-f) muestran los respectivos espectros de amplitud.

2011). En la mayoría de los pasos del procesamiento se utiliza una ondícula de fase mínima debido a su corta duración en el tiempo. Dado que la sección final debe revelar la geología en gran detalle, en algún punto la componente de fase mínima debe ser removida para obtener una sección compuesta de ondículas simétricas, ya que estas permiten una mejor resolución desde el punto de vista estratigráfico (Yilmaz, 2001; Robinson y Treitel, 2008).

En este sentido, Schoenberger (1974) demostró mediante una serie de ejemplos sintéticos que una ondícula de fase cero (simétrica) con el mismo espectro que una ondícula de fase mínima permite resolver mejor un conjunto de coeficientes de reflexión al compararlo con dicha ondícula de fase mínima. De esta manera, una ondícula de fase cero brinda una mejor resolución del dato sísmico. En la Figura 2.5 se presentan trazas sintéticas generadas convolucionando la serie de coeficientes de reflexión con ondículas de fase cero y fase mínima. Los coeficientes de reflexión son de igual magnitud y polaridad, y aparecen de a pares, cada vez más cercanos hacia la derecha. Puede verse cómo la ondícula de fase cero en el panel b permite identificar mejor los coeficientes de reflexión en cada par de reflectores en comparación con la ondícula de fase mínima



**Figura 2.5.** Comparación de ondículas de fase mínima y fase cero con igual contenido en frecuencia: a) conjunto de coeficientes de reflexión cada vez más cercanos entre sí hacia la derecha, b) sintético creado con ondícula de fase cero y c) sintético creado con ondícula de fase mínima.

en el panel c. Además, la ondícula de fase cero también permite al intérprete vincular fácilmente los coeficientes de la reflectividad con los picos de la traza sintética.

En la práctica, si bien pueden utilizarse distintas estrategias durante la adquisición y el procesamiento para un mejor control de la fase (Trantham, 1994), difícilmente se llegue a una sección con ondículas completamente simétricas (Edgar y van der Baan, 2011). El tratamiento de la fase de la ondícula es un proceso complejo, dado que ésta varía tanto en tiempo como en *offset*, sumado a los efectos que el medio tiene sobre esta señal.

Es común encontrar desajustes de fase entre las trazas procesadas finales listas para interpretar y los sismogramas sintéticos generados a partir de información de pozos con ondículas simétricas (usualmente ondículas de Ricker). Por lo tanto, para mejorar la resolución de las imágenes y la interpretación del dato sísmico, es necesario aplicar algún tipo de corrección. En la práctica, es común rotar cada traza de la sección procesada hasta llevarla a una ondícula simétrica. Para esto, se puede utilizar alguna métrica o la inspección visual para determinar el valor óptimo de la rotación, asumiendo una hipótesis de fase constante (Robinson y Treitel, 2008). Una forma más precisa de hacer esta estimación es mediante métodos deterministas utilizando registros de pozos disponibles como control para la fase (Herron, 2011; Ma et al., 2015). También es posible utilizar métodos estadísticos, los cuales se basan en el espectro de amplitud del dato y utilizan la hipótesis de fase constante para poder estimar la misma (Bo et al.,

2013). En general, se recurre a estos métodos cuando no se cuenta con más información que el dato sísmico, aunque también pueden ser utilizados como técnicas de control para los métodos deterministas (Edgar y van der Baan, 2011).

A lo largo de esta Tesis se presentarán dos estrategias que permiten estimar la fase de la ondícula sísmica, ya que es de vital importancia en cuanto a la búsqueda de una mejor resolución sísmica.

## 2.7. Realce en frecuencias

Desde el punto de vista del procesamiento, una correcta interpretación de la geología requiere procesos digitales especiales tendientes a mejorar significativamente la capacidad de resolver estructuras relativamente pequeñas. Esto se puede lograr a partir de procesos como el realce en frecuencia de las trazas sísmicas, cuyo objetivo fundamental consiste en aumentar el ancho de banda efectivo de la señal.

Los algoritmos que permiten realizar el realce en frecuencia también pueden encontrarse en la bibliografía o en la jerga petrolera como algoritmos de extensión de ancho de banda, extensión espectral y/o realce espectral (Marfurt y de Matos, 2014). Desde hace varias décadas y hasta el presente, se ha trabajado en la investigación y desarrollo de este tipo de algoritmos para comprender mejor estos procesos y lograr diseños de filtros y operadores óptimos que permitan mejorar la resolución vertical de manera efectiva (Oldenburg et al., 1983; Yilmaz, 2001; Wang, 2009; Mamasani et al., 2017; Liang et al., 2017; Babasafari et al., 2019).

Es importante destacar que la información del contenido en frecuencias absorbido por el medio ya no se encuentra en el dato, y para recuperarla es necesario recurrir a algún tipo de hipótesis. En este contexto, se debe ser cuidadoso, ya que, si bien existen varias estrategias que permiten incrementar las altas frecuencias, no necesariamente mejoran la resolución sísmica vertical (Chávez-Pérez y Centeno-Miranda, 2013; Liang et al., 2017). Este punto hace que el uso de estas técnicas a veces pueda ser algo controversial, ya que pueden hacer que se pierda la credibilidad de dichas propuestas. Sin embargo, los métodos basados en el realce en frecuencias han funcionado muy bien en diferentes aplicaciones (Kumar et al., 2008; Kazemeini et al., 2010), particularmente aquellos basados en modelos de reflectividad de tipo *sparse-spike* (Velis, 2008; Johnston, 2010; Marfurt y de Matos, 2014; Somasundaram et al., 2015; Pérez et al., 2017).

### Técnicas de realce en frecuencia

El conjunto de algoritmos que permite realizar el realce de los datos es muy amplio. A partir de lo que se puede observar en la bibliografía, estos algoritmos pueden dividirse en dos grupos: uno donde las estrategias buscan extender el espectro efectivo dentro del ancho de banda del dato sísmico observado, y otro grupo donde el espectro se extiende más allá del ancho de banda del dato sísmico.

Dentro del primer grupo podemos encontrar técnicas como el *spectral whitening*, donde lo que se busca es aplanar el espectro de amplitud del dato. Esto se puede lograr

dividiendo el dato en bandas de frecuencia, ecualizando cada franja mediante una función de escalamiento (por ejemplo, una función de ganancia) y volviendo a sumar estos resultados. Así se obtiene una traza con mejor resolución y un espectro plano (Robinson y Treitel, 2008). Otra estrategia similar, aunque dependiente de información adicional al dato sísmico, es el *spectral blueing* (Blache-Fraser y Neep, 2004). El operador que se utiliza para aplanar el espectro se obtiene a partir de perfiles de pozos y permite recuperar frecuencias que no estaban en el dato observado, mejorando su resolución (Kazemeini et al., 2010). El balance de amplitud (*spectral balancing*) es otro método clásico en este grupo. Fue introducido en el mundo del procesamiento digital en los años 70 con el fin de mejorar la resolución sísmica (Marfurt y de Matos, 2014).

Los efectos de absorción y dispersión que sufre la ondícula a medida que se propaga por la tierra pueden describirse mediante el factor de calidad  $Q$  (Aki y Richards, 2002; Shearer, 2019). Este parámetro es una medida adimensional de la relación entre la energía media almacenada y la energía que se pierde en un período de tiempo dado. Para compensar estos efectos, se puede diseñar un filtro que contrarreste este fenómeno, dando lugar al filtro inverso  $Q$ . Este método emplea un procedimiento de propagación de onda inverso que busca compensar la energía absorbida por el terreno y corregir la deformación de la ondícula debida a la dispersión (Wang, 2009). Un filtro inverso está compuesto por dos componentes: una que busca compensar la fase y otra que busca corregir la amplitud de la onda. En la bibliografía se encuentran distintos modelos matemáticos para modelar  $Q$  de manera teórica (Wang, 2009). En la práctica, este tipo de filtro presenta dos grandes desafíos: uno es controlar la inestabilidad que se produce en la corrección de amplitud y, por otro lado, obtener una estimación adecuada de  $Q$  (van der Baan, 2012; Chen et al., 2014).

Dentro del segundo grupo de técnicas de realce se encuentran métodos que se valen de modelos e hipótesis sobre la solución buscada. Un modelo ampliamente utilizado que permite extender el ancho de banda sin límite es la reflectividad de tipo *sparse-spike*, que aparece como solución al utilizar distintas estrategias de inversión sísmica (Debye y van Riel, 1990; Velis, 2008). Como se verá en otros capítulos, el problema puede plantearse en términos de una norma que brinde soluciones *sparse-spike* y luego resolverse de distintas formas, como, por ejemplo, mediante programación lineal (Levy y Fullagar, 1981), mínimos cuadrados reponderados (Sacchi, 1997) o *basis pursuit* (Chen et al., 2001). Otra estrategia basada en un modelo *sparse-spike* es la reconvolución sísmica (*loop reconvolution*), la cual se basa en una serie de pasos matemáticos que buscan detectar y amplificar eventos importantes de la traza sísmica (Young et al., 2005). La solución que se obtiene es una reflectividad *sparse-spike*, con valores pesados a partir de una interpolación entre los valores de la amplitud máximos y mínimos de la traza sísmica. Finalmente, se puede convolucionar dicha serie reflectiva con una ondícula de mayor contenido en frecuencia. La elección de dicha ondícula queda a criterio y experiencia del intérprete. Si bien esta técnica se basa completamente en un criterio matemático y tiene poco o ningún significado geofísico, ha demostrado ser de utilidad en ciertos tipos de estudios (Welayaturromadhona et al., 2017).

Por último, para cerrar este breve resumen de técnicas de realce en frecuencia, es necesario mencionar la deconvolución. Esta es otra de las técnicas que apunta a mejorar la resolución sísmica a partir de incrementar el ancho de banda del dato (Yilmaz, 2001; Robinson y Treitel, 2002; Young et al., 2005). Históricamente, ha sido una de las técnicas más utilizadas y estudiadas para mejorar la resolución (Cary, 2006; Soldo et al., 2008). En la bibliografía pueden encontrarse distintos tipos de deconvolución, donde, según los criterios utilizados al resolver esta ecuación, podría pertenecer a cualquiera de los dos grupos propuestos (Wiggins, 1978; Debeye y van Riel, 1990; Yilmaz, 2001; Velis, 2008; Robinson y Treitel, 2008). En el siguiente capítulo se presentará esta técnica con un mayor grado de detalle.

## 2.8. Comentarios finales

En este capítulo se explicaron conceptos básicos del método sísmico y conceptos relacionados al problema de la resolución sísmica vertical. Se presentó el modelo convolucional, hipótesis fundamental para los siguientes capítulos, y las ondículas sísmicas que se utilizarán. Luego, se explicó en qué consiste el problema de resolución sísmica y, mediante ejemplos simples cómo se relaciona con el ancho de banda del dato observado. También se mostró la relación entre resolución y fase de la ondícula sísmica a la hora de realizar una interpretación sísmica. Finalmente, se presentaron algunas de las estrategias utilizadas para mejorar la resolución mediante la extensión del ancho de banda del dato. En la bibliografía puede encontrarse una amplia variedad de estrategias que utilizan esta metodología de la extensión del ancho de banda en frecuencias. Aquí se propone hacer una división en dos grupos: uno donde los métodos extienden el espectro efectivo dentro del ancho de banda del dato sísmico, y otro que permite extender dicho espectro más allá del dato sísmico. En este segundo grupo, suele utilizarse información adicional o hipótesis adicionales vinculadas con el problema. Una de las hipótesis clásicas es la de una reflectividad del subsuelo de tipo *sparse-spike*, que será utilizada en los Capítulos 4 y 6.

Debe tenerse en cuenta que existen otras técnicas de realce que podrían entrar dentro de las categorías propuestas pero no son mencionadas aquí por razones de brevedad.

# Capítulo 3

## Deconvolución sísmica

### 3.1. Introducción

La deconvolución es una técnica ampliamente utilizada en Geofísica, especialmente en los métodos sísmicos de prospección. Su objetivo principal es atenuar o eliminar respuestas sísmicas no deseadas o distorsionadas en los datos registrados, lo que se conoce comúnmente como deconvolución sísmica. En teoría, esta operación permite estimar la reflectividad del subsuelo a partir de los sismogramas observados, mejorando así la resolución temporal de los datos sísmicos (Robinson y Treitel, 2008). La deconvolución puede entenderse como el proceso inverso a la convolución, el cual genera sismogramas sintéticos al combinar una ondícula sísmica (firma de la fuente) con la reflectividad del subsuelo. Generalmente, la ondícula sísmica se estima a partir de los datos mediante diversas estrategias (Ulrych et al., 1995).

La literatura sobre la deconvolución es extensa y está en constante evolución (Peacock y Treitel, 1969; Wiggins, 1978; Debeye y van Riel, 1990; Kaaresen y Taxt, 1998; Cary, 2006; Zhang y Castagna, 2011; Menke, 2018; Pérez et al., 2024). En términos generales, la deconvolución se implementa bajo el criterio de mínimos cuadrados (Robinson y Treitel, 2008). Sin embargo, debido a factores como la banda limitada de la ondícula, el ruido y la incompletitud de los datos, el problema de la deconvolución suele estar mal condicionado. Esto implica que la solución es inestable y no es única, lo que impide una solución directa mediante la simple inversión del operador de convolución.

Para mitigar este problema, se introducen términos de regularización que no solo estabilizan la solución, sino que también permiten incorporar información *a priori*, favoreciendo soluciones con características deseadas. Inicialmente, la deconvolución se implementaba a través de la teoría de Wiener y la regularización propuesta por Tikhonov (1963), minimizando un *misfit* basado en la norma  $L_2$  para ajustar los datos observados, junto con un término de regularización basado también en la norma  $L_2$  que garantiza la estabilidad de la solución. Si bien esta aproximación mejora la resolución de las secciones sísmicas, la solución sigue estando limitada por la banda de frecuencia.

Además, diversos estudios han demostrado que la reflectividad tiende a seguir distribuciones no gaussianas más que gaussianas (Walden y Hosken, 1986; Velis, 2003;

Gholami y Sacchi, 2012). Por ello, es conveniente explorar enfoques alternativos que favorezcan este tipo de distribuciones y mejoren la resolución de los datos sísmicos, utilizando información *a priori* del subsuelo como regularización del problema inverso. En este contexto, una manera efectiva de abordar este desafío es mediante la utilización de términos de regularización que promuevan soluciones de tipo *sparse* en la serie de reflectividad sísmica. Este enfoque permite extender el ancho de banda de los datos más allá de su límite original, mejorando considerablemente la resolución (Oldenburg et al., 1983; Velis, 2008).

Este capítulo introduce el problema de la deconvolución sísmica en el contexto de esta tesis, con énfasis en la deconvolución *sparse-spike* que se utilizará en los capítulos posteriores. Se discuten los efectos de las regularizaciones cuadráticas y no cuadráticas en el proceso de deconvolución, así como los espectros de amplitud resultantes al comparar diferentes enfoques. Además, se presenta un marco bayesiano para comprender la relación entre las soluciones *sparse* y la regularización basada en la norma  $l_1$ .

## 3.2. Deconvolución sísmica

Como se explicó en la Sección 2.2, el modelo convolucional puede expresarse como la convolución entre una ondícula sísmica y una serie de coeficientes de reflexión o reflectividad. De esta ecuación se desprenden dos problemas fundamentales para la deconvolución: la estimación de la ondícula y el desarrollo de un operador matemático que permita eliminar dicha ondícula, obteniendo así la reflectividad, que es el objeto de interés.

Para lograr esto, se debe calcular un filtro  $f_k$  tal que  $f_k * w = \delta_k$ , donde  $\delta_k$  es la señal de impulso unitario. En la práctica, no es posible obtener este resultado exacto, por lo que se busca un filtro que cumpla  $f_k * w = a_k$ , donde  $a_k$  es una aproximación a la función delta en el caso ideal. Aplicando  $f_k$  a ambos lados de la ecuación 2.1, obtenemos:

$$\hat{r}_k = a_k * \kappa + f_k * \eta = r_k + (a_k - \hat{q}) * \kappa + f_k * \eta, \quad (3.1)$$

donde se desea que  $\hat{r}_k \approx r_k$ . Para ello, deben cumplirse las siguientes condiciones:

$$a_k = w_k * \hat{\kappa} \approx \hat{q} \quad (3.2)$$

y

$$f_k * \eta \approx 0. \quad (3.3)$$

Matricialmente, esto se expresa como:

$$\mathbf{Wf} \approx \mathbf{d}, \quad (3.4)$$

y

$$\mathbf{C}_n \mathbf{f} \approx \mathbf{0}, \quad (3.5)$$

donde  $\mathbf{W}$  y  $\mathbf{C}_n$  son las matrices de convolución asociadas a la ondícula y ruido, respectivamente. Ambas ecuaciones se satisfacen minimizando la siguiente función de costo:

$$J = \|\mathbf{W}\mathbf{f} - \mathbf{d}\|_2^2 + \beta \|\mathbf{C}_n \mathbf{f}\|_2^2, \quad (3.6)$$

donde  $\beta$  es un parámetro de *trade-off* que busca balancear los dos términos, y  $\|\cdot\|_2$  representa la norma  $l_2$ . El segundo término puede reescribirse como:

$$\|\mathbf{C}_n \mathbf{f}\|_2^2 = \mathbf{f}^T \mathbf{C}_n^T \mathbf{C}_n \mathbf{f}, \quad (3.7)$$

donde  $\mathbf{C}_n^T \mathbf{C}_n$  es una matriz de Toeplitz que contiene los elementos de la autocorrelación del ruido. Si se asume que el ruido es no correlacionado, podemos realizar la siguiente aproximación:

$$\mathbf{C}_n^T \mathbf{C}_n \approx \sigma_n^2 \mathbf{I}, \quad (3.8)$$

donde  $\sigma_n^2$  es la varianza del ruido e  $\mathbf{I}$  es la matriz identidad. Así, la ecuación 3.6 se puede reescribir como:

$$J = \|\mathbf{W}\mathbf{f} - \mathbf{d}\|_2^2 + \lambda \|\mathbf{f}\|_2^2, \quad (3.9)$$

donde  $\lambda = \sigma_n^2 \beta$  es un nuevo parámetro de *trade-off* que reemplaza  $\beta$ . La solución se encuentra minimizando esta ecuación, obteniéndose así el filtro inverso buscado (Tarantola, 2005):

$$\mathbf{f} = (\mathbf{R}_w + \lambda \mathbf{I})^{-1} \mathbf{W}^T \mathbf{d}, \quad (3.10)$$

donde  $\mathbf{R}_w = \mathbf{W}^T \mathbf{W}$  es la matriz de autocorrelación de la ondícula, con estructura de Toeplitz.

Si no se cuenta con una aproximación de la ondícula, es necesario introducir una hipótesis adicional, como la de reflectividad blanca. Bajo esta suposición, la reflectividad se comporta como un proceso estocástico de ruido blanco con media cero, lo que implica que su autocorrelación es proporcional a la de la ondícula. En este caso, la ecuación 3.10 se convierte en:

$$\mathbf{f} = (\mathbf{R}_s + \lambda \mathbf{I})^{-1} \mathbf{W}^T \mathbf{d}, \quad (3.11)$$

Resulta importante destacar que, debido a que todo filtro inverso es de fase mínima, la ondícula deberá ser de fase mínima. La ondícula estimada a partir de la autocorrelación es de fase cero, con lo cual se pierde la fase en este proceso y es necesario realizar ajustes para garantizar la fase mínima en el filtro inverso. Caso contrario, el filtro resultante no producirá los resultados esperados.

### 3.3. Deconvolución de tipo *sparse-spike*

El segundo término cuadrático de la ecuación 3.9, utilizado para obtener el operador de deconvolución, es conocido como el término de regularización cuadrático o de Tikhonov (1963). Este término estabiliza la solución, ya que la inversa de la matriz de autocorrelación de la ondícula puede ser inestable o inexistente, lo que daría lugar a un filtro poco útil. La regularización introduce una pequeña perturbación en la diagonal

de la matriz de autocorrelación (ver ecuación 3.10), lo cual es suficiente para garantizar estabilidad.

Además de estabilizar la solución, este término permite incorporar información *a priori* sobre la solución buscada. Esto es crucial en problemas de datos sísmicos, y en general en la teoría de inversión geofísica, ya que al resolver solo el primer término de la ecuación 3.9, se obtiene una solución no única (Menke, 2018). En el caso de la regularización cuadrática, la solución obtenida será aquella de mínima norma.

Para un caso más general, la ecuación 3.9 puede reescribirse como:

$$J(\mathbf{r}) = \|\mathbf{W}\mathbf{r} - \mathbf{s}\|_2^2 + \lambda R(\mathbf{r}), \quad (3.12)$$

donde  $R(\mathbf{r})$  representa un término de regularización, y el primer término corresponde al *misfit*. Este cambio de enfoque implica que, en lugar de buscar un filtro que convierta la ondícula en un impulso unitario, ahora se intenta estimar la reflectividad de manera que, al convolucionarla con la ondícula, ajuste a los datos observados, al mismo tiempo que presenta características deseadas impuestas por el término de regularización.

Es evidente que  $J(\mathbf{r})$  está compuesto por dos términos que imponen restricciones diferentes sobre la reflectividad buscada. El parámetro  $\lambda$  actúa como un *trade-off*, equilibrando la influencia de ambos términos. Si es grande, se prioriza la información *a priori* incorporada en el problema, mientras que si es pequeño, las características deseadas tendrán menor peso en la solución.

En particular, si  $\lambda = 0$ , la minimización de la función de costo da lugar a:

$$\mathbf{r} = (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{s}, \quad (3.13)$$

Esto equivale a no tener regularización alguna, ajustando los datos observados lo mejor posible, lo cual puede conducir a sobreajustes, comprometiendo la estabilidad del estimador de la reflectividad si  $(\mathbf{W}^T \mathbf{W})^{-1}$  es inestable.

La estabilidad se puede lograr mediante una regularización cuadrática, es decir, utilizando  $R(\mathbf{r}) = \|\mathbf{r}\|_2^2$ . En este caso,

$$J_q(\mathbf{r}) = \|\mathbf{W}\mathbf{r} - \mathbf{s}\|_2^2 + \lambda \|\mathbf{r}\|_2^2, \quad (3.14)$$

cuya minimización conduce a

$$\mathbf{r} = (\mathbf{W}^T \mathbf{W} + \lambda \mathbf{I})^{-1} \mathbf{W}^T \mathbf{s}, \quad (3.15)$$

que es la solución de mínima norma.

En caso de conocer el error esperado en el *misfit*, el valor óptimo de  $\lambda$  será aquel que iguale dicho error, manteniendo el término de regularización al mínimo. Sin embargo, este valor generalmente es desconocido y no existe un método universal para determinar el  $\lambda$  óptimo. Si se puede estimar el error, se pueden emplear métodos como el criterio de la curva-L o la validación cruzada generalizada (Farquharson y Oldenburg, 2004; Hennenfent et al., 2008; van den Berg y Friedlander, 2008). En la práctica, lo habitual es seleccionar  $\lambda$  mediante ensayo y error.

Otra forma de garantizar la estabilidad de la solución e incorporar información *a priori* en la ecuación 3.12 es mediante términos no cuadráticos, los cuales permiten obtener soluciones que representan mejor los *spikes* de la reflectividad buscada en comparación con las soluciones obtenidas con términos cuadráticos (Ulrych y Sacchi, 2005). En el contexto de la deconvolución sísmica, este tipo de soluciones se refiere a reflectividades con un bajo porcentaje de coeficientes de reflexión distintos de cero, conocidas como soluciones *sparse-spike* (Oldenburg et al., 1983; Sacchi, 1997).

Las normas de Cauchy y Huber son ejemplos de términos de regularización no cuadráticos que pueden utilizarse en la ecuación 3.12 para favorecer soluciones *sparse-spike* (Ulrych y Sacchi, 2005). Estas normas están asociadas a distribuciones de probabilidad de colas largas, que son utilizadas como distribuciones *a priori* en los modelos de reflectividad (Sacchi, 1997). Por ejemplo, la norma de Cauchy se expresa como

$$S(r) = \sum_i \ln \left( 1 + \frac{r_i^2}{\sigma^2} \right), \quad (3.16)$$

donde  $\sigma$  es una constante pequeña en relación  $\alpha$ . La minimización de la función de costo correspondiente genera

$$r = \left( \mathbf{W}^T \mathbf{W} + \lambda \mathbf{Q}(r) \right)^{-1} \mathbf{W}^T \mathbf{s}, \quad (3.17)$$

donde:

$$Q(r) = \frac{1}{\sigma^2 + r^2}. \quad (3.18)$$

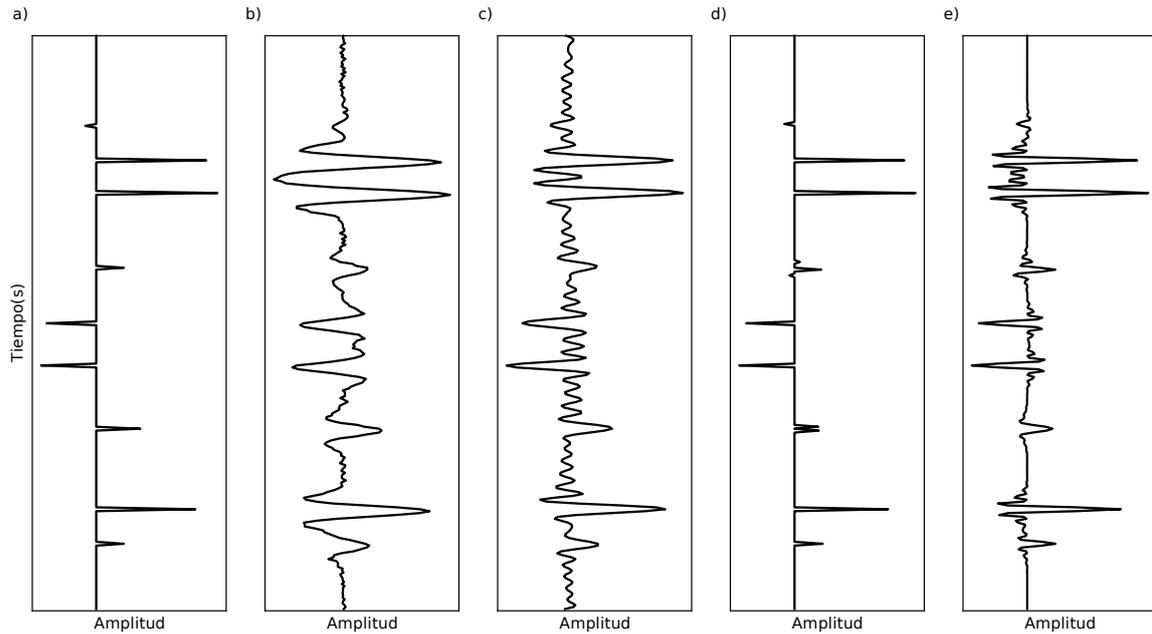
Otro tipo de norma que promueve soluciones *sparse-spike* es la norma  $l_1$  (Oldenburg et al., 1983), que se utilizará en los próximos capítulos. Con esta regularización, la función de costo se define como

$$J_{nq}(\mathbf{r}) = \|\mathbf{W}\mathbf{r} - \mathbf{s}\|_2^2 + \lambda \|\mathbf{r}\|_1, \quad (3.19)$$

donde  $\|\cdot\|_1$  es la norma  $l_1$ . Esta formulación es también conocida como el problema LASSO (*least absolute shrinkage and selection operator*) (Tibshirani, 1996; Hastie et al., 2009).

Es importante señalar que el campo de los algoritmos para minimizar eficientemente la ecuación 3.19 es amplio y sigue en constante desarrollo (Murphy, 2012). Ejemplos incluyen métodos clásicos como la *Programación Lineal* (Gass, 1958), el método de *Iterative Re-weighted Least Squares* (IRLS) (Beaton y Turkey, 1974), los *Iterative Shrinkage-Thresholding Algorithms* (ISTA) (Daubechies et al., 2004) y los *Two-Step Iterative Shrinkage-Thresholding Algorithms* (TwIST) (Bioucas-Dias y Figueiredo, 2007). Cabe destacar que el éxito de la deconvolución con regularización no cuadrática dependerá de si el modelo de reflectividad del subsuelo es verdaderamente *sparse-spike* (Sacchi, 1997).

Una vez estimada la reflectividad mediante regularizaciones no cuadráticas se puede convolucionar con una ondícula sísmica de mayor ancho de banda que la de la

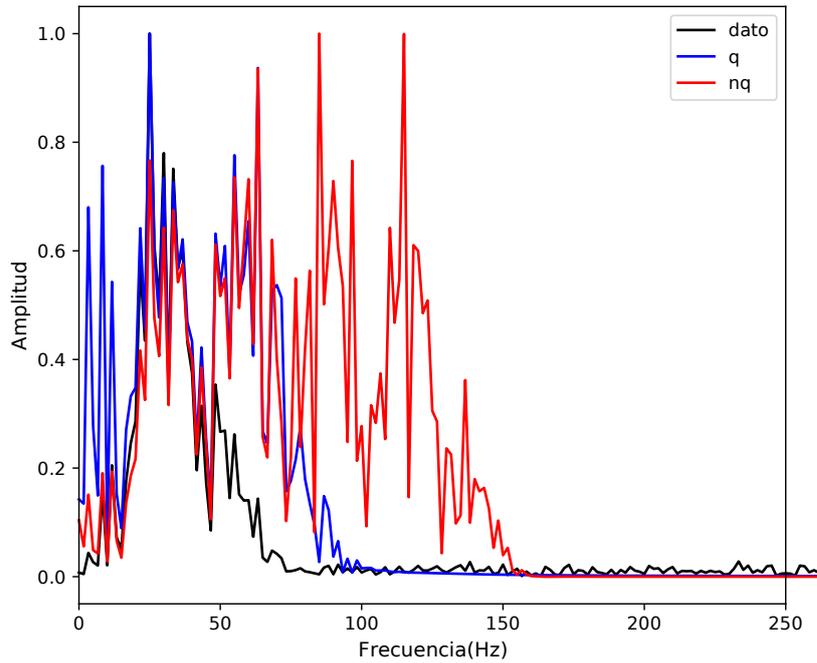


**Figura 3.1.** Ejemplo de deconvoluciones con diferentes regularizaciones: a) reflectividad, b) traza sintética, c) deconvolución con regularización cuadrática, d) deconvolución con regularización no cuadrática y e) reflectividad *sparse-spike* del panel d) convolucionada con una ondícula de mayor ancho de banda.

fuente original. Esto le otorga a la solución un carácter similar al dato sísmico para facilitar su interpretación (Marfurt y de Matos, 2014).

Como ejemplo, en la Figura 3.1 se muestra la deconvolución utilizando regularizaciones cuadráticas y no cuadráticas, y en la Figura 3.2 se presentan los espectros de amplitud resultantes. En el panel a de la Figura 3.1 se genera un modelo de reflectividad que se convoluciona con una ondícula de Ricker de 30 Hz y se le añade ruido gaussiano. Esta traza sintética se presenta en el panel b. En el panel c, se muestra la traza deconvolucionada utilizando regularización con norma  $L_2$  (Tikhonov), donde se observa cierta mejora en la definición de algunos reflectores aunque sigue siendo limitada debido al ruido y ancho de banda estrecho (Figura 3.2). En el panel d, se aplica la regularización con norma de Cauchy utilizando el algoritmo IRLS, con  $\sigma = 0.0001$  y  $\lambda = 0.0001$ . Aquí, la solución se asemeja más al modelo de reflectividad original, aunque algunos reflectores quedan subestimados y aparecen otros espurios de menor amplitud.

Finalmente, una solución más ajustada al dato sísmico observado puede lograrse convolucionando esta solución *sparse-spike* con un filtro pasabanda que posea mayor contenido de frecuencia, como se muestra en el panel e, donde se utiliza una ondícula de Ormsby con frecuencias  $f_1 = 5$ ,  $f_2 = 25$ ,  $f_3 = 100$ , y  $f_4 = 120$  Hz. En la Figura 3.2, se observa cómo el ancho de banda del espectro de amplitud se incrementa.



**Figura 3.2.** Espectros de amplitud: de la traza sintética, del dato deconvolucionado con una regularización cuadrática ( $q$ ), y del deconvolucionado con regularización no cuadrática ( $nq$ ) y aplicado una ondícula de Ormsby.

### 3.4. Relación entre la norma $l_1$ y soluciones de tipo *sparse-spike*

En la sección anterior se presentó a la deconvolución como un problema de inversión desde un punto de vista determinista. Otra forma de abordar el problema planteado por la ecuación 3.19 y que permite entender por qué la norma  $l_1$  brinda soluciones de tipo *sparse-spike* es mediante un punto de vista bayesiano. Desde esta óptica, el modelo se considera como una variable aleatoria y la solución toma la forma de una función de probabilidad asociada a los parámetros del modelo (Aster et al., 2018). El enfoque permite incorporar información *a priori* de una forma natural.

Matemáticamente, el marco teórico que permite esto es el Teorema de Bayes, que expresa la solución como una distribución de probabilidades *a posteriori* de los parámetros del modelo (Aster et al., 2018). Considerando el caso general, donde el dato se representa por  $\mathbf{d} = [d_1, d_2, \dots, d_n]$  y los parámetros de interés son  $\mathbf{m} = [m_1, m_2, \dots, m_p]$ , la función de distribución *a priori*  $\phi(\mathbf{m})$  deberá ser tal que permita incorporar la información adicional en las soluciones del modelo que se quiere estimar.

Por otro lado, la probabilidad de obtener  $\mathbf{d}$  a partir del modelo  $\mathbf{m}$  está representada por la función de verosimilitud  $\phi(\mathbf{d}/\mathbf{m})$ . Luego, mediante el enfoque bayesiano se tiene

que la distribución de probabilidad *a posteriori*  $p(\mathbf{m}/\mathbf{d})$  se puede obtener mediante

$$p(\mathbf{m}/\mathbf{d}) \propto p(\mathbf{d}/\mathbf{m})p(\mathbf{m}). \quad (3.20)$$

Un criterio para seleccionar solo un modelo es entonces escoger aquel que maximice esta función. Este modelo es conocido como *maximum a posteriori model selection* (MAP).

Una distribución *a priori* para obtener soluciones de tipo *sparse-spike* es la laplaciana con media cero, también conocida como distribución de doble exponencial (Figueiredo, 2003; Hastie et al., 2009). Para el caso de la deconvolución sísmica, notar que la distribución de amplitudes de las reflectividades se asemeja considerablemente a este modelo. Para una variable, esta distribución se expresa como

$$p(m_i) = \frac{1}{2\lambda} \exp\left(-\frac{|m_i|}{\lambda}\right), \quad (3.21)$$

donde  $\lambda$  es un parámetro de escala positivo. Asumiendo que cada  $m_i$  es independiente, la distribución de probabilidad conjunta de todos los  $m_i$  es el producto de todas las distribuciones individuales. Por lo tanto, la distribución de probabilidad *a priori* representará al vector  $\mathbf{m}$  estará dada por

$$p(\mathbf{m}) = \prod_{i=1}^N \frac{1}{2\lambda} \exp\left(-\frac{|m_i|}{\lambda}\right) = \frac{1}{(2\lambda)^N} \exp\left[-\frac{1}{\lambda} \sum_{i=1}^N |m_i|\right]. \quad (3.22)$$

Expresando el ruido como  $\mathbf{A}\mathbf{m} - \mathbf{d}$ , donde  $\mathbf{A}$  es una matriz  $N \times M$  que describe cómo los datos observados  $\mathbf{d}$  están relacionados con el modelo subyacente  $\mathbf{m}$ , y considerando que sigue una distribución gaussiana con varianza  $\sigma_n^2$ , la función de verosimilitud será una función de densidad de probabilidad gaussiana multivariada que se puede escribir como

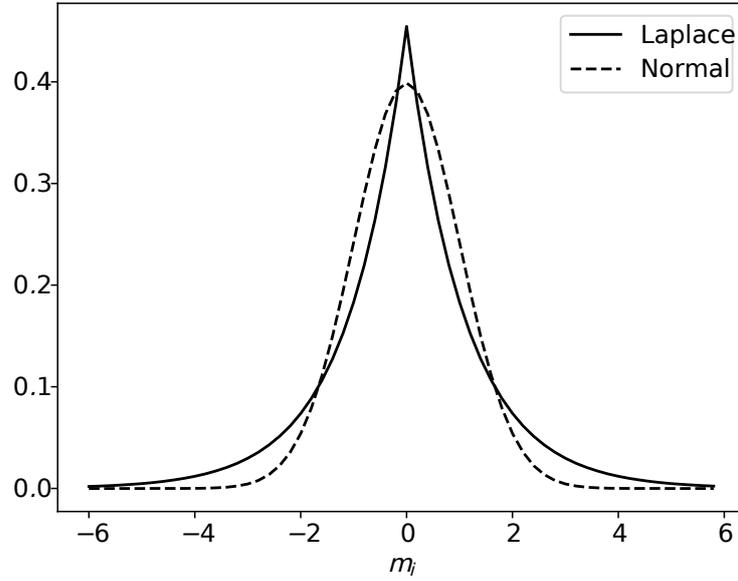
$$p(\mathbf{d}/\mathbf{m}) = \frac{1}{(2\pi)^{M/2} \sigma_n^M} \exp\left[-\frac{1}{2\sigma_n^2} (\mathbf{A}\mathbf{m} - \mathbf{d})^T (\mathbf{A}\mathbf{m} - \mathbf{d})\right], \quad (3.23)$$

Luego, mediante Bayes (ecuación 3.20) se puede obtener la función de densidad de probabilidad *a posteriori*

$$p(\mathbf{m}/\mathbf{d}) \propto C \exp\left[-\frac{1}{2\sigma_n^2} (\mathbf{A}\mathbf{m} - \mathbf{d})^T (\mathbf{A}\mathbf{m} - \mathbf{d}) - \frac{1}{\lambda} \sum_{i=1}^N |m_i|\right], \quad (3.24)$$

donde

$$C = \frac{1}{(2\lambda)^N (2\pi)^{M/2} \sigma_n^M}. \quad (3.25)$$



**Figura 3.3.** Distribuciones normal y laplaciana centradas en el origen. La primera asociada a las soluciones suaves de la deconvolución con regularización cuadrática y la segunda a soluciones de tipo *sparse-spike* mediante una regularización con norma  $l_1$  (no cuadrática).

Por lo tanto, la solución más probable será aquella que maximice esta función, lo que es equivalente a maximizar el argumento de la exponencial. Es decir

$$\mathbf{m} = \underset{\mathbf{m}}{\operatorname{argmin}} (\mathbf{A}\mathbf{m} - \mathbf{d})^T (\mathbf{A}\mathbf{m} - \mathbf{d}) + \frac{\sigma_n^2}{\lambda} \sum_{i=1}^N |\mathbf{m}_i|, \quad (3.26)$$

lo que implica minimizar

$$J(\mathbf{m}) = \|\mathbf{A}\mathbf{m} - \mathbf{d}\|_2^2 + \mu \|\mathbf{m}\|_1, \quad (3.27)$$

con  $\mu = \frac{\sigma_n^2}{\lambda}$ , que es el mismo problema planteado en la ecuación 3.19.

Es importante mencionar que las características de la distribución laplaciana son las que la hacen una buena opción para brindar soluciones de tipo *sparse*. Esta es una distribución estrecha cerca del valor medio en comparación a la distribución gaussiana (utilizada en el enfoque bayesiano que lleva a minimizar la ecuación 3.27 con regularización cuadrática (Murphy, 2012)), pero con una cola más larga, como se muestra en la Figura 3.3. Esta propiedad permite que los valores más probables sean aquellos cercanos a la media, pero sin que la probabilidad de obtener valores grandes sea demasiado baja, como ocurre con la distribución gaussiana.

### 3.5. Conclusiones

El objetivo de este capítulo ha sido presentar la deconvolución sísmica, una técnica fundamental en el procesamiento de datos sísmicos. Se mostró cómo las soluciones obtenidas varían al aplicar regularizaciones cuadráticas y no cuadráticas. Las regularizaciones cuadráticas proporcionan estabilidad, pero pueden limitar la resolución de los datos sísmicos. En contraste, las regularizaciones no cuadráticas, como la norma  $l_1$ , permiten obtener soluciones más precisas y ajustadas a modelos *sparse-spike*, incrementando la resolución y el ancho de banda de los datos, especialmente en entornos donde el subsuelo puede modelarse de esta manera. Como se pudo observar en los ejemplos, las soluciones resultan mejor definidas al utilizar regularización no cuadrática. Aplicando un filtro adecuado, es posible ajustar el resultado para asemejarlo más al dato sísmico, incrementando el ancho de banda de la señal de una manera controlada. También se abordó brevemente la relación entre la norma  $l_1$  y las soluciones de tipo *sparse-spike*, desde una perspectiva bayesiana.

# Capítulo 4

## Estimación de la ondícula sísmica

### 4.1. Introducción

En este capítulo se propone un método alternativo para la estimación de la ondícula sísmica a partir de los datos observados. Como se discutió en el capítulo 2, la ondícula constituye un elemento esencial en el flujo de trabajo del procesamiento e interpretación de datos sísmicos (Yilmaz, 2001; Robinson y Treitel, 2008; Herron, 2011). El esfuerzo suele concentrarse en la estimación de la fase de la ondícula, dado que la determinación de su espectro de amplitud no presenta mayores dificultades (Robinson y Treitel, 2002; van der Baan, 2008; Edgar y van der Baan, 2011). Obtener una estimación precisa de la fase (cuando la hipótesis de fase mínima no es aplicable) resulta crucial en procesos como el amarre de pozos, la inversión de trazas, la deconvolución y la interpretación, especialmente en análisis geológicos más detallados (Yilmaz, 2001; Lu, 2005; Herron, 2011; Yuan y Wang, 2011; Simm y Bacon, 2014).

La estimación de la fase suele abordarse de manera determinista utilizando información de pozos en la región de estudio, como se detalló también en el capítulo 2. Sin embargo, dicha información no siempre está disponible y, cuando lo está, puede ser poco confiable (por ejemplo, debido a *washouts* o mal contacto de la herramienta con la pared del pozo). Además, surge la dificultad de cómo proceder cuando pozos cercanos muestran grandes discrepancias en las estimaciones de la ondícula (Ma et al., 2015). Estas situaciones generan incertidumbre en el proceso de estimación determinística de la ondícula (van der Baan, 2008; Edgar y van der Baan, 2011; Newrick, 2012; Herrera et al., 2014).

Ante estos inconvenientes, resulta necesario y conveniente desarrollar métodos que permitan obtener una estimación confiable de la ondícula, especialmente de su fase, utilizando exclusivamente datos sísmicos. Estas estimaciones no solo aportan información complementaria, sino que también funcionan como una herramienta de control adicional (QC) al análisis clásico basado en pozos. En la bibliografía pueden encontrarse numerosas técnicas, algunas basadas en estimadores estadísticos de orden superior que capturan la información de la fase de manera adecuada (Ulrych et al., 1995; Velis y Ulrych, 1996; Edgar y van der Baan, 2011). Un ejemplo de esto son los

métodos basados en la maximización de la curtosis o *skewness*, los cuales han sido ampliamente estudiados por varios autores (Longbottom et al., 1988; Ulrych et al., 1995; Fomel y van der Baan, 2014; Ma et al., 2015). Si bien estos métodos son robustos en presencia de ruido y efectivos cuando la reflectividad es no-gaussiana, presentan ciertas limitaciones cuando el ancho de banda de la señal es relativamente estrecho o cuando la reflectividad no es suficientemente *sparse* (Velis y Ulrych, 1996).

Con el fin de superar dichas limitaciones, se presenta un nuevo método para obtener la fase de la ondícula a partir de las trazas sísmicas observadas. A diferencia de la maximización de un estadístico de alto orden en este método se busca obtener la rotación de fase constante que minimiza la norma  $l_1$  de las trazas deconvolucionadas. Esto implica que la deconvolución del dato con la ondícula apropiada permite obtener estimadores de la reflectividad cuya norma sea relativamente pequeña. La técnica propuesta se basa en dos hipótesis fundamentales: (1) la fase de la ondícula puede ser aproximada por un valor constante y (2) la serie de coeficientes de reflexión es de tipo *sparse-spike*. Bajo estas hipótesis, la deconvolución se presenta como un problema inverso regularizado mediante la norma  $l_1$ . Este proceso permite obtener estimaciones de la reflectividad de alta resolución (soluciones tipo *sparse-spike*) y recuperar la información de la fase incluso cuando el ancho de banda del dato es limitado. Además, el método puede adaptarse rápidamente para considerar la no estacionariedad de la ondícula sísmica en los datos observados. Las estimaciones obtenidas son relevantes para los métodos propuestos en los siguientes capítulos, ya que la ondícula es la base para muchas aplicaciones en el método sísmico.

Es relevante abordar ciertos aspectos relacionados con las dos hipótesis centrales de este nuevo método. Aunque pueden parecer limitantes, la hipótesis de *sparseness* ha demostrado ser eficaz en la resolución de problemas de deconvolución en diversos contextos (Taylor et al., 1979; Oldenburg et al., 1983; Sacchi, 1997; Velis, 2008; Johnston, 2010; Pérez et al., 2013, 2017, e.g.). Si bien la estructura real del subsuelo es más continua que *sparse* (Cooke y Schneider, 1983), la amplitud de los coeficientes de reflexión sigue una distribución no-gaussiana (Walden y Hosken, 1986; Velis, 2003). De este modo, el subsuelo puede ser representado mediante un modelo de capas con propiedades asociadas a distribuciones no-gaussianas, como se discutió en el Capítulo 3.

Por su parte, la hipótesis de fase constante ha sido ampliamente estudiada y aplicada en diversos problemas sísmicos, como la deconvolución, el amarre de pozos y el *zero-phasing* (Levy y Oldenburg, 1987; White, 1988; Velis, 2008; van der Baan, 2008; Edgar y van der Baan, 2011; Muñoz y Hale, 2012). Esta hipótesis permite reducir los grados de libertad en el problema de la estimación de la fase (Longbottom et al., 1988), lo que sugiere que la ondícula sísmica podría ser más sencilla de lo que se asume (Neidell, 1991).

Este capítulo describe en detalle el método propuesto para la estimación de la ondícula y explica paso a paso el algoritmo. Posteriormente, se ilustra el funcionamiento y desempeño de esta técnica mediante ejemplos 1D y 2D, basados en la minimización de la norma  $l_1$ . También se aplica el algoritmo a datos de campo, considerando la no estacionariedad de la ondícula. En todos los casos, se comparan los resultados obtenidos

con el método basado en la maximización de la curtosis. Finalmente, se presentan una breve discusión y las conclusiones más relevantes.

## 4.2. Estimación de la ondícula sísmica mediante la maximización de la curtosis

La estimación de la ondícula sísmica juega un rol crucial en el procesamiento e interpretación de datos sísmicos. En particular, la fase de la ondícula es un aspecto primordial ya que tiene un impacto directo en la calidad de los procesos de inversión (Yuan y Wang, 2011). Cuando no se dispone de información proveniente de pozos o algún otro tipo de información *a priori*, es esencial contar con un método que permita obtener estimaciones confiables. Un método clásico utilizado para obtener la ondícula bajo la hipótesis de fase constante es el basado en la maximización de la curtosis (Levy y Oldenburg, 1987; Longbottom et al., 1988; Xu et al., 2012; Fomel y van der Baan, 2014).

A diferencia de la varianza, que es un estadístico de segundo orden, la curtosis es un estadístico de cuarto orden que preserva la información de fase de la ondícula (Ulrych et al., 1995; van der Baan, 2008). Este estadístico de alto orden proporciona una medida de la cola de la distribución y puede interpretarse como una medida de no-gaussianidad. La curtosis normalizada se define como

$$k = N \frac{\sum_{t=1}^P s_t^4}{(\sum_{t=1}^P s_t^2)^2} - 3, \quad (4.1)$$

donde  $N$  es la longitud de la serie discreta  $s_t$ .

Para determinar la fase de la ondícula, se realizan una serie de rotaciones de fase constante sobre la traza, calculando el valor de la curtosis para cada ángulo. El ángulo que maximiza este estadístico, con su signo invertido, es el candidato para la fase buscada, ya que corresponde a la fase óptima que maximiza la curtosis y acerca la ondícula a una forma simétrica, como la de fase cero. Aunque la rotación de fase puede realizarse en el dominio de las frecuencias, se ha demostrado que también es posible implementarla en el dominio del tiempo, con ciertas ventajas sobre el primero (Arons y Yennie, 1950). La rotación de fase en el dominio del tiempo se lleva a cabo mediante la transformada de Hilbert generalizada:

$$s_t^{rot} = \cos(\phi) s_t + \sin(\phi) HT \{s_t\}, \quad (4.2)$$

donde  $\phi$  es la rotación de fase constante y  $HT \{ \cdot \}$  es la transformada de Hilbert (Levy y Oldenburg, 1987; Robinson y Treitel, 2002). Una vez estimada la fase, el espectro de amplitud de la ondícula buscada se estima, estadísticamente, promediando el espectro de amplitud de las trazas en alguna ventana de tiempo de interés (van der Baan, 2008).

### 4.3. Estimación de la ondícula mediante la minimización de la norma $l_1$

Dada una sección sísmica  $\mathbf{s}$  compuesta por  $n_t$  trazas y  $n_s$  muestras en la dimensión del tiempo, el objetivo es desarrollar una nueva estrategia para la estimación de la ondícula sísmica  $\mathbf{w}$  sin contar con otro tipo de información *a priori*. Para ello, es necesario considerar tres hipótesis: (1) asumir como válido el modelo convolucional; (2) la fase de la ondícula puede ser aproximada por una constante; y (3) la serie de coeficientes de reflexión  $\mathbf{r}$  asociada a cada traza es no-gaussiana y/o de tipo *sparse-spike*.

Bajo estas condiciones, la fase óptima de la ondícula se asocia con la rotación de fase constante que minimiza el promedio de la norma de las reflectividades obtenidas mediante la deconvolución *sparse-spike* (ecuación 3.19) de las trazas. La norma  $l_1$  promedio del dato deconvolucionado  $\mathbf{r}$  se puede expresar como:

$$\bar{l}_1 = \frac{1}{n_t} \sum_{j=1}^{n_r} \left( \sum_{i=1}^{n_s} |r_{ij}| \right) \quad (4.3)$$

donde  $n_r$  es la longitud de la reflectividad estimada. La deconvolución se realiza de manera independiente para todas las trazas de la sección  $\mathbf{s}$ . Como se mencionó en el Capítulo 3, esta operación puede ser vista como un problema de inversión donde, dada la ondícula  $\mathbf{w}$  y los datos observados  $\mathbf{S}$ , el objetivo es encontrar como solución la reflectividad *sparse*.

Para realizar la deconvolución *sparse-spike*, es necesario minimizar la ecuación 3.19. Esta función está compuesta por el término de *misfit* y el de la regularización. Este último permite balancear durante la optimización el ajuste entre los datos observados y calculados, además de estabilizar y mejorar el condicionamiento de la solución. También permite impartir una característica de tipo *sparse* a la reflectividad obtenida, algo esperable en modelos de reflectividad típicos del subsuelo (Walden y Hosken, 1986; Velis, 2003). El impacto del término de regularización es controlado por el parámetro de *trade-off*  $\lambda$ , el cual debe ser determinado por el usuario previamente a la inversión.

Por simplicidad, el espacio de búsqueda de la fase se recorre mediante un procedimiento de *grid search*. Esta técnica permite explorar exhaustivamente el espacio de soluciones completo, aunque podría utilizarse alguna otra estrategia más eficiente, como el método del gradiente conjugado. En cada iteración del *grid search*, la rotación de la ondícula se obtiene a partir de la transformada de Hilbert generalizada de la ecuación 4.2, reemplazando  $\mathbf{s}_t$  por la ondícula. Al igual que en el método de la curtosis, la ondícula de fase cero se obtiene calculando el espectro de amplitud promedio sobre todas las trazas disponibles y realizando la transformada inversa de Fourier. Para mejorar la estimación, se aplica una ventana de Hamming, lo que suaviza el espectro promedio obtenido y permite incluir posible información *a priori* acerca de la longitud de la ondícula (van der Baan, 2008).

A modo de resumen, para cada rotación de la ondícula se realiza la deconvolución *sparse-spike* de cada traza del dato minimizando la ecuación 3.19. Luego, se asigna el

valor medio de todas las normas  $l_1$  de las reflectividades estimadas a la correspondiente rotación de fase. Una vez completado el procedimiento de búsqueda de la fase en todo el espacio de soluciones, se elige como fase óptima aquella que conduce a la reflectividad *sparse* con el menor valor medio de la norma  $l_1$ .

Un punto importante a considerar es la tolerancia en las estimaciones de fase del método propuesto. Se sabe que las rotaciones de fase constante dentro de un rango de  $\pm 20^\circ$  no modifican significativamente la forma de la ondícula (Levy y Oldenburg, 1987; van der Baan, 2008; Ma et al., 2015). Esto hace que las rotaciones en este rango sean difíciles de percibir a simple vista. Por este motivo, se consideran como buenas estimaciones de la fase de la ondícula aquellos valores que difieran en este rango.

El algoritmo propuesto para la estimación de la ondícula mediante la minimización de la norma  $l_1$ , paso a paso, se puede resumir de la siguiente manera:

1. Fijar rango de búsqueda de la fase  $\phi_{min}$  y  $\phi_{max}$ .
2. Estimar una ondícula de prueba de fase  $\phi_0$  a partir del dato sísmico observado en una ventana de tiempo adecuada.
3. Para los valores de fase comprendidos entre  $\phi_{min}$  y  $\phi_{max}$ :
  - a) Rotar la ondícula de prueba mediante la ecuación 4.2.
  - b) Realizar la deconvolución *sparse-spike* (ecuación 3.19) de cada traza de la sección sísmica utilizando la ondícula de prueba rotada.
  - c) Calcular la norma  $l_1$  promedio (ecuación 4.3) de las reflectividades obtenidas.
4. Tomar como fase óptima aquella asociada al mínimo valor de la norma promedio.

Como puede observarse en el algoritmo, el paso 3b) requiere la minimización de la ecuación 3.19 en reiteradas oportunidades. Existen varios algoritmos para llevar a cabo esta minimización de manera eficiente. Para este trabajo se utilizó el *Fast Iterative Shrinkage-Thresholding Algorithm* (FISTA) (Beck y Teboulle, 2009). Este es un algoritmo de la familia del ISTA (*Iterative shrinkage-thresholding algorithm*) y TwIST (Two-Step Iterative Shrinkage/Thresholding Algorithms). FISTA es una extensión del algoritmo del gradiente conjugado para resolver problemas de inversión lineales de gran escala de manera simple y eficiente. En cada iteración de este algoritmo, solo se realizan operaciones de multiplicación de matrices y no de inversión de ellas. En este contexto, FISTA provee soluciones de tipo *sparse* de manera simple y efectiva. En el Apéndice A.4 se encuentra una descripción más detallada de este algoritmo.

Por último, aunque no menos importante, el parámetro de *trade-off* de la ecuación 3.19 merece especial atención. Este parámetro no es único y puede existir un rango de valores para los cuales la solución encontrada permita honrar al dato observado de manera igualmente adecuada dentro de una misma tolerancia. En la práctica, la selección de este parámetro se basa en prueba y error por parte del usuario, particularmente cuando no hay información sobre el tipo de ruido en el dato (Farquharson y Oldenburg, 2004). En el contexto de este trabajo, se muestra que hay un rango de valores de

para los cuales el mínimo de las curvas de la norma  $l_1$  es consistente, dentro de un pequeño margen de error, con el valor real de la fase de la ondícula sísmica.

## 4.4. Resultados numéricos

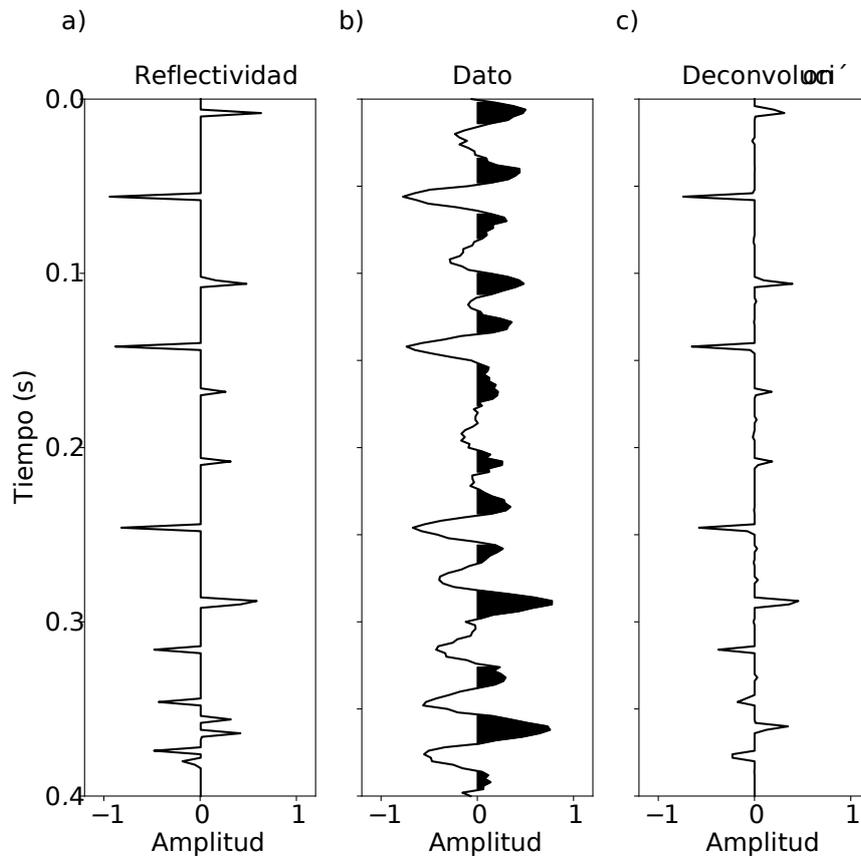
Para analizar el alcance del método propuesto en diversos escenarios, se consideraron tres ejemplos sintéticos y uno con datos de campo. El primer ejemplo con datos sintéticos busca mostrar la influencia del parámetro de *trade-off* en el desempeño del algoritmo propuesto. El segundo ejemplo presenta un análisis estadístico de la sensibilidad del algoritmo, considerando el ancho de banda de los datos y el nivel de *sparseness* de la reflectividad. Los resultados se comparan con aquellos obtenidos mediante el método clásico de la curtosis.

En el tercer ejemplo, ambos métodos se ponen a prueba utilizando datos generados a partir de una sección 2D del modelo elástico Marmousi2 (Martin et al., 2006). Es importante mencionar que en los dos primeros ejemplos, los espectros de amplitud de la ondícula se estiman directamente a partir del dato, como se explicó previamente en la Sección 4.3. En el tercer ejemplo, se utiliza el espectro de amplitud original de la ondícula. Finalmente, se presentan los resultados al aplicar ambos métodos en datos de campo, utilizando ventanas temporales para considerar la no estacionariedad de la ondícula sísmica.

### 4.4.1. Selección del parámetro de *trade-off*

En el ejemplo que sigue, se analiza el comportamiento de la fase estimada con respecto al parámetro de *trade-off*  $\lambda$ . Para aplicar el método propuesto, es necesario elegir un valor adecuado para  $\lambda$  previamente. Si este valor es muy grande, el término de regularización en la ecuación 3.19 predominará sobre el término de *misfit*, brindando soluciones que pueden no ajustarse adecuadamente a los datos observados. Por otro lado, si  $\lambda$  es demasiado pequeño, se puede terminar ajustando en exceso el dato, incluyendo ruido en la solución. Sin embargo, puede existir un rango de valores  $\lambda$  de para los cuales la solución correspondiente respeta adecuadamente los datos observados. El ejemplo muestra que para la estimación de fase no es necesario un ajuste riguroso de  $\lambda$ , ya que existe un amplio rango de valores de este parámetro para los cuales las soluciones obtenidas son aceptables. Esta característica proporciona cierta flexibilidad al usuario al seleccionar el valor de  $\lambda$ .

Para el análisis, se consideró la traza con ruido de la Figura 4.1b, la cual fue generada mediante la convolución de una serie de coeficientes de reflexión *sparse* (Figura 4.1a) con una ondícula de Ricker de 30 Hz que fue rotada  $-30^\circ$ . Luego, se agregó ruido gaussiano de banda limitada ( $S/N = 5$ ). Para cada fase en el rango de  $-90^\circ$  a  $90^\circ$ , se deconvolucionó la traza sísmica utilizando 6 valores diferentes para  $\lambda$  en el rango de 0.005 a 0.1. Las curvas de la norma  $l_1$  para las trazas deconvolucionadas con los 6 valores de  $\lambda$  mencionados se presentan en la Figura 4.2. En la Tabla 4.1 se muestran los valores de las fases estimadas en cada caso. A pesar del amplio rango del parámetro de



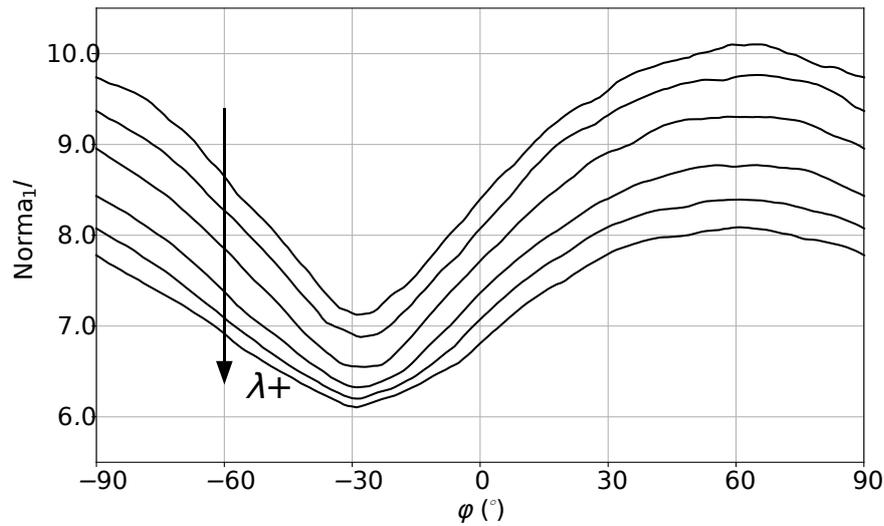
**Figura 4.1.** Ejemplo sintético 1: a) modelo de reflectividad, b) traza con ruido y c) traza deconvolucionada utilizando la ondícula con la fase estimada mediante el método de la norma  $l_1$ .

*trade-off*, se puede observar que los valores mínimos de todas las curvas se encuentran próximos al valor de fase con el que se generó el dato. Este resultado sugiere que la selección de  $\lambda$  para este algoritmo no es tan crítica a la hora de hallar una estimación correcta de la fase de la ondícula.

Finalmente, la rotación de fase óptima se obtiene seleccionando aquella que conduce al valor mínimo de la norma  $l_1$ . La correspondiente traza deconvolucionada se muestra en la Figura 4.1c. Para este ejemplo se utilizó  $\lambda = 0.05$ . Como podemos ver, la reflectividad estimada se parece a la del modelo original, aunque hay una subestimación de las amplitudes de los *spikes*. Este efecto indeseado es esperado cuando se trabaja con soluciones de tipo *sparse* (Figueiredo et al., 2007; Gramfort et al., 2013).

#### 4.4.2. Análisis de sensibilidad

En este ejemplo se realiza un análisis de la sensibilidad del método respecto al ancho de banda (BW) y el grado de *sparse* de la reflectividad. Para ello, se generan conjuntos de datos sintéticos 1D, libres de ruido, utilizando ondículas con diferentes



**Figura 4.2.** Ejemplo sintético 1: Curvas de la norma  $l_1$  para los valores  $\lambda = 0.005, 0.01, 0.025, 0.05, 0.075$  y  $0.1$ . La flecha indica la dirección en la que crece  $\lambda$ .

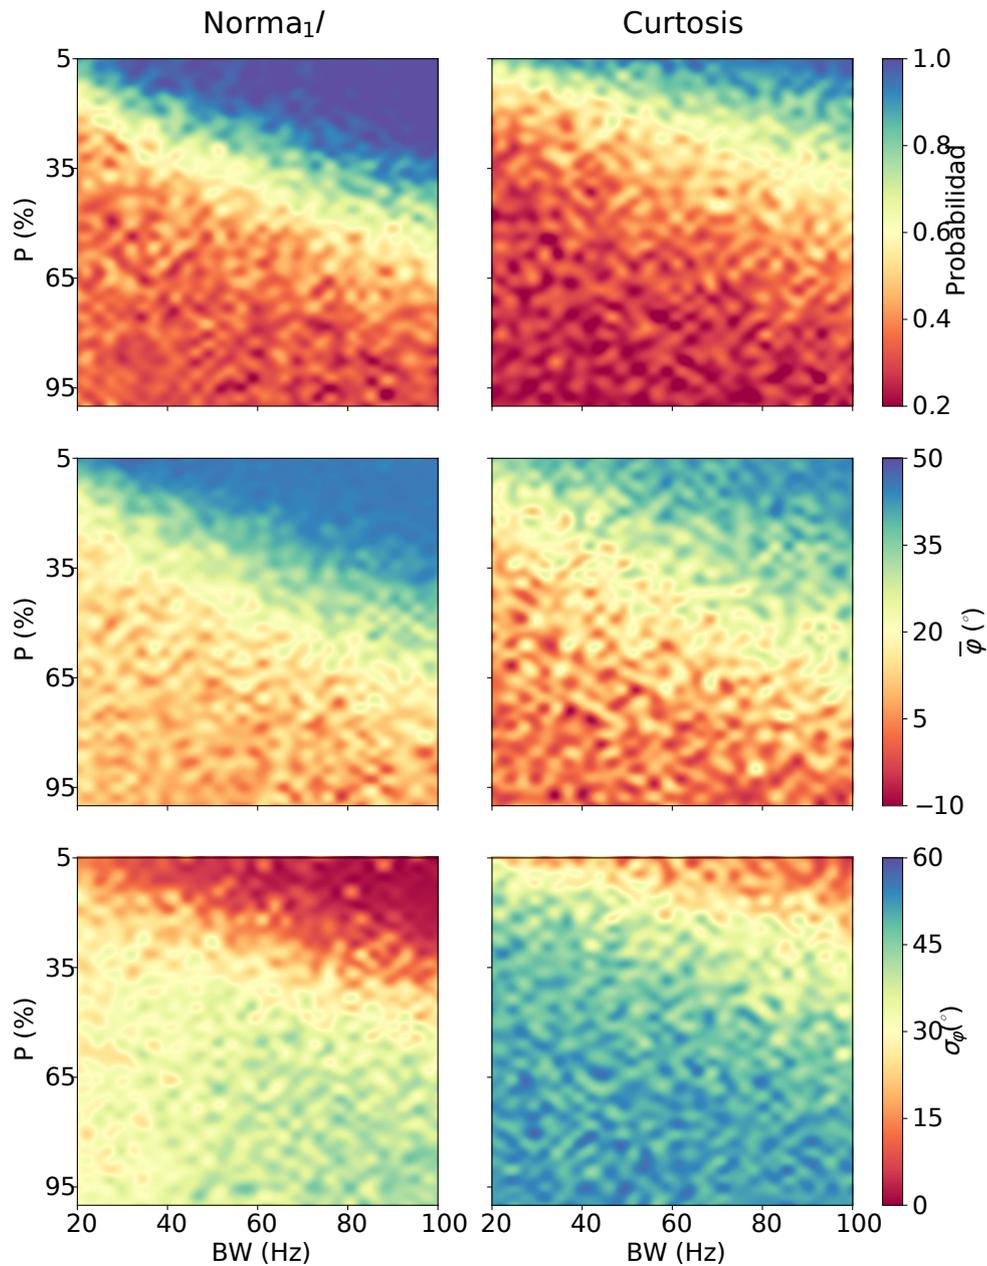
	$\phi = -30^\circ$					
$\lambda$	0.005	0.01	0.025	0.05	0.075	0.1
$\hat{\phi} (^\circ)$	-29	-28	-27	-29	-29	-29

**Tabla 4.1.** Ejemplo sintético 1: fases óptimas  $\hat{\phi}$  (en grados) para distintos valores del parámetro de *trade-off*  $\lambda$ .

anchos de banda y niveles de *sparseness*. Las reflectividades siguen un modelo Bernoulli-Gaussiano, donde el nivel de *sparseness* se cuantifica mediante el porcentaje  $P$  de coeficientes de reflexión distintos de cero. Se consideraron valores de  $P$  en el rango de 5 a 100 % y ondículas con un ancho de banda entre 20 y 100 Hz, con un paso de 2.5 para cada variable. Las ondículas fueron rotadas  $45^\circ$ . Para cada par de valores  $P$  y  $BW$ , se generaron 100 realizaciones, donde cada una consistió en crear una traza convolucionando la ondícula rotada con una reflectividad aleatoria que tuviera el nivel de *sparseness* apropiado.

Para examinar la efectividad del método propuesto para cualquier  $BW$  y  $P$  dado, se estima la fase para las 100 trazas generadas. Luego, para esas 100 soluciones encontradas, se calcula la probabilidad de estimar  $\phi$  con un rango de tolerancia de  $\pm 20^\circ$ . Este procedimiento se realizó para todos los valores de  $BW$  y  $P$  en los rangos mencionados anteriormente. Los resultados se comparan con aquellos obtenidos mediante el método clásico de la curtosis detallado previamente.

La Figura 4.3 muestra los resultados del análisis de sensibilidad propuesto. La primera fila muestra la probabilidad de estimar la fase correctamente en el rango de tolerancia admitida utilizando los métodos basados en la norma  $l_1$  y la curtosis.



**Figura 4.3.** Ejemplo sintético 2: Primera fila: probabilidad de encontrar la fase correcta dentro de una tolerancia de  $\pm 20^\circ$  utilizando los métodos de la norma  $l_1$  y el de la curtosis. Segunda fila: fases medias estimadas. Tercer fila: desvío estándar de las fases estimadas.

La segunda y tercera fila muestran las fases medias estimadas y los correspondientes desvíos estándar para cada método, respectivamente. En general, puede verse que el método de la norma  $l_1$  es más robusto que el método de la curtosis. En efecto, la región azul, donde la probabilidad de obtener la fase correcta dentro de la tolerancia

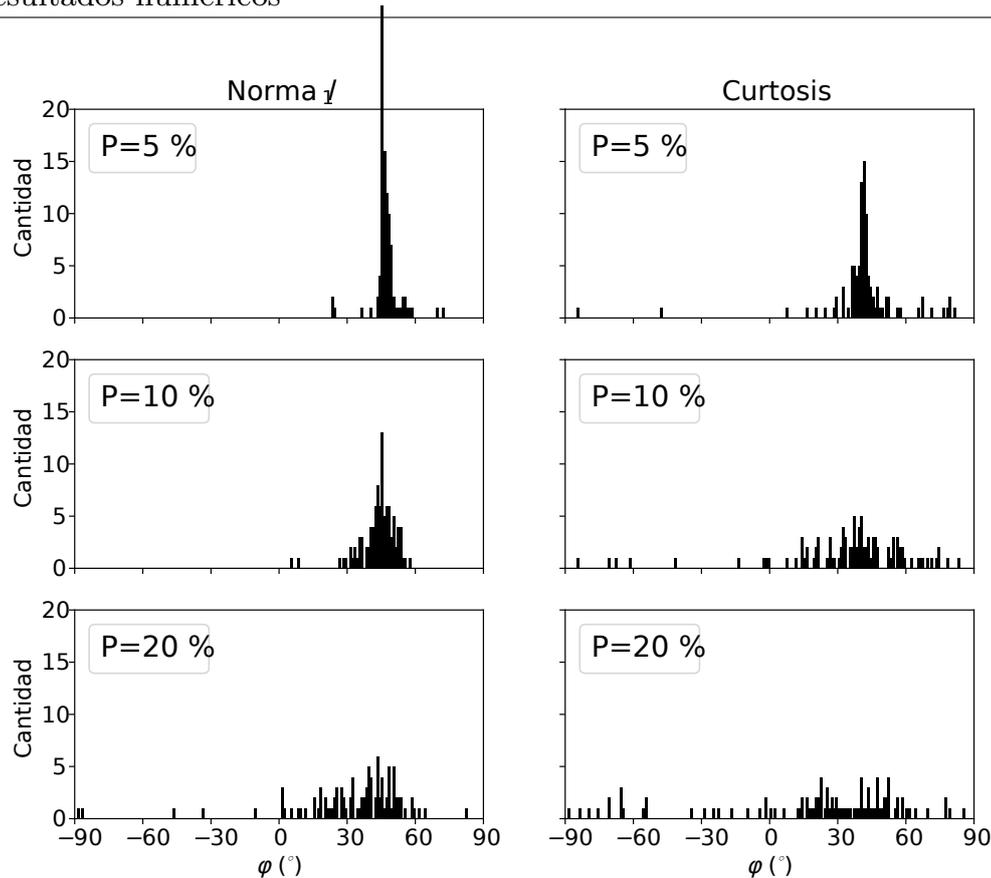
establecida es alta, es mucho mayor para la norma que para el método basado en la curtosis. Como es de esperarse, la probabilidad se incrementa al aumentar el ancho de banda y decrece cuando el valor de  $P$  aumenta en ambos casos. La segunda y tercera fila de la Figura 4.3 refuerzan esta conclusión, mostrando la ventaja del método propuesto sobre el método basado en la curtosis cuando el ancho de banda y el grado de *sparseness* del dato es relativamente bajo. Puede notarse cómo el valor medio decrece significativamente para grandes valores de  $P$  y/o pequeños valores de  $BW$ . Esto puede explicarse a partir del hecho de que en estas situaciones la distribución de las fases medias estimadas en el rango de búsqueda se convierte en uniforme (es decir, no hay información de fase), lo cual en este caso las estimaciones se centran en los cero grados. Por otro lado, mientras más grande el ancho de banda y el *sparseness* ( $P$  bajo), el pico de la distribución se encontrará más cercano a la fase verdadera, como se muestra en la Figura 4.3, segunda fila.

Simplemente por completitud la Figura 4.4 muestra los histogramas de las 100 soluciones correspondientes a  $BW = 40$  Hz y  $P = 5, 10$  y  $20$  %. Estos muestran cómo el desempeño de ambos métodos decrece a medida que el modelo de reflectividad se vuelve menos *sparse*, y viceversa. A pesar de esto, el método de la norma es más robusto que el método basado en la técnica de la curtosis, mostrando de manera consistente estimaciones de la fase más cercanas a la verdadera.

### 4.4.3. Marmousi2

En este ejemplo se pone a prueba el método propuesto en un dato sintético 2D y nuevamente se compara su rendimiento con el método basado en la curtosis. Para generar el dato sintético, se utiliza una serie de reflectividades extraídas del modelo elástico Marmousi2 (Martin et al. 2006), el cual se muestra en la Figura 4.5a. Las secciones sísmicas libres de ruido se generan convolucionando las reflectividades con ondículas de tipo Ormsby, variando el ancho de banda entre 20 y 100 Hz, y con una rotación de la fase de  $30^\circ$ . Con fines estadísticos, se crearon 100 realizaciones, a las cuales se les agregó ruido gaussiano de banda limitada ( $S/N = 3$  y  $S/N = 15$ ). Las Figuras 4.5b y 4.5c muestran dos de las secciones para  $BW = 30$  Hz y  $80$  Hz, y  $S/N = 3$ . Contrariamente a los ejemplos de las secciones 4.4.1 y 4.4.2, en esta prueba no se estima el espectro de amplitud de los datos para generar la ondícula de prueba, sino que se utiliza el espectro verdadero con el fin de evitar errores asociados a la estimación del mismo y focalizar el análisis en la obtención de la información de fase únicamente.

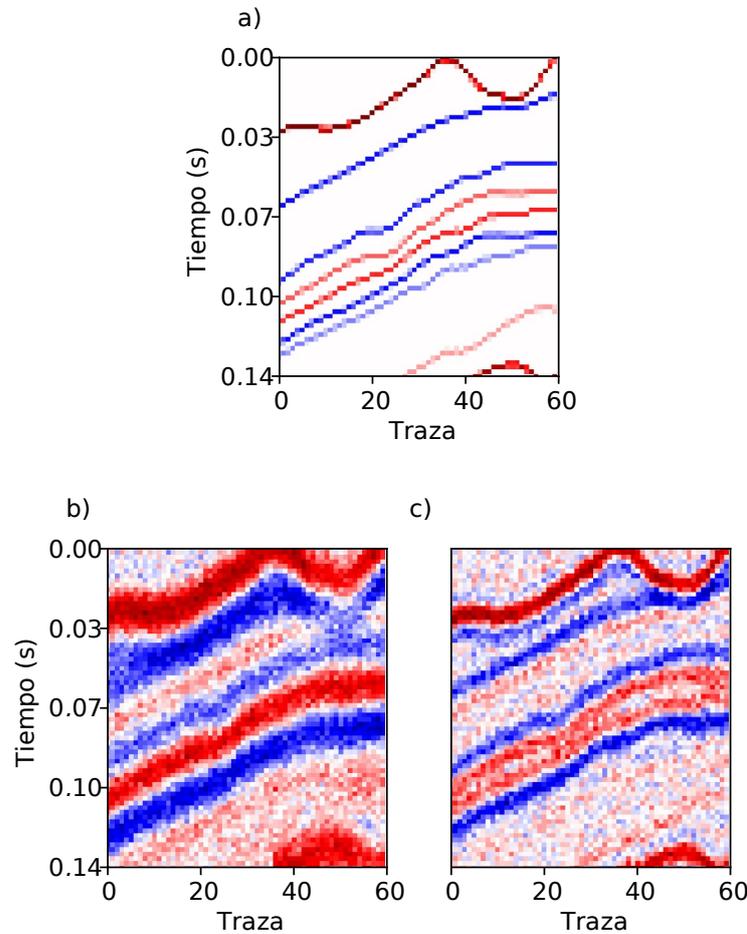
Los resultados se muestran en la Figura 4.6. El primer panel muestra las fases estimadas para el caso libre de ruido. Aunque la mayoría de las soluciones se encuentran en el rango de  $\pm 20^\circ$  alrededor del valor verdadero de la fase en ambos métodos, los resultados obtenidos con la norma son más precisos que los obtenidos con el método de la curtosis. Esto es particularmente evidente para datos con un ancho de banda bajo. Esto puede apreciarse para todos los datos con distinto ancho de banda, siendo muy precisa incluso para valores bajos del ancho de banda. Los paneles b y c de la Figura 4.6 muestran las fases medias estimadas y sus correspondientes valores del desvío standard para las 100 realizaciones. Como es de esperarse, la precisión de las



**Figura 4.4.** Ejemplo sintético 2: histogramas de las estimaciones de la norma  $l_1$  y la curtosis para  $BW = 40$  Hz y distintos valores de  $P$ .

soluciones mejoran cuando se incrementa el ancho de banda y la relación señal ruido. Aún así, en ambos casos las soluciones medias estimadas utilizando la norma  $l_1$  superan aquellas obtenidas mediante la curtosis, para todos los valores de  $BW$ . En contraste, las soluciones obtenidas con el método de la curtosis presentan valores del desvío standard menores que los obtenidas con la técnica de la norma  $l_1$ . Así, para un cierto ancho de banda y  $S/N$ , el método de la curtosis muestra ser más robusto que el método de la norma  $l_1$ . Por otro lado, sus soluciones tienen un mayor *bias*, especialmente para valores bajos del ancho de banda.

Con fines meramente ilustrativos la Figura 4.7 muestra las deconvoluciones de tipo *sparse-spike* de las secciones sísmicas mostradas en las Figuras 4.5b y 4.5c con las ondículas estimadas por cada método. En todos los casos, la deconvolución se llevó a cabo utilizando un valor de  $\lambda = 0.01$ . Puede observarse una leve mejora al utilizar la fase estimada con el método de la norma  $l_1$  sobre la fase estimada con la técnica de la curtosis en el caso de  $BW = 30$  Hz. En el caso de  $BW = 80$  Hz, las diferencias son despreciables a simple vista.

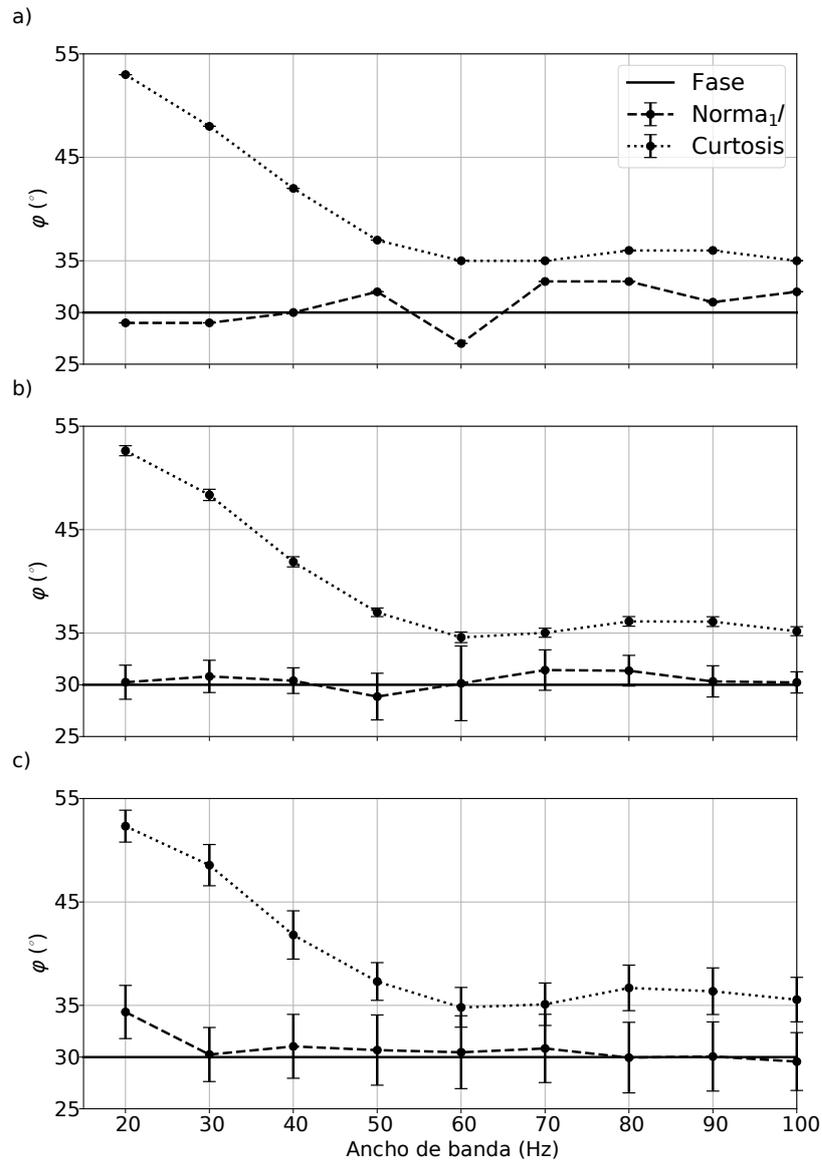


**Figura 4.5.** Ejemplo sintético 3: prueba a) modelo de reflectividad extraído del Marmousi2, b) sección con  $BW = 30$  Hz, c) sección con  $BW = 80$  Hz. En ambos casos,  $S/N = 3$ .

#### 4.4.4. Datos de campo

En este último ejemplo se pone a prueba el algoritmo propuesto frente a datos de campo. La sección sísmica en la Figura 4.8a contiene 200 trazas cubriendo un intervalo de tiempo de 1.6 s con un intervalo de muestreo de 2 ms. Como se explicó previamente, la Tierra no es un medio elástico perfecto, y la ondícula sufre diferentes procesos que generan cambios en sus propiedades estadísticas a medida que se propaga por el subsuelo. En otras palabras, la ondícula no es estacionaria.

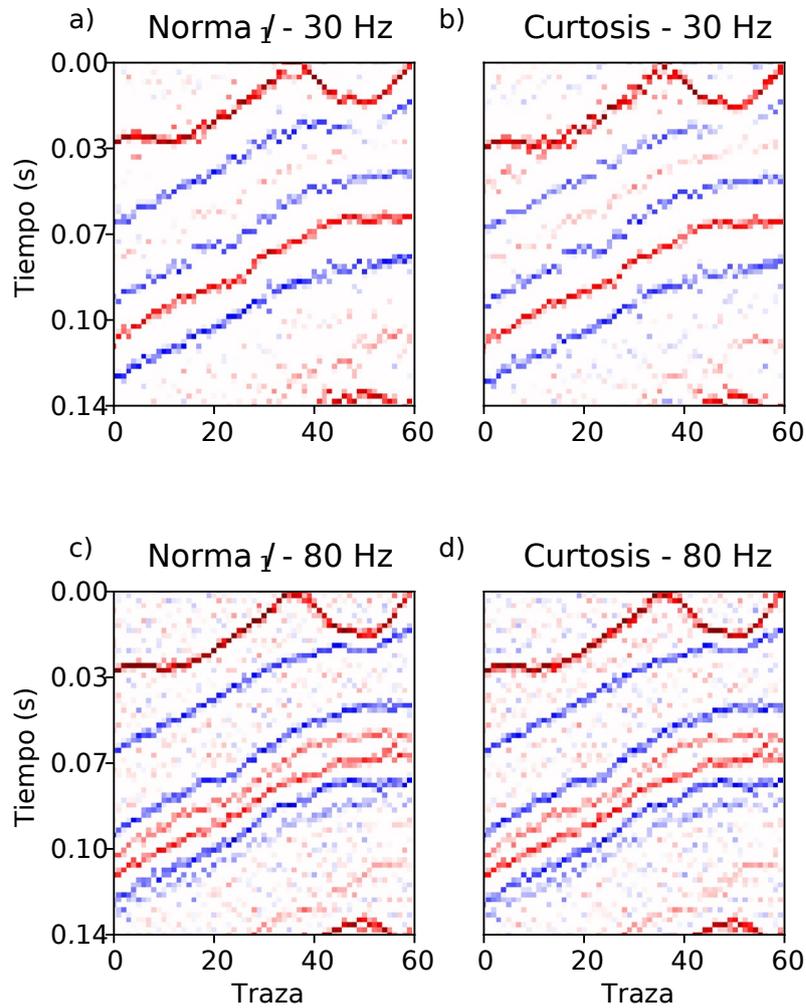
Para considerar este fenómeno, se utilizó una estrategia similar a la empleada por van der Baan (2008), donde se estiman ondículas individuales en ventanas temporales que se solapan, cubriendo diferentes rangos de tiempo y asignando el valor de la fase estimada al centro de la ventana de análisis. En este ejemplo, se seleccionaron ventanas de tiempo de 0.8 s con un solapamiento de 0.4 s, cubriendo así toda la sección sísmica.



**Figura 4.6.** Ejemplo sintético 3: desempeño de la norma<sub>1</sub> y la curtosis: a) dato libre de ruido, b)  $S/N = 15$  y c)  $S/N = 3$ .

La Figura 4.10 muestra las ondículas estimadas por cada método y la Tabla 4.2 los valores correspondientes. Se observa que las estimaciones en la segunda y tercera ventana son similares, con diferencias en las fases por debajo de los  $25^{\circ}$ . Sin embargo, la diferencia en las fases estimadas por cada método para la primera ventana es cercana a  $80^{\circ}$ . Esta discrepancia se refleja en las secciones deconvolucionadas de las Figuras 4.8b y 4.8c, donde las mayores diferencias se encuentran en los reflectores entre 0.3 y 0.4 s.

La Figura 4.9 muestra en detalle las regiones indicadas con rectángulos negros en la Figura 4.8. Estas secciones, resultado de la deconvolución *sparse-spike*, fueron obtenidas luego de minimizar la ecuación 3.19 con  $\lambda = 0.75$  y utilizando las ondículas

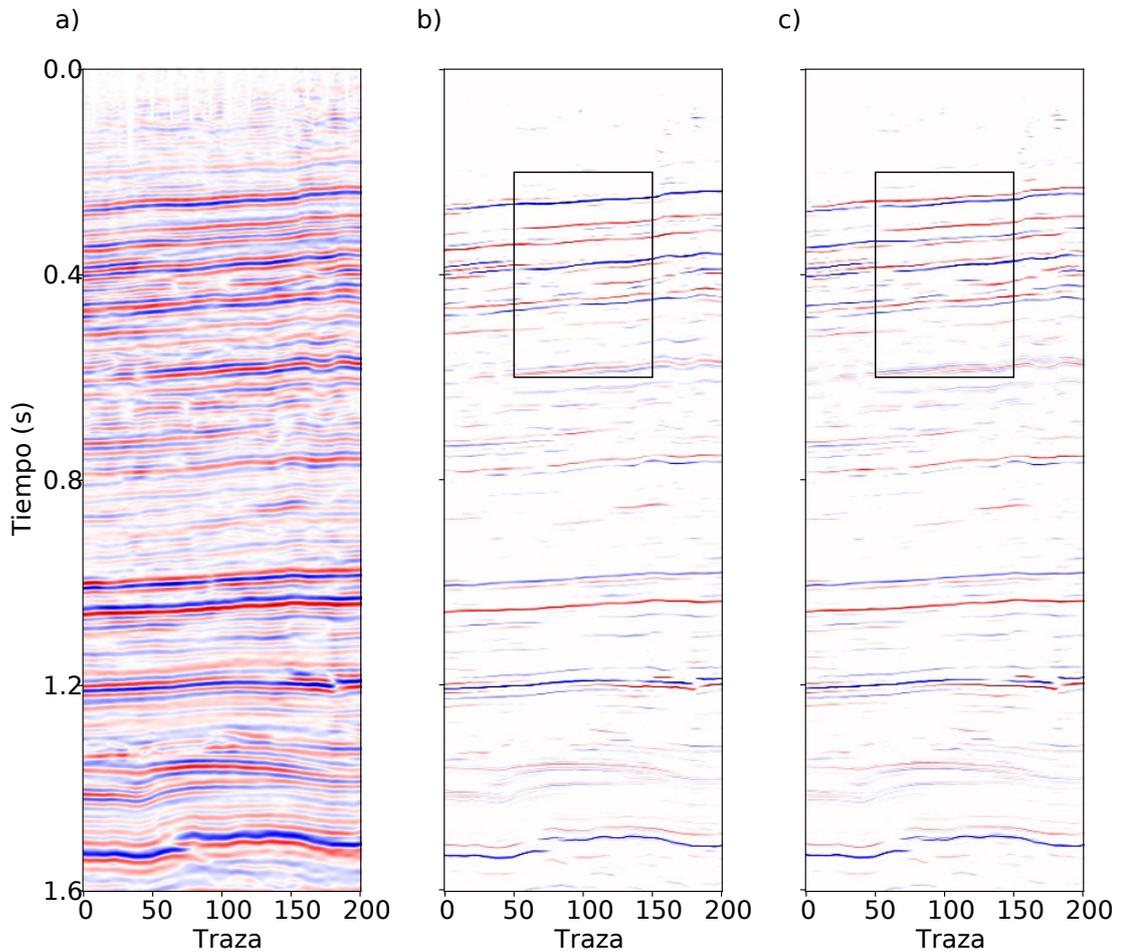


**Figura 4.7.** Ejemplo sintético 3: deconvoluciones *sparse-spike* para los casos con  $BW = 30$  Hz (primer fila) y  $80$  Hz (segunda fila).

estimadas de la Figura 4.10. Finalmente, la Figura 4.11 muestra los resultados para una sola traza (traza #100) en el medio de la sección. Se observa que la deconvolución resultante utilizando las ondículas estimadas con el método de la norma  $l_1$  es más *sparse* y muestra reflectores mejor definidos que la traza deconvolucionada utilizando las ondículas obtenidas con el método basado en la curtosis.

## 4.5. Discusión

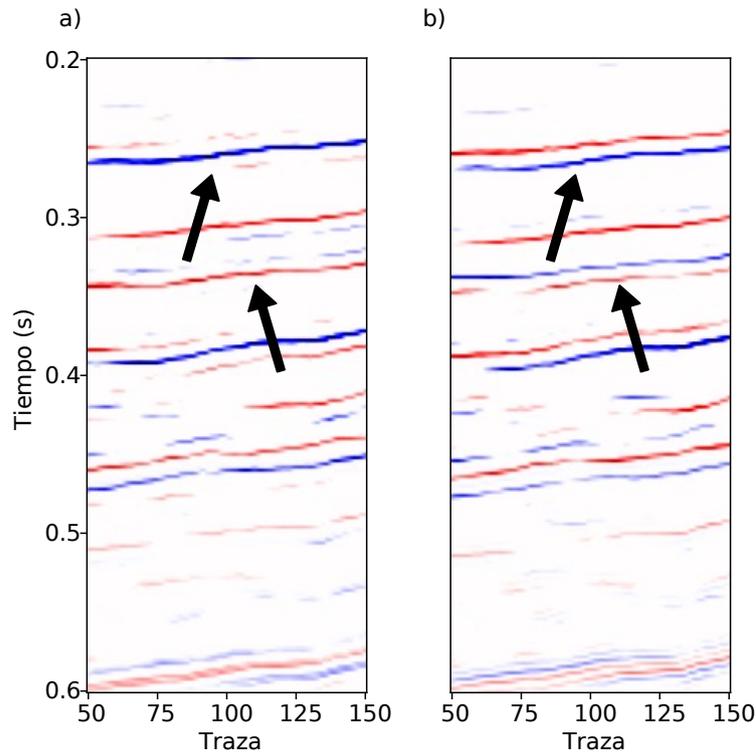
Una particularidad importante de la ondícula sísmica es su no estacionariedad. En el estudio de los datos de campo, se utilizó una estrategia que permite incorporar este fenómeno, asumiendo que la ondícula varía suavemente en el tiempo. De esta manera, la ondícula puede considerarse estacionaria dentro de ventanas temporales específicas.



**Figura 4.8.** Ejemplo dato de campo: a) Sección sísmica; b) y c) deconvoluciones *sparse-spike* utilizando las ondículas estimadas mediante los métodos de la norma  $l_1$  y la curtosis, respectivamente.

Existe una relación entre la longitud de las ventanas y la no estacionariedad de la ondícula; el uso de ventanas temporales superpuestas puede servir como herramienta de control para obtener ondículas confiables. Si se observan cambios abruptos en la estimación de la fase entre ventanas consecutivas, esto podría indicar que la estimación no es precisa.

Otro aspecto relevante es que el método propuesto se basa en la hipótesis de que la fase de la ondícula puede asumirse constante. En análisis previos, se ha observado que las estimaciones de fase de las ondículas sísmicas, derivadas de información de pozos, suelen tener fases aproximadamente constantes (Longbottom et al., 1988). Además, cuando se considera la no estacionariedad de la ondícula, esta hipótesis permite obtener resultados comparables a técnicas más complejas que permiten cambios en la fase (Edgar y van der Baan, 2011). Esto refuerza la validez de la hipótesis utilizada en el método propuesto.

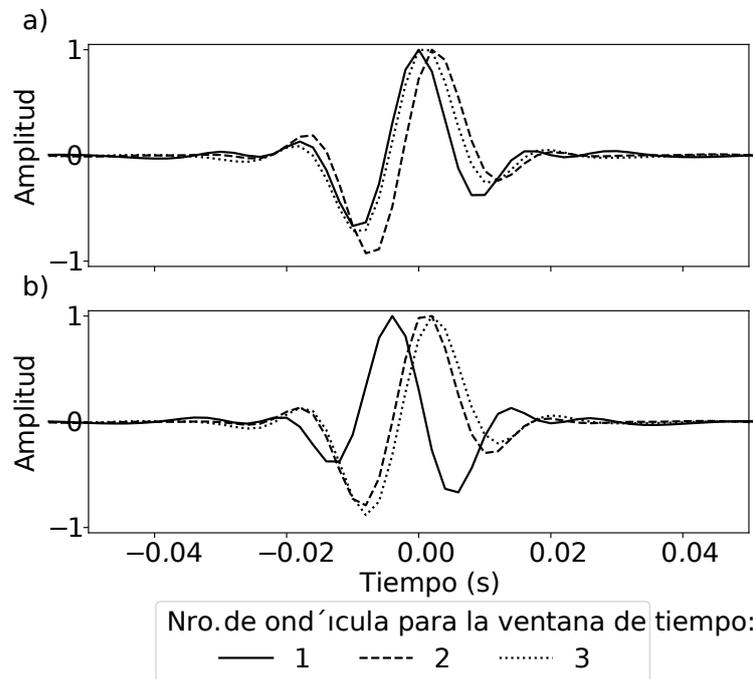


**Figura 4.9.** Ejemplo dato de campo: regiones indicadas en los rectángulos blancos en la Figura 4.8: a) norma  $l_1$  y b) curtosis. Las flechas negras indican las principales diferencias entre las dos soluciones obtenidas.

## 4.6. Conclusiones

En este trabajo se ha presentado un método alternativo para estimar la fase de la ondícula directamente a partir del dato sísmico, sin necesidad de información adicional. El método asume que la reflectividad del subsuelo es no-gaussiana y que la fase de la ondícula es constante. La fase óptima se estima buscando la deconvolución *sparse-spike* de la traza con la menor norma  $l_1$ . Se ha demostrado que las estimaciones de la fase pueden ser imprecisas cuando la reflectividad es muy poco *sparse*. A pesar de esto, el método propuesto ofrece buenas estimaciones para reflectividades con un moderado grado de *sparseness*.

El método ha sido probado en datos sintéticos 1D y 2D bajo diversos niveles de ruido, ancho de banda y grados de *sparseness* de la reflectividad. En todos los casos, el método propuesto ha mostrado estimaciones más consistentes y precisas que las obtenidas mediante la técnica clásica de la curtosis. Sin embargo, el método de la curtosis ha demostrado ser más robusto al ruido, aunque a costa de producir estimaciones con cierto sesgo respecto al valor real de la fase, especialmente en condiciones de bajo ancho de banda y grado de *sparseness*.

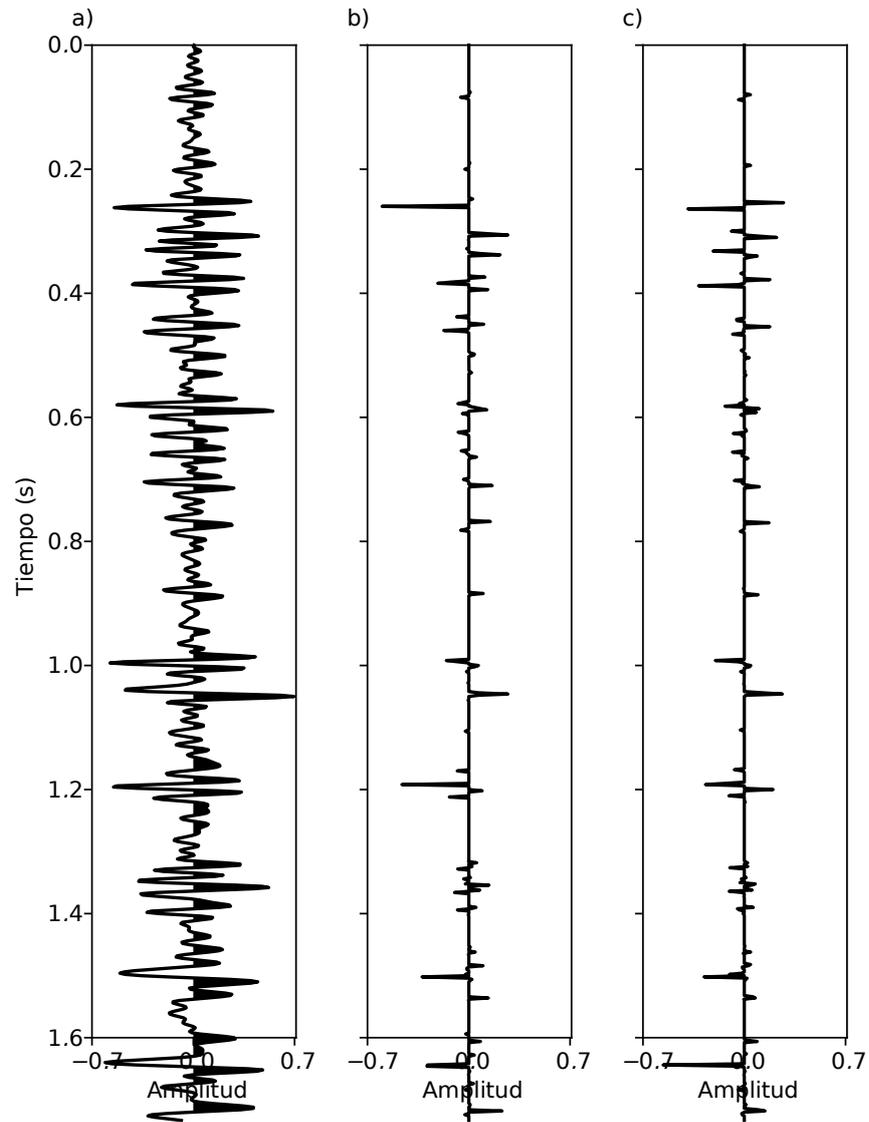


**Figura 4.10.** Ejemplo dato de campo: ondículas estimadas en cada ventana de análisis utilizando a) la norma  $l_1$  y b) la curtosis.

Ventana Temporal	Norma $l_1$	Curtosis
1	-38	38
2	-83	-58
3	-53	-76

**Tabla 4.2.** Ejemplo dato de campo: fases estimadas por cada método en cada ventana solapada (en grados).

Finalmente, se ha ilustrado el método utilizando datos de campo y ventanas temporales para considerar la no estacionariedad de la ondícula. Se ha demostrado que las estimaciones de la fase obtenidas mediante la norma  $l_1$  producen reflectividades más *sparse* y mejor definidas que aquellas obtenidas utilizando el método de la curtosis. Esto permite obtener imágenes sísmicas más confiables y con mayor resolución.



**Figura 4.11.** Ejemplo dato de campo: a) traza 100; b) y c) deconvolución *sparse-spike* utilizando las ondículas estimadas por medio de los métodos de la norma  $l_1$  y la curtosis, respectivamente.

# Capítulo 5

## Amarre de pozos y estimación de la fase de la ondícula sísmica

### 5.1. Introducción

El amarre de pozos (*well-tying*) y la estimación de la ondícula sísmica particularmente su fase, son dos etapas fuertemente relacionadas y fundamentales para el procesamiento e interpretación de datos sísmicos (e.g. Ulrych et al., 1995; Ziolkowski et al., 1998; White y Simm, 2003). Su correcta implementación es crucial para obtener valores de correlación aceptables entre los rasgos geológicos de una zona de estudio y los datos sísmicos obtenidos allí. Esto es vital para diversos procesos, como la inversión sísmica (e.g. Herron, 2011; Yuan y Wang, 2011; Simm y Bacon, 2014).

El proceso de amarre de pozos implica la comparación entre un sismograma sintético, creado a partir de perfiles de pozos y una ondícula sísmica dada, con las trazas sísmicas observadas en la cercanía de dicho pozo. La calidad del amarre, usualmente medida por el coeficiente de correlación entre ambas trazas, depende de la disponibilidad de perfiles de pozo confiables y buenas estimaciones de la ondícula (Anderson y Newrick, 2008; Herrera y van der Baan, 2014; Herrera et al., 2014; Wu et al., 2017). Un primer amarre puede realizarse aplicando, manualmente, un corrimiento de tiempo (*time-shift*) al dato sintético generado a partir del perfil de pozo y ondículas *ad-hoc*, como podría ser una ondícula de Ricker de fase cero (Newrick, 2012; White y Simm, 2003; Bianco, 2016). Con frecuencia, este primer amarre se ve afectado por factores como la dispersión de la velocidad, haciendo que el resultado no sea aceptable. Por lo tanto, además de aplicar *time-shifts*, también es necesario recurrir a un estiramiento (*stretching*) y/o acortamiento (*squeezing*) del sismograma sintético hasta que el amarre sea satisfactorio. Esto implica modificar en pequeña cantidad el perfil sónico observado (Anderson y Newrick, 2008; Herrera y van der Baan, 2014). Con el fin de mejorar aún más la correlación, puede ser necesario aplicar rotaciones a la fase de la ondícula, asumiendo que esta es aproximadamente constante. Es sabido que la selección de la ondícula tiene un impacto significativo en el sismograma sintético final (Anderson y Newrick, 2008). Mientras la estimación del espectro de amplitud no presenta grandes dificultades, la

estimación de la fase que mejore la correlación puede ser una tarea difícil (e.g. Robinson y Treitel, 2002; Ulrych et al., 1995).

En la bibliografía pueden encontrarse distintas estrategias para mejorar el amarre manual de pozos (e.g. Walden y White, 1984; White y Hu, 1998; Ziolkowski et al., 1998; White y Simm, 2003; Duchesne y Gaillot, 2011; Edgar y van der Baan, 2011; Qi y Hilterman, 2017). Usualmente, estos procedimientos incluyen varias etapas de interpretación, presentando un considerable error humano acumulado (Muñoz y Hale, 2012). Además, estos procesos consumen mucho tiempo y, en ciertos casos, resultan frustrantes para el usuario. Con el fin de superar estos inconvenientes, se desarrollan nuevas estrategias para realizar el amarre de forma automática. Como ejemplo, se pueden mencionar los trabajos de Herrera et al. (2014) y Muñoz y Hale (2015), quienes utilizan *Dynamic Time Warping* (DTW) (Berndt y Clifford, 1994), un algoritmo originalmente introducido para comparar patrones de habla en el reconocimiento de voz automático (Mueller, 2007). En el contexto del amarre de pozos, DTW es un algoritmo capaz de deformar, mediante estiramiento y/o acortamiento del dato sintético para ajustarlo al dato sísmico observado con alta precisión (Herrera y van der Baan, 2014). Este algoritmo puede restringirse convenientemente para evitar soluciones sin significado físico. Alternativamente, Herrera et al. (2014) se basan en el atributo de similaridad local (LSIM) propuesto por Fomel (2007) para obtener información acerca de los *time-shifts* necesarios para corregir el dato sintético. Similar a DTW, esta aproximación permite crear una función de deformación (*warping function*) que luego se utiliza para transformar la traza sintética a la escala temporal de la traza observada. El algoritmo utiliza filtros para controlar la cantidad de estiramiento y/o acortamiento del dato sintético, y por ende del perfil sísmico. Aunque estos métodos son efectivos para obtener altos valores del coeficiente de correlación con poca supervisión, tanto DTW como LSIM pueden llevar a deformaciones no deseadas de la forma de onda si la *warping function* no está suficientemente restringida.

En el presente capítulo se presenta una estrategia alternativa para realizar el amarre automático entre el dato sintético y la traza sísmica observada, preservando la forma de onda. Además, de ser necesario, el método permite obtener en simultáneo una estimación de la fase de la ondícula, la cual se asume como una variable adicional. El método propuesto perturba iterativamente el perfil de velocidades y la fase de la ondícula sísmica de manera que la correlación entre el nuevo sintético y la traza sísmica mejore con las iteraciones. La velocidad del perfil se perturba aplicando una función construida a partir de una interpolación de *splines* cúbicos monótonos con un número fijo de nodos. Se utiliza *Differential Evolution*, un algoritmo iterativo de optimización global, para encontrar la amplitud óptima de los nodos de la función de deformación y la rotación de fase de la ondícula. Una ventaja de este método, en contraste con el amarre manual y los procesos automáticos mencionados, es que el sintético final no se deforma durante el proceso de amarre, ya que lo que se deforma es el perfil de velocidades antes de generar el sismograma sintético y no este en sí mismo. Es decir, el estiramiento y acortamiento de la señal se obtienen intrínsecamente modificando los datos del pozo. Además, por el tipo de interpolación utilizado, los cambios en la

velocidad son fácilmente restringidos dentro de una tolerancia predefinida, limitando los nodos de la función de perturbación. Esta característica es importante en términos de *Quality Control* (QC). Asimismo, si se cuenta con una ondícula confiable previamente estimada, el algoritmo permite realizar solo el proceso de amarre automático.

En este capítulo se introducen los fundamentos básicos del amarre de pozos utilizado normalmente y luego se presenta la teoría del método propuesto, con una descripción paso a paso del algoritmo. Luego, se ilustra su funcionamiento en un ejemplo pseudo-sintético y, posteriormente, se muestra su rendimiento en datos de campo de la Cuenca Neuquina en Argentina, comparando los resultados obtenidos con los de DTWA. Finalmente, se presenta una adaptación del algoritmo para realizar el amarre y la estimación de la fase con perfiles de pozo *blocky*. Esto es útil para obtener un modelo inicial de la reflectividad que será necesario en el próximo capítulo. Finalmente, se presenta una breve discusión y las conclusiones con los resultados más relevantes.

## 5.2. Fundamentos del amarre de pozos

La integración de la información proveniente de los datos sísmicos y la de los perfiles de pozos es de gran importancia al momento de identificar formaciones geológicas. Dicho proceso es llamado amarre o atado de pozos, y es un complejo flujo de trabajo que involucra procesos como el pre-acondicionamiento de datos sísmicos, la estimación de ondículas, la interpretación geológica del área de estudio y correcciones manuales por parte del intérprete (Muñoz y Hale, 2012). Muchos *softwares* comerciales permiten realizar este procedimiento de manera manual. También existe *software* libre y *open-source* con el cual se puede realizar este procedimiento. A partir de una interfaz interactiva, muchos de estos programas permiten modificar el sismograma sintético para mejorar la correlación entre la traza sísmica y la traza sintética generada a partir de los perfiles de pozo.

En términos generales, la mayoría de los autores concuerdan en los pasos necesarios para la realización del amarre de pozos. El primero de ellos consiste en generar una reflectividad a partir de los datos de pozo disponibles. Dadas series de datos de velocidades y densidades en función de la profundidad, en términos generales la reflectividad se puede expresar como

$$r(z) = \frac{v(z+dz)\rho(z+dz) - v(z)\rho(z)}{v(z+dz)\rho(z+dz) + v(z)\rho(z)}, \quad (5.1)$$

donde  $dz$  es el intervalo de muestreo del perfil  $v(z)$  es la velocidad de propagación de las ondas sísmicas y  $\rho(z)$  es la densidad. Para el amarre de pozo propuesto en este capítulo, nos limitaremos a utilizar únicamente la velocidad de las ondas P, por lo que, de aquí en adelante,  $v(z)$  representa la velocidad de las ondas P y  $r(z)$  la reflectividad asociada a dichas ondas. Dado que las mediciones del pozo se encuentran en unidades de profundidad y los datos sísmicos en unidades de tiempo es necesario buscar la relación que permita pasar de un dominio al otro. Para obtener el tiempo de reflexión ida y vuelta,

$$t(z) = t_0 + \int_{z_0}^z \frac{dz}{v(z)}, \quad (5.2)$$

donde  $t_0$  es el tiempo para  $z = z_0$ . En el caso de contar con información de *check shots* o VSP (*vertical seismic profiles*), es conveniente incorporarla a la información proveniente del sísmico para mejorar la relación tiempo-profundidad, T-P. Debido a la falta de esta información en algunas ocasiones, es necesario aplicar un fuerte *time-shift*.

Finalmente, se genera una traza sintética convolucionando la reflectividad estimada con la ecuación 5.1 con una ondícula sísmica apropiada. La elección de la ondícula a utilizar no es un tema menor, ya que esta puede afectar significativamente la calidad del amarre (Anderson y Newrick, 2008; Edgar y van der Baan, 2011; Muñoz y Hale, 2012; Herrera y van der Baan, 2014). Generalmente, se suele utilizar una ondícula teórica, por ejemplo, una ondícula de Ricker de fase constante con un ancho de banda similar al del dato sísmico o la ondícula estadística que se podría estimar de este. Si se parte con una ondícula de fase cero, esta puede no ser óptima para el amarre, por lo que el siguiente paso es rotar la fase para mejorar la correlación entre la traza sintética y la observada (White y Simm, 2003). El amarre se da por concluido cuando los reflectores más importantes de ambas trazas se encuentran alineados. Sin embargo, es importante destacar que los resultados nunca son perfectos, ya que la traza sintética y la observada tienen diferente origen y naturaleza (Newrick, 2012). Un paso adicional opcional es mejorar el ajuste entre la traza y el sintético mediante el uso de *stretching* y/o *squeezing*. Estas dos técnicas pueden llevar a una mejor correlación al alinear los reflectores, pero como desventaja, pueden modificar groseramente el perfil de velocidades, y por ende la relación T-P de la ecuación 5.2 (Simm y Bacon, 2014).

### 5.3. Amarre de pozos y estimación de la fase automáticamente

El flujo de trabajo del amarre de pozos, que es un procedimiento estandarizado y regularmente utilizado en la industria, puede demandar mucho tiempo, y la experiencia del usuario puede influir en demasía en el proceso, dando lugar a errores humanos que comprometen la calidad final del amarre. Lo mismo ocurre con la tarea de estimar una ondícula confiable para ser utilizada en el proceso. Para superar estos inconvenientes, se presenta un nuevo método que busca abordar estas dos problemáticas en simultáneo. El objetivo es amarrar la traza sintética y la traza sísmica observada ajustando en simultáneo el modelo de velocidades y la fase de la ondícula sísmica. Estos dos pasos se llevan a cabo de manera iterativa hasta que el coeficiente de correlación entre ambas trazas sea máximo.

Dado el perfil de velocidad de la onda  $P$  obtenido del pozo,  $v_{obs}(z)$ , se obtiene un perfil de velocidades perturbado mediante

$$v_{per}(z) = v_{obs}(z) \times [1 + p(z)], \quad (5.3)$$

donde  $\rho(\cdot)$  es una función de perturbación. En este caso, la función de perturbación se construye utilizando algún método de interpolación apropiado con un cierto número de nodos  $M$  predefinidos por el usuario, donde  $M$  es mucho menor que el número de muestras de  $v_{obs}(z)$ . Por simplicidad, y con el fin de reducir el número de grados de libertad y, por lo tanto, la ambigüedad del problema de optimización, se mantiene la posición de los nodos en profundidades fijas e igualmente espaciadas a lo largo del rango de profundidad de interés. Por otro lado, para evitar soluciones que carezcan de sentido físico, se limita la función de perturbación de tal forma que:

$$-P \leq \rho(z) \leq P, \quad (5.4)$$

donde  $P \in [0, 1]$  es un parámetro a definir por el usuario, por ejemplo,  $P = 0.1$  representa una perturbación máxima de un 10 % respecto de la velocidad observada. En la práctica, se busca perturbar lo menos posible el perfil observado (e.g. Herrera y van der Baan, 2014; Wang et al., 2017), por lo que valores de  $P$  bajos garantizan que el perfil de velocidad perturbado será cercano al perfil observado. El método de interpolación elegido para generar la función  $\rho(z)$  puede ser crítico. En este caso, utilizamos *splines* monotónicos, ya que garantizan que la función entre los nodos será suave, continua y estará acotada entre los nodos (Fritsch y Carlson, 1980). Este tipo de interpolación permite además restringir los valores de los nodos, y por lo tanto de  $\rho(z)$ , dentro de un rango predefinido por  $P$ , haciendo posible establecer un máximo porcentaje permitido para perturbar el perfil de velocidades observado. De esta manera, se permite al intérprete tener un control completo sobre los cambios en la velocidad que aparecen durante el proceso de amarre de pozos. Esto es un factor clave desde el punto de vista del QC.

Respecto a la fase de la ondícula, esta se ajusta aplicando una rotación de fase constante por medio de la Transformada de Hilbert generalizada (ecuación 4.2), donde ahora  $\phi$  representa la rotación de fase constante y  $w_0$  es una ondícula de fase cero de entrada al algoritmo. En la práctica, y a diferencia de lo planteado en el Capítulo 4, puede ser preseleccionada, por ejemplo, utilizando una ondícula de Ricker de frecuencia pico central similar a la del dato, o puede ser estimada estadísticamente a partir de los datos sísmicos adyacentes al pozo. Aquí hay dos puntos en común con lo visto en el Capítulo 4. Por un lado, dado que rotaciones de fase en el rango  $0^\circ$  no son fácilmente distinguibles a simple vista (Levy y Oldenburg, 1987), las soluciones que difieren en este rango serán consideradas como buenas soluciones para el problema de amarre de pozos y estimación de la ondícula. Por otro lado, la hipótesis de fase constante puede ser cuestionada, pero esta es usualmente utilizada en el proceso de amarre de pozos y, además, ha sido utilizada y estudiada satisfactoriamente en distintos contextos (Levy y Oldenburg, 1987; White, 1988; Neidell, 1991; van der Baan, 2008; Wang et al., 2014). También se ha encontrado que esta hipótesis ofrece algunas ventajas sobre la estimación determinista basada en el amarre de pozos, sobre todo cuando los perfiles de pozo son cortos o su calidad de registro no es buena (Edgar y van der Baan, 2011).

El proceso de amarre de pozos y estimación de fase de la ondícula propuesto consiste en ajustar el valor de los  $M$  nodos y la fase constante  $\phi$  de tal forma que maximicen el

coeficiente de correlación entre el dato sintético y la traza observada. Para llevar esto a cabo, se minimiza la siguiente función de costo:

$$J = 1 - \gamma, \quad (5.5)$$

donde  $\gamma \in [-1, 1]$  es el coeficiente de correlación entre el sismograma sintético  $\hat{s}$  y el sismograma observado  $s$ . Matemáticamente, se expresa como:

$$\gamma = \frac{\sum_{i=1}^N (\hat{s}_i - \bar{\hat{s}})(s_i - \bar{s})}{\sqrt{\sum_{i=1}^N (\hat{s}_i - \bar{\hat{s}})^2 \sum_{i=1}^N (s_i - \bar{s})^2}}, \quad (5.6)$$

donde  $\bar{\hat{s}}$  y  $\bar{s}$  son los valores medios de  $\hat{s}$  y  $s$  respectivamente, y  $N$  es el número de muestras. Como esta función  $J$  es no lineal y multimodal, se utiliza el algoritmo de optimización global *Differential Evolution* (DE) para hallar la solución óptima. En cada iteración de DE, los nodos y la fase se actualizan haciendo que el perfil de velocidad de la onda  $P$  y la ondícula también se actualicen utilizando las ecuaciones 5.3 y 4.2, respectivamente. Este algoritmo de optimización, al igual que los algoritmos genéticos, busca imitar los procesos que tienen lugar en la evolución natural. DE funciona como una herramienta simple para resolver problemas de optimización complejos ya que fue diseñado para optimizar funciones de manera estocástica en un dominio continuo  $N$ -dimensional, y dada su capacidad de exploración sobre el espacio de búsqueda, evita quedar atrapado en óptimos locales. Las ventajas de este algoritmo son que tiene pocos parámetros a definir en comparación con otros algoritmos evolutivos, permite realizar análisis de incertidumbre sobre la solución por su naturaleza estocástica y tiene una convergencia más rápida que otras estrategias evolutivas (Storn y Price, 1997). En el Apéndice A.2 se presenta una descripción más detallada de este algoritmo de optimización global.

El algoritmo de amarre de pozos y estimación de la fase de la ondícula se puede describir paso a paso de la siguiente manera:

1. Fijar el número de nodos  $M$  a ser utilizado y sus correspondientes profundidades.
2. Fijar el parámetro  $P$  que limitará la función de perturbación  $p(z)$  y determinar el rango de búsqueda de la fase de la ondícula  $\phi$ .
3. En cada iteración de DE:
  - I Modificar la ondícula usando la ecuación 4.2.
  - II Perturbar el perfil de velocidades usando la ecuación 5.3.
  - III Calcular la serie de coeficientes de reflexión utilizando la ecuación 5.1.
  - IV Aplicar la relación T-P dada por la ecuación 5.2 a la reflectividad para convertirla de profundidad a tiempo.
  - V Crear el sismograma sintético utilizando la reflectividad y la ondícula perturbadas.

VI Evaluar la función de costo usando la ecuación 5.5.

VII Comprobar convergencia o criterio de corte.

Es importante señalar que, en caso de ya contar con una estimación confiable de la ondícula, se puede utilizar esta directamente para generar el amarre automático sin realizar el ajuste de fase (Gelpi et al., 2019a).

Un punto de relevancia, previo a comenzar con el proceso de amarre tanto de forma manual como automática, es tener un adecuado pre-acondicionamiento de los datos registrados en el pozo. En este sentido, hay varios puntos a considerar. Por un lado, los perfiles de densidad son sensibles a las condiciones del pozo (*washouts* o invasiones), requiriendo un buen contacto de la herramienta con la pared del pozo (Anderson y Newrick, 2008). Por otro lado, los perfiles sónicos, si bien no son tan sensibles a las condiciones del pozo, se ven afectados por ruido sísmico, dispersión, etc. Como consecuencia, una edición del perfil, como puede ser aplicar un filtro de mediana, es necesaria para minimizar el impacto de errores en las altas frecuencias de las mediciones (Leaney y Ulrych, 1987). Para más ejemplos y detalles relacionados con el procesamiento de perfiles y QC, el lector puede referirse a Anderson y Newrick (2008) y White y Simm (2003).

## 5.4. Resultados numéricos

En esta sección, probamos el método propuesto para el amarre de pozos y la estimación de la fase de la ondícula mediante ejemplos numéricos utilizando datos pseudo-sintéticos y datos de campo. Con el primer tipo de datos se estudió el rendimiento del método usando distintos valores de los parámetros  $M$  y  $P$  del algoritmo. Además, se evaluó el impacto de dichos parámetros en la estabilidad del algoritmo y, en particular, en la estimación de la fase de la ondícula mediante un análisis estadístico. Finalmente, se aplicó el método propuesto a datos de campo en dos escenarios diferentes: uno donde la correlación inicial entre el sintético y la traza observada era relativamente alta (0.64), y otro donde la correlación era baja (0.37) y se consideró necesaria una mejora en el amarre. Además del análisis detallado del funcionamiento del algoritmo propuesto, se realizaron pruebas con el algoritmo automático *Dynamic Time Warping* (DTW) para comparar los resultados.

### 5.4.1. Dato pseudo-sintético

En este ejemplo utilizamos un dato pseudo-sintético para probar el algoritmo. Para ello generamos dos trazas: una hará la función de dato sísmico observado y la llamaremos traza observada, mientras que la otra será la traza sintética asociada al dato de pozo, la cual será ajustada al dato observado mediante el algoritmo de amarre.

Para generar la traza sintética inicial, partimos de un perfil de velocidades de onda  $P$  real medido en un pozo, al cual le aplicamos un filtro de mediana para minimizar el impacto de observaciones espurias. Asumiendo, por simplicidad, una densidad constante

con la profundidad, generamos un perfil de reflectividad a partir de este perfil de velocidades utilizando la ecuación 5.1. Utilizando el perfil de velocidad, transformamos la reflectividad del dominio de la profundidad al tiempo. Luego, convolucionamos esta reflectividad con una ondícula de Ricker de frecuencia central de 30 Hz y sin rotación de fase, generando así la traza sintética inicial.

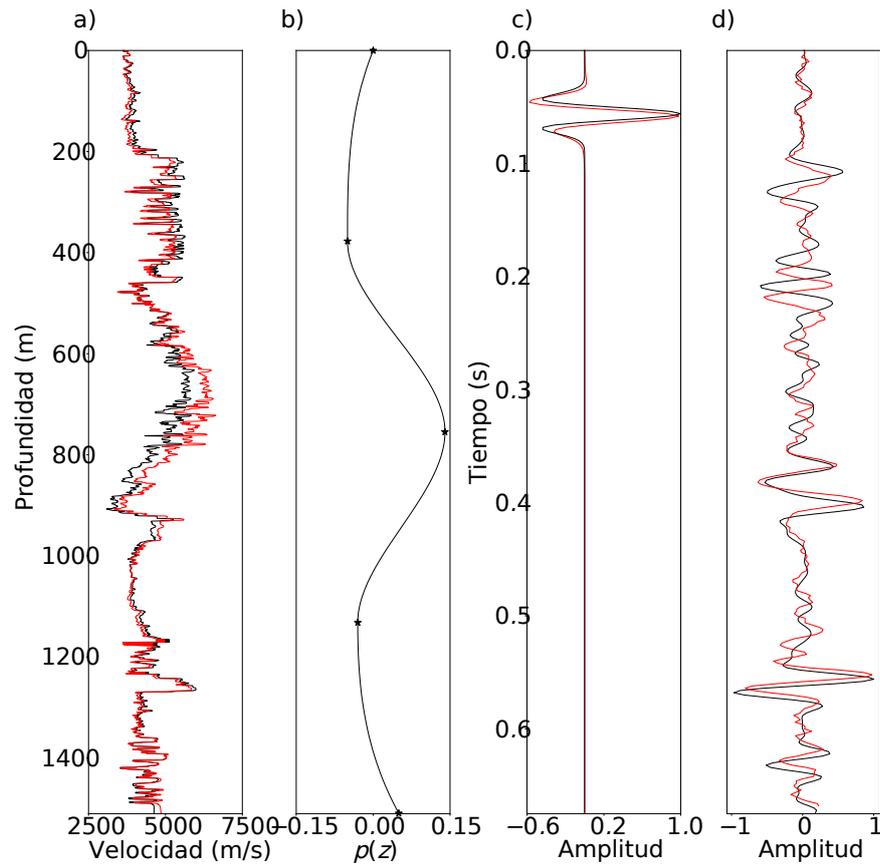
El perfil de velocidades, la ondícula utilizada y el dato resultante pueden verse en color negro en las Figuras 5.1a, c y d, respectivamente. Para generar la traza observada, aplicamos una función de perturbación  $\rho(z)$  al perfil de velocidades utilizando la ecuación 5.3, obteniendo un perfil de velocidades perturbado. Esta función fue construida utilizando *splines* cúbicos monotónicos con 5 nodos  $P = 0.15$ , como se muestra en la Figura 5.1b. A partir de este perfil perturbado y asumiendo una densidad constante, generamos un perfil de reflectividades en el dominio del tiempo, que convolucionamos con una ondícula de Ricker de frecuencia central de 30 Hz y su fase rotada a  $-30^\circ$  la traza resultante le agregamos ruido Gaussiano de banda limitada.

El perfil de velocidades, la ondícula utilizada y la traza resultante pueden verse en color rojo en las Figuras 5.1a, c y d, respectivamente. La correlación entre las trazas observada y sintética es 0.45, lo que indica que el ajuste entre ellas es relativamente bajo y requiere una mejora en el amarre de los datos.

### 5.4.2. Dependencia de los parámetros

En esta sección analizamos los resultados del amarre de ambas trazas en función de los parámetros  $M$  y  $P$ . Para ello, aplicamos el algoritmo con diferentes valores de estos parámetros y analizamos los resultados.

Primero, fijamos el valor de  $P$  y analizamos el rendimiento del método para distintos valores de  $M$ . La Figura 5.2a muestra en negro el perfil de velocidad original y los distintos perfiles resultantes luego de aplicar el método con  $M=3, 5, 10, 50$  y  $100$ . En todos los casos se consideró  $P = 0.15$ . Las Figuras 5.2b y 5.2c muestran las funciones  $\rho(z)$  estimadas correspondientes y las trazas sintéticas obtenidas, respectivamente. Se puede ver que cuanto mayor es el número de nodos  $M$ , mayor es la inestabilidad de las funciones  $\rho(z)$  estimadas, las cuales se alejan de la curva utilizada para generar el dato que se muestra en la Figura 5.1b. A pesar de estas diferencias, los sismogramas después del ajuste son muy similares entre sí, como puede verse en la Figura 5.2c. La Tabla 5.1 resume los resultados obtenidos. Los coeficientes de correlación resultantes entre los sintéticos observados y ajustados son muy altos en todos los casos, incluso en los casos con  $M = 3$  y  $M = 100$ , donde las estimaciones de la fase de la ondícula no fueron buenas. Como es de esperar, cuanto mayor es el número de nodos (ej. 50 o 100), mayor es el valor del coeficiente de correlación. Sin embargo, muchos nodos pueden introducir deformaciones locales no deseadas en el perfil de velocidad perturbado. Estas deformaciones no son reales y pueden llevar a una mala interpretación. Un ejemplo de esto puede observarse entre los 900 y 1200 m para el caso  $M = 100$ , curva violeta en la Figura 5.2a. Por el contrario, muy pocos nodos pueden no ser suficientes para lograr una correlación apropiada entre el dato sintético y el dato observado. Un criterio conservador podría ser seleccionar el número mínimo de nodos que logre un coeficiente



**Figura 5.1.** Ejemplo pseudo-sintético: a) en negro el perfil de velocidad original y en rojo el perfil perturbado; b) curva  $\rho(z)$  utilizada para perturbar el perfil de velocidad con  $M = 5$  y  $P = 0.15$ ; c) en negro la ondícula de Ricker de fase cero y en rojo con la fase rotada a  $-\pi/3$ ; d) en negro la traza sintética inicial asociada al dato de pozo y en rojo la traza observada.

**Tabla 5.1.** Ejemplo pseudo-sintético: Coeficientes de correlación y fases estimadas para diferentes números de nodos y un cambio de velocidad fijo  $P = 0.15$ .

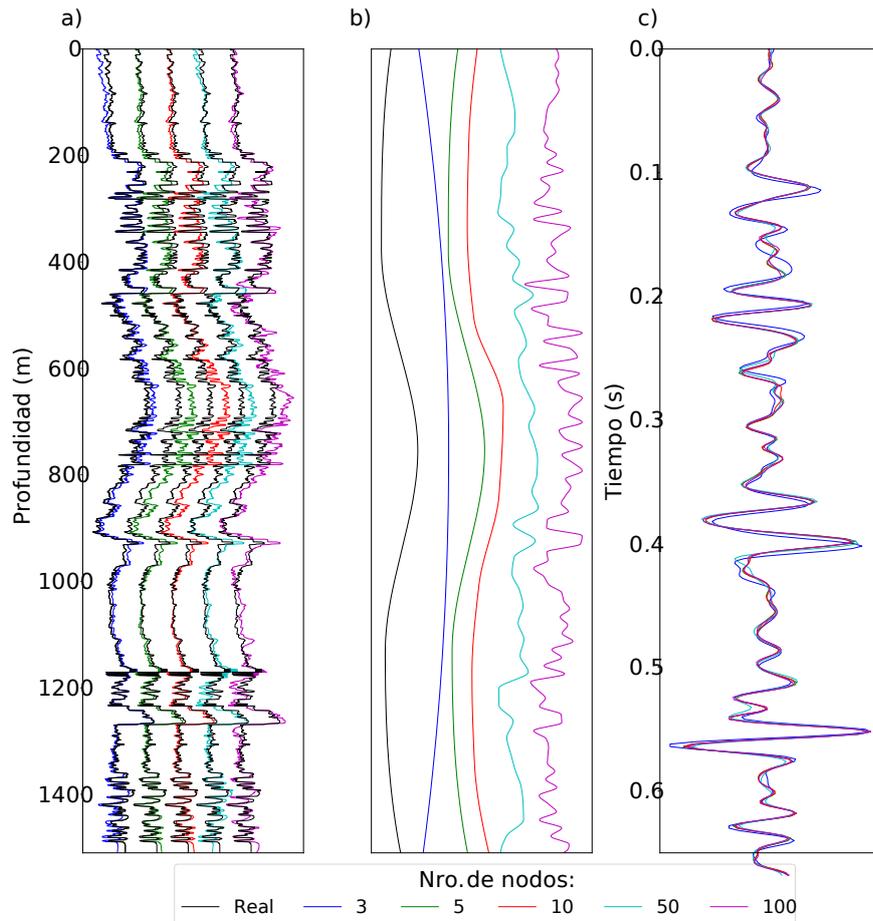
	$M$				
	3	5	10	50	100
$\gamma$	0.89	0.98	0.98	0.99	0.99
$\phi(^{\circ})$	2	-30	-32	-26	-60

**Tabla 5.2.** Ejemplo pseudo-sintético: Coeficientes de correlación y fases estimadas para diferentes cambios de velocidad y un número fijo de nodos  $M = 10$ .

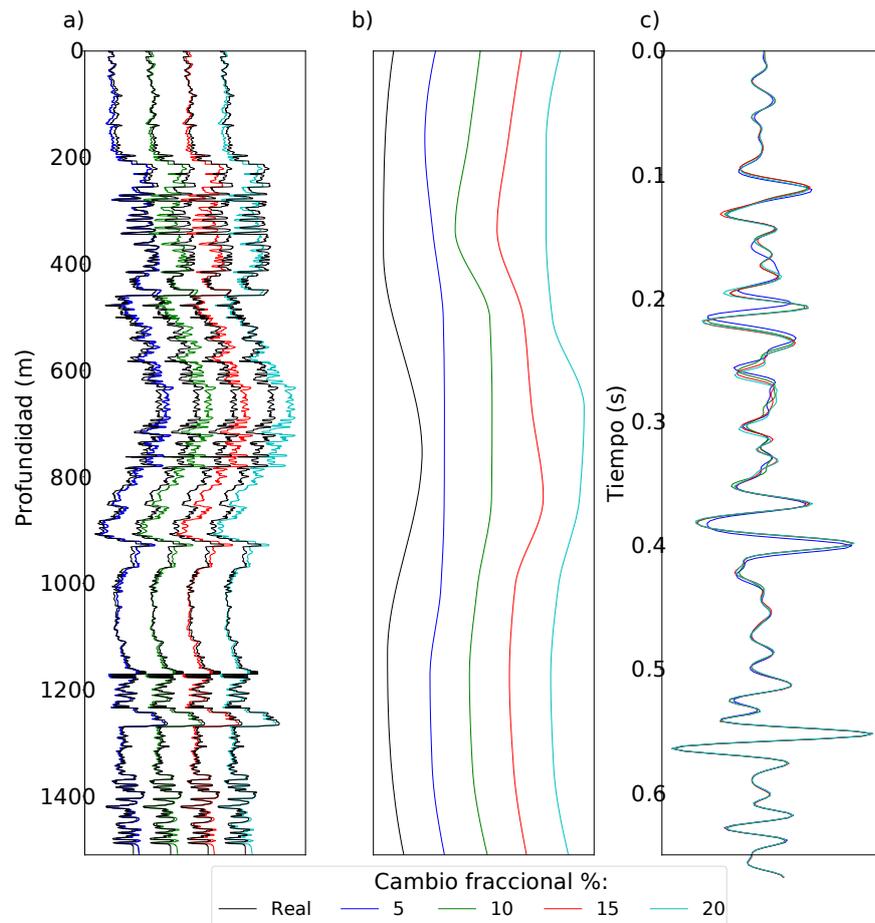
	$P$			
	0.05	0.1	0.15	0.2
$\gamma$	0.91	0.98	0.98	0.98
$\phi(^{\circ})$	-12	-33	-30	-27

de correlación razonablemente bueno, por ejemplo, 0.90 (Zhou, 2014). Este número puede ser obtenido fácilmente con un procedimiento simple como el de ensayo y error.

A continuación, analizamos el comportamiento del algoritmo para un número fijo de nodos  $M = 10$  y valores  $P = 0.05, 0.1, 0.15$  y  $0.2$ . Los resultados se muestran en la Figura 5.3 y un resumen de los mismos puede encontrarse en la Tabla 5.2. Dado que el número seleccionado de nodos es conservador, las estimaciones de las curvas  $\rho(z)$  son estables y similares a la curva original, como se muestra en la Figura 5.1b, incluso para los mayores valores de  $P$ . El coeficiente de correlación varía desde 0.91 para el caso de  $P = 0.05$  hasta 0.98 para el caso  $P = 0.20$ . En todos los casos, las fases estimadas estuvieron dentro de  $\pm 4^{\circ}$  de la fase verdadera, excepto en el caso de  $P = 0.05$ , donde la fase estimada fue de  $-12^{\circ}$ . Estos resultados muestran que, dado un número conservador de nodos, se pueden obtener altos valores del coeficiente de correlación utilizando perturbaciones entre medias y bajas de la velocidad. Sin embargo, no se recomienda utilizar grandes valores de  $P$  a menos que el perfil sónico registrado sea de mala calidad o poco confiable. Como se observa en la Figura 5.3 para el caso de  $P = 0.2$ , el perfil de velocidades original fue afectado severamente en algunas regiones por la curva  $\rho(z)$  resultante. Estas variaciones pueden ser innecesarias en la mayoría de las situaciones, ya que se pueden lograr mejoras en los valores de la correlación utilizando valores pequeños de  $P$ , como se deduce de la Tabla 5.2.



**Figura 5.2.** Ejemplo pseudo-sintético: resultados con un cambio de velocidad de  $P = 0.15$  para diferente número de nodos. a) Perfiles de velocidad observados (negro) y perturbados (en colores), b) curva  $v(z)$ , y c) trazas sintéticas correspondientes.



**Figura 5.3.** Ejemplo pseudo-sintético: resultados con  $M = 10$  y distintos cambios de velocidad  $P$ . a) Perfiles de velocidad observados (negro) y perturbados (en colores), b) curva  $\alpha(z)$ , y c) trazas sintéticas correspondientes.

### 5.4.3. Análisis estadístico

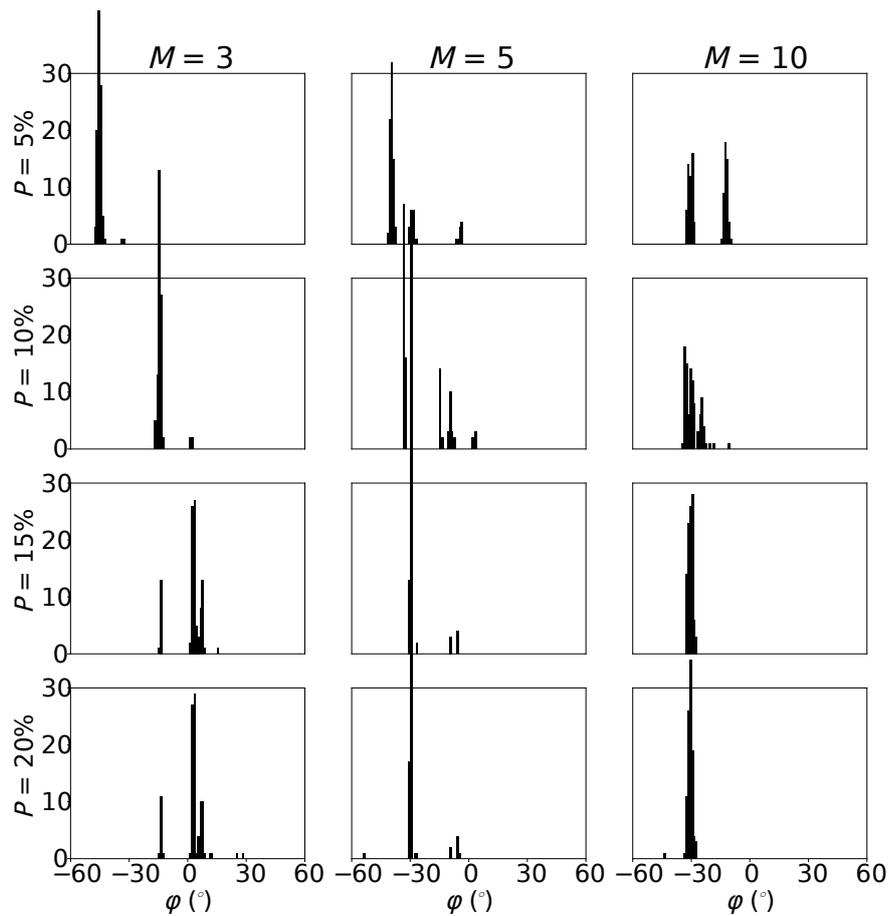
Los resultados resumidos en las Tablas 5.1 y 5.2 muestran que, como el método estima en simultáneo  $\rho(z)$  y la fase de la ondícula, puede existir un cierto *trade-off* entre ellos, especialmente cuando  $M$  o  $P$  toman valores grandes. En este ejemplo, para analizar el comportamiento de las soluciones estimadas y evaluar la estabilidad del algoritmo, se repite el proceso varias veces bajo las mismas condiciones, aprovechando la ventaja de la naturaleza estocástica del algoritmo DE.

Para el análisis, consideramos valores de  $M = 3, 5$  y  $10$ ; y  $P = 0.05, 0.1, 0.15$  y  $0.2$ . Con fines estadísticos, considerando que las soluciones finales pueden variar dependiendo de la población inicial del algoritmo DE, para cada par de parámetros se aplicó el método propuesto 100 veces. En todos los casos, el rango de búsqueda de la fase de la ondícula fue de  $-90^\circ$  a  $90^\circ$ . La Tabla 5.3 resume los resultados obtenidos. Mientras más grandes sean  $M$  y  $P$ , mayores son los valores del coeficiente de correlación; sin embargo, en la práctica no se debería esperar obtener valores tan altos de la correlación al realizar el amarre de pozos (Newrick, 2012). Estos valores, claro está, no son realistas y se recomienda al usuario ser conservador y sensato en la selección de los parámetros. Usualmente, valores de la correlación entre 0.8 a 0.9 son más que aceptables para una óptima interpretación de los datos (Zhou, 2014). Estos valores pueden ser alcanzados seleccionando unos pocos nodos y valores de  $P$  del orden de 0.15, como puede verse en los resultados. La selección de los valores óptimos dependerá, naturalmente, de la longitud de la ventana en la que se requiere realizar el amarre y de cuánto confíe el usuario en los perfiles observados, entre otras cuestiones.

**Tabla 5.3.** Ejemplo pseudo-sintético 3: coeficientes de correlación promedio luego de 100 realizaciones para los distintos pares de parámetros. En todos los casos, el desvío estándar estuvo en el orden de 0.001.

$P$	$M$		
	3	5	10
0.05	0.82	0.86	0.91
0.1	0.88	0.96	0.97
0.15	0.89	0.98	0.98
0.2	0.89	0.98	0.98

La Figura 5.4 muestra, para todas las combinaciones de parámetros, los histogramas de las fases de la ondícula estimadas para las 100 realizaciones. Se puede observar que, en la mayoría de los casos, las estimaciones se encuentran comprendidas dentro del rango de  $\pm 20^\circ$  de la fase original, los cuales son valores aceptables bajo la hipótesis asumida de fase constante. También puede observarse cómo la calidad de las estimaciones decrece al utilizar pocos nodos o cuando se permite variar muy poco el modelo de velocidad registrado. En estos casos, las curvas de perturbación que se obtienen no son capaces de recrear la curva  $\rho(z)$  original, y la fase intenta compensar estas limitaciones.



**Figura 5.4.** Ejemplo pseudo-sintético 3: Histogramas de las fases estimadas luego de las 100 realizaciones para los distintos pares de parámetros.

Contrariamente, las estimaciones mejoran al utilizar 5 o más nodos y permitir grandes variaciones en la velocidad.

Ahora, el análisis se centra en dos casos particulares. El primero con  $M = 3$  y  $P = 0.05$  y el segundo con  $M = 10$  y  $P = 0.15$ . Dado que el dato fue creado utilizando  $M = 5$  y  $P = 0.15$ , se espera que el primer caso muestre valores bajos de correlación y estimaciones de la fase poco satisfactorias, mientras que para el segundo se esperan correlaciones más altas y buenas estimaciones de la fase, como se concluyó en los ejemplos previos. La Figura 5.5a muestra en negro el perfil de velocidad observado y en rojo el perturbado para las 100 realizaciones al utilizar  $M = 3$  y  $P = 0.05$ , mientras que las Figuras 5.5b y 5.5c muestran respectivamente las correspondientes curvas  $\hat{\rho}(z)$  estimadas y los sismogramas sintéticos. Puede verse que las 100 curvas  $\hat{\rho}(z)$ , aunque son muy parecidas entre sí y estables, no honran la curva original con la que se generó el dato, mostrada en la Figura 5.1b. Lo mismo se observa para los sintéticos generados. Por otro lado, la Figura 5.6a muestra en negro el perfil de velocidad observado y en rojo el perturbado para las 100 realizaciones con  $M = 10$  y  $P = 0.15$ , mientras que las Figuras 5.6b y 5.6c muestran respectivamente las correspondientes curvas  $\hat{\rho}(z)$  estimadas y los sismogramas sintéticos. Se puede observar que en este caso, las 100

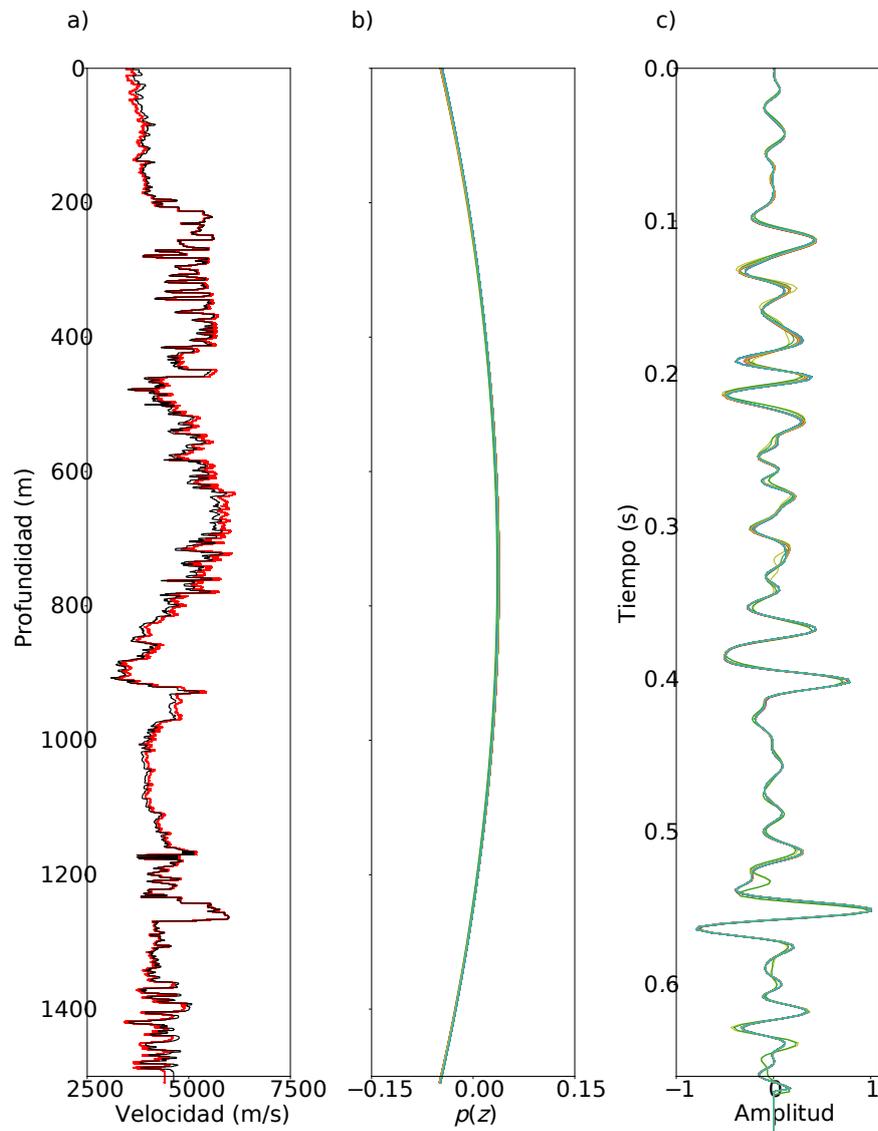
curvas  $\rho(z)$  son similares entre sí y siguen la tendencia de la curva original que se utilizó para generar la traza observada, mostrada en la Figura 5.1b. Sin embargo, las curvas son inestables en la parte superior de la ventana de trabajo, lo que puede explicarse por la falta de reflectores significativos en esa profundidad, lo que reduce la sensibilidad del coeficiente de correlación a las variaciones de velocidad en esa región. Por otro lado, los 100 sintéticos resultantes son muy parecidos entre sí. El coeficiente de correlación se incrementó de 0.45 a 0.82 en el primer caso y de 0.45 a 0.98 en el segundo, con un desvío estándar de 0.001. En cuanto a la fase de la ondícula, se obtuvo una rotación de fase media de  $-45^\circ$  con un desvío estándar de  $1.9^\circ$  para el primer caso y una fase de  $-30^\circ$  con un desvío estándar de  $1.2^\circ$  para el segundo.

El análisis para todos los pares de parámetros muestra que, utilizando pocos nodos y pequeños cambios de velocidad, se obtienen curvas  $\rho(z)$  estables. Por otro lado, aunque el uso de varios nodos y grandes cambios de velocidad lleva a curvas inestables, estas siguen la tendencia de la curva original. Sin embargo, se recomienda utilizar la menor cantidad de nodos posible y permitir pequeñas variaciones de velocidad para minimizar las desviaciones del perfil de velocidad observado.

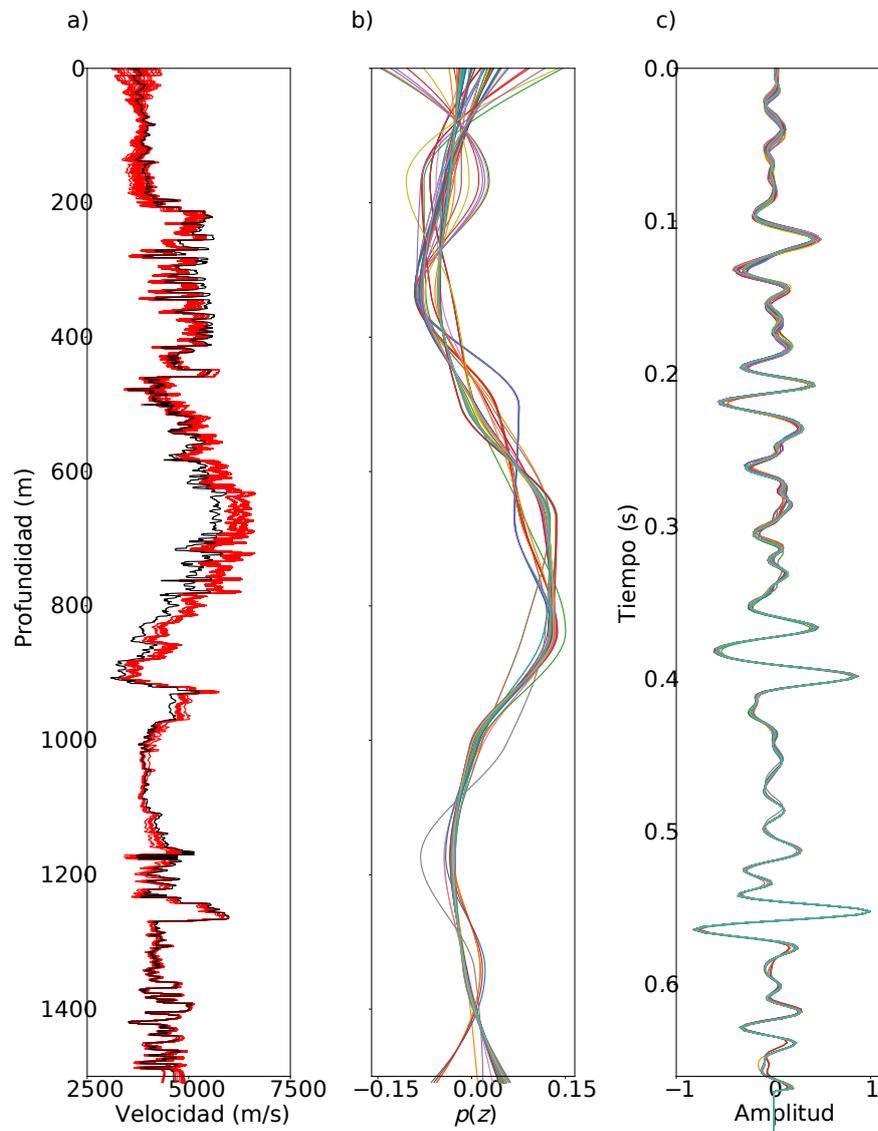
#### 5.4.4. Datos de campo

En este ejemplo utilizamos datos de campo para poner a prueba el método propuesto. El conjunto de datos disponible consiste en un cubo sísmico migrado en tiempo, con un intervalo de muestreo de 2 ms, además se cuenta con dos perfiles sónicos medidos en dos pozos, pozo A y pozo B, ubicados en el área. Los datos fueron registrados en la cuenca Neuquina, Provincia de Neuquén, Argentina. Al dato, como parte de su preprocesamiento, se le había aplicado una rotación de fase de  $90^\circ$ . Ante la falta de *check shots* y datos de VSP, la relación tiempo-profundidad la obtuvimos, para ambos pozos, integrando el perfil sónico. En ambos perfiles se aplicó un filtro de mediana de 33 puntos (White y Simm, 2003; Duchesne y Gaillot, 2011). Las ondículas de fase cero necesarias para realizar el amarre se obtuvieron estadísticamente a partir del dato sísmico cercano a los pozos. Dichas ondículas pueden verse, con líneas punteadas, en las figuras 5.9a y b. En este ejemplo, además de realizar el amarre utilizando el algoritmo propuesto, compararemos los resultados obtenidos con aquellos que surgen de hacer el amarre de manera manual y utilizando DTW con restricciones.

La Figura 5.7a muestra en color negro el perfil de velocidad observado que se obtiene a partir del sónico del pozo A. La Figura 5.7c muestra en negro la traza observada en las cercanías del pozo y en color rojo la traza sintética inicial luego de realizar el amarre manualmente, que consistió en la elección de la ondícula y realizar un *time-shift* que mejore la correlación. El coeficiente de correlación entre estas trazas es 0.64, por lo que, a pesar de ser relativamente bueno, el amarre podría mejorarse. Luego realizamos el amarre utilizando el algoritmo propuesto, eligiendo valores de los parámetros  $M = 15$  y  $P = 0.15$ . La Figura 5.7a muestra en rojo el perfil de velocidad perturbado. Puede verse que los apartamientos del perfil de velocidad observado son relativamente pequeños, en concordancia con el máximo cambio permitido para la velocidad durante el proceso de optimización. La curva de perturbación  $\rho(z)$  se observa en la Figura 5.7b. La



**Figura 5.5.** Ejemplo pseudo-sintético 3: Resultado luego de 100 realizaciones utilizando  $M = 3$  y  $P = 0.05$ . a) Perfil de velocidad observado en negro y perturbado en rojo, b) curvas  $\rho(z)$ , y c) sismogramas sintéticos calculados.



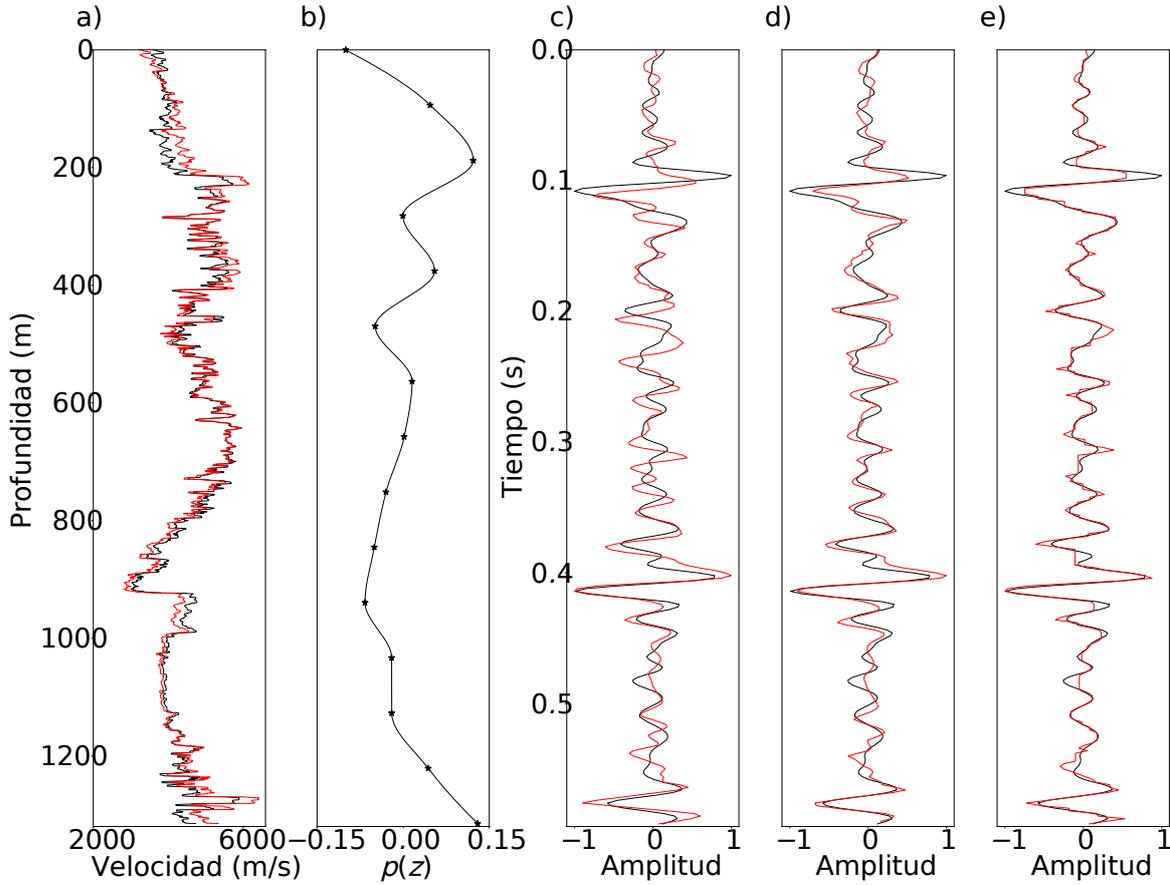
**Figura 5.6.** Ejemplo pseudo-sintético 3: Resultado luego de 100 realizaciones utilizando  $M = 10$  y  $P = 0.15$ . a) Perfil de velocidad observado en negro y perturbado en rojo, b) curvas  $\rho(z)$ , y c) sismogramas sintéticos calculados.

Figura 5.7d muestra en negro la traza observada en las cercanías del pozo y en color rojo la traza sintética después de realizar el amarre. Se puede observar una mejora en el ajuste de las dos trazas. En efecto, el coeficiente de correlación final pasó de 0.64 a 0.88. La ondícula estimada se muestra con línea sólida en la Figura 5.9a y resultó con una rotación de fase óptima de 82, valor cercano a los 90 que posee el dato. Finalmente, la Figura 5.7e muestra los resultados del amarre utilizando DTW. Se utiliza la versión con restricciones siguiendo el trabajo de Herrera y van der Baan (2014), donde se utiliza una ventana de deformación (*warping window*) de 10 muestras. Se debe mencionar que la implementación del algoritmo DTW no considera ningún sobremuestreo o filtro de suavizado. Aunque el coeficiente de correlación es un poco mayor que el obtenido con el método propuesto, alcanzando un valor de 0.94, la traza ajustada muestra algunas características no deseadas, como picos y lóbulos planos poco realistas, que no se encuentran cuando se utiliza el método propuesto.

La Figura 5.8a muestra en color negro el perfil de velocidad observado que se obtiene a partir del sónico del pozo B. En este caso se observa un comportamiento similar al obtenido en el caso anterior. La Figura 5.8c muestra en negro la traza observada en las cercanías del pozo y en color rojo la traza sintética inicial luego de realizar el amarre manualmente. El coeficiente de correlación entre estas trazas es 0.37, por lo que en este caso el amarre no es bueno y debe mejorarse. Dado que en este caso la ventana de trabajo es más corta que en el caso anterior, para el amarre con el algoritmo propuesto se optó por utilizar valores  $dM = 10$  y  $P = 0.1$ . La Figura 5.8a muestra en rojo el perfil de velocidad perturbado. Puede verse que los apartamientos del perfil de velocidad observado son relativamente pequeños, en concordancia con el máximo cambio permitido para la velocidad durante el proceso de optimización. La curva de perturbación  $\rho(z)$  se observa en la Figura 5.8b. La Figura 5.8d muestra en negro la traza observada en las cercanías del pozo y en color rojo la traza sintética después de realizar el amarre. Se puede observar una mejora significativa en el ajuste de las dos trazas. En efecto, el coeficiente de correlación final pasó de 0.37 a 0.79. La ondícula estimada se muestra con línea sólida en la Figura 5.9b y resultó con una rotación de fase óptima de 89, valor cercano a los 90 que posee el dato. Finalmente, la Figura 5.8e muestra los resultados del amarre utilizando DTW. En este caso, la correlación alcanzó un valor de 0.84. Nuevamente, esta estrategia permite obtener un mejor coeficiente de correlación, pero a cambio de algunas deformaciones de la ondícula que son poco realistas, como también se observó en el ejemplo anterior.

## 5.5. Amarre *blocky* de pozos

Con el fin de representar el subsuelo como una serie de capas con propiedades físicas bien diferenciadas, los registros de pozos pueden ser subdivididos en segmentos relativamente uniformes que representan zonas con similar litología. Los límites de estos segmentos corresponden a cambios abruptos en las capas del subsuelo, representando los límites entre unidades geológicas. En la práctica, con el fin de seguir estos bordes geológicos establecidos por el intérprete o petrofísico, es conveniente que los perfiles



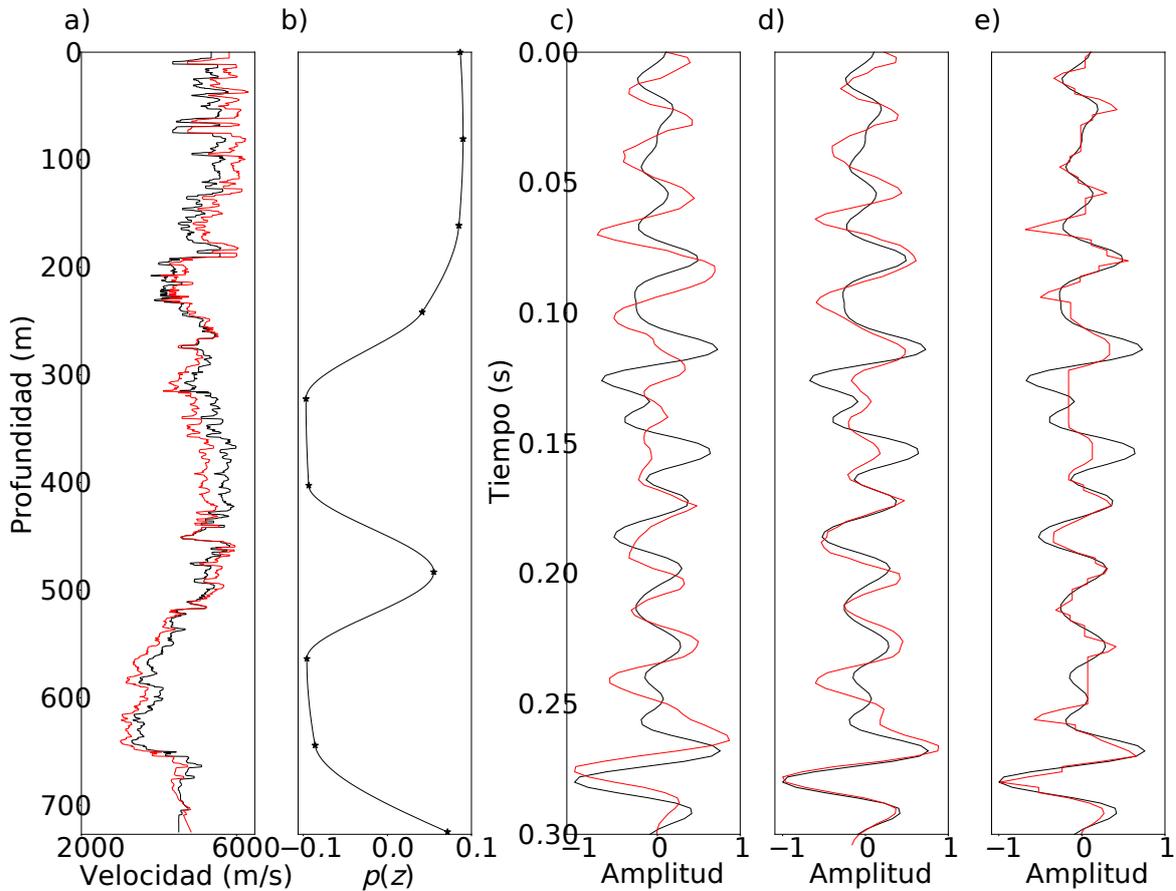
**Figura 5.7.** Ejemplo dato de campo, Pozo A: a) Perfil de velocidad observado en negro y perturbado en rojo, b) curva  $\rho(z)$  utilizando  $M = 15$  y  $P = 0.15$ , trazas observada en negro y sintética en rojo luego del c) amarre manual, d) el método propuesto y e) DTW con restricciones.

registrados en el pozo tengan una representación en bloques o, como se lo llama comúnmente, *blocky*. Para poder mantener esta característica *blocky* durante el amarre es importante tener un buen control de las perturbaciones que se le realizarán al perfil sísmico. El problema surge cuando, durante el procedimiento de amarre, con el fin de mejorar la correlación, se crean intervalos de velocidad que no son realistas o que no respetan el análisis de capas geológicas definido previamente.

Una ventaja del método propuesto es que puede adaptarse fácilmente para trabajar con perfiles *blocky*. Para esto, en cada iteración del DE, la función que perturba el perfil sísmico dada por la ecuación 5.3 se puede reutilizar de la siguiente manera:

$$v_{per}^b(\Delta z) = v_{obs}^b(\Delta z) \times [1 + \rho(z^*)], \quad (5.7)$$

donde  $\Delta z$  son intervalos de velocidad constantes y  $z^*$  son las profundidades medias de cada intervalo en el perfil de velocidad. La fase de la ondícula se perturba de la misma

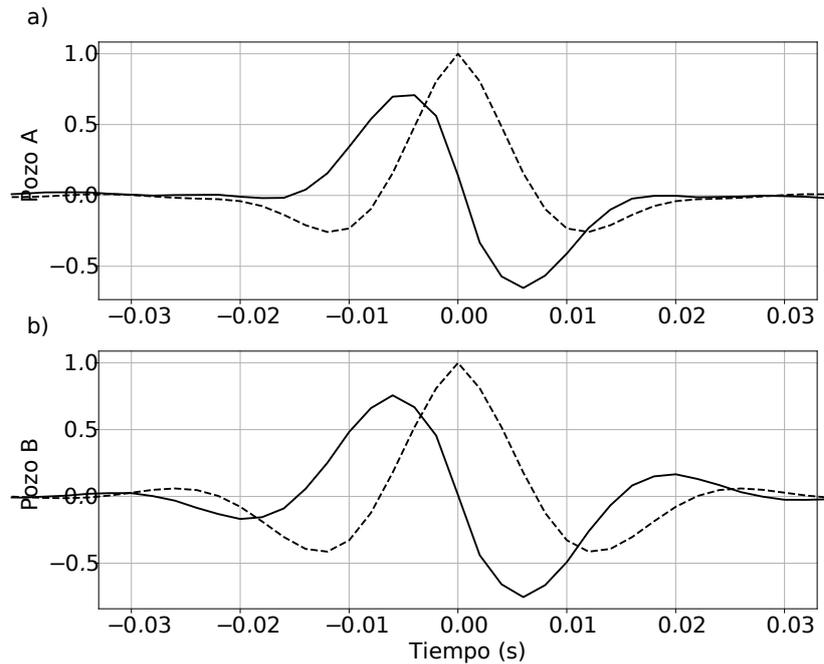


**Figura 5.8.** Ejemplo dato de campo, Pozo B: a) Perfil de velocidad observado en negro y perturbado en rojo, b) curva  $\rho(z)$  utilizando  $M = 10$  y  $P = 0.1$ , trazas observada en negro y sintética en rojo luego del c) amarre manual, d) el método propuesto y e) DTW con restricciones.

manera en cada iteración de DE mediante la transformada de Hilbert generalizada, dada por la ecuación 4.2.

### 5.5.1. Segmentación de perfiles de pozo

Una versión *blocky* del perfil observado se puede obtener mediante un análisis interpretativo del mismo, siguiendo rasgos geológicos característicos como distintas litologías, tipo de sedimentos o algún otro tipo de información de la cuenca. En este paso es común la interacción entre el intérprete y el petrofísico. Una alternativa es utilizar algún algoritmo de segmentación. Los enfoques clásicos para abordar este problema de segmentación se basan en encontrar cambios abruptos en la media (Webster, 1973) o varianza (Gill, 1970) de la secuencia bajo estudio. También pueden encontrarse estrategias basadas en técnicas de *clustering* y análisis espectral (Gill et al., 1993; Ligges et al., 2002). En este trabajo de tesis, para obtener un perfil *blocky*, se utiliza la técnica propuesta por Velis (2007). En este algoritmo, el objetivo de la segmentación



**Figura 5.9.** Ejemplo dato de campo: Ondículas estadísticas estimadas (línea punteada) y con estimación de fase (línea continua) para a) pozo A y b) pozo B.

es subdividir la secuencia original  $\mathbf{x} = (x_1, x_2, \dots, x_N)$  en segmentos más pequeños de manera tal que localmente sean relativamente estacionarios. Es decir, se busca una secuencia de puntos de cambio

$$\mathbf{t} = (t_1, t_2, \dots, t_k) \quad (5.8)$$

crecientes. Estos índices determinan la longitud de los segmentos del dato  $t_{j+1} - t_j$ .

Luego, el algoritmo busca de manera iterativa sucesivos puntos de cambio a partir de la hipótesis de que dos intervalos adyacentes son distintos cuando la función de densidad de probabilidad (*pdf*) de los datos a cada lado del punto de cambio es significativamente diferente. Para esto, se utiliza una ventana de longitud centrada en el punto de cambio a examinar y se la divide a la mitad para el cálculo de las *pdfs* y su posterior comparación. El tamaño de la ventana debe ser tal que permita encontrar intervalos estacionarios. Para esto, el algoritmo recae en el método de máxima entropía (Jaynes, 1957) para el cálculo de las *pdfs* (Velis, 2003). Este método, a su vez, utiliza estadísticos calculados directamente de los datos para restringir la maximización de la *pdf* de la entropía. Para realizar la segmentación, la estrategia hace uso de una ventana deslizante a lo largo de la serie a segmentar. De esta manera, la ventana recorre todo el dato y asigna un punto de cambio cuando se observa un fuerte cambio en la *pdf*. Como parámetros de control, este algoritmo permite seleccionar al usuario el largo de la ventana a utilizar para el análisis y la distancia mínima aceptable para los puntos de cambio a encontrar en la secuencia.

### 5.5.2. Ejemplo de amarre *blocky*

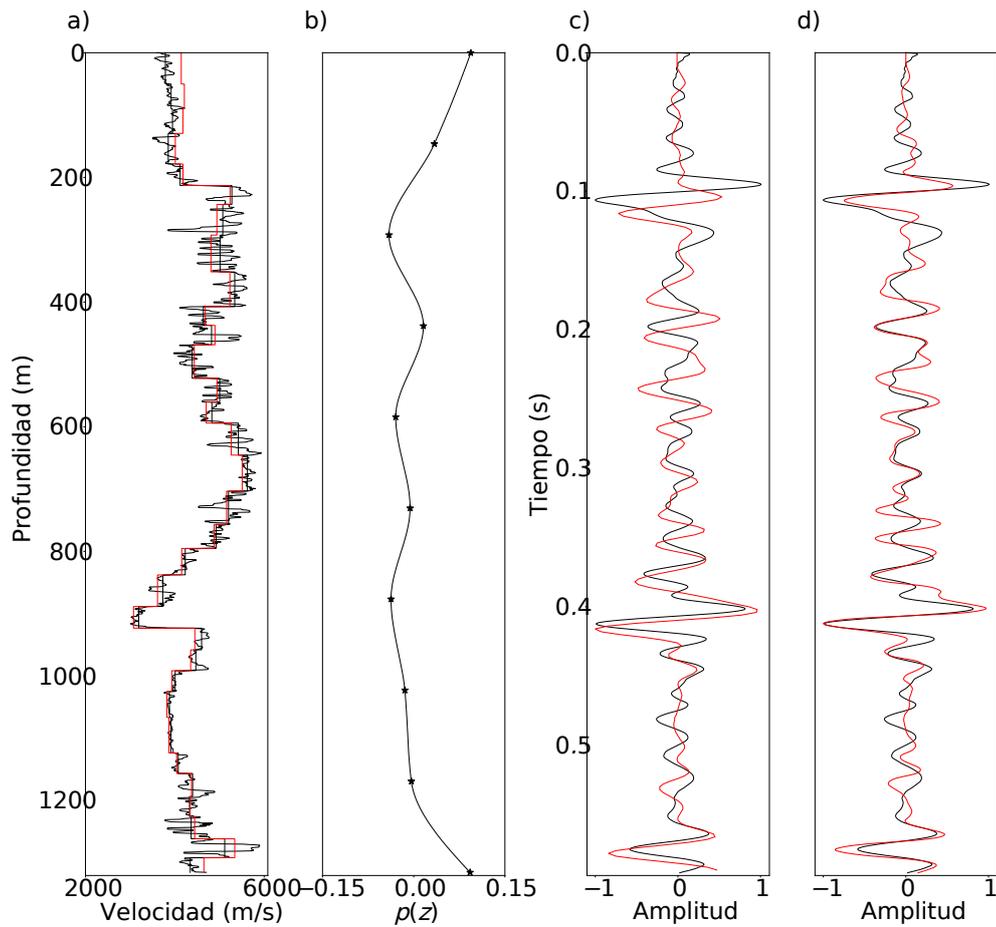
Para ilustrar los resultados al utilizar el método *blocky*, utilizamos los datos correspondientes al pozo A del ejemplo 5.4.4, así como la ondícula estadística de fase cero estimada del dato sísmico. En la Figura 5.10a se puede ver en gris el perfil sísmico observado y en negro la versión *blocky* del mismo obtenida mediante el algoritmo de segmentación. En la Figura 5.10c se puede ver en negro la traza sísmica observada y en rojo la traza sintética obtenida al convolucionar la reflectividad estimada del perfil *blocky* con la ondícula de fase cero. La correlación entre estas dos trazas es 0.61. Al igual que antes, si bien este valor no es considerado bajo, siempre es deseable mejorar el amarre de manera confiable. El amarre utilizando el algoritmo propuesto fue aplicado con valores  $M = 10$  y  $P = 0.1$ . La Figura 5.10a muestra en rojo el perfil *blocky* perturbado. La Figura 5.10b muestra la curva de perturbación  $\phi(z)$ , mientras que en la Figura 5.10d se puede ver en rojo la traza sintética final luego del amarre. La correlación final entre las trazas es de 0.8 y se estimó un valor de la fase de la ondícula de  $85^\circ$ . Es decir, se logró mejorar el ajuste entre la traza sintética y la observada, obteniendo un valor para la fase de la ondícula dentro del rango esperado.

## 5.6. Discusión

Una hipótesis implícita en el algoritmo de amarre presentado es que la ondícula debe ser estacionaria dentro de la ventana de trabajo. Generalmente, esta hipótesis se considera válida para ventanas de duración relativamente corta en tiempo, estableciendo algunos autores tiempos máximos del orden de los 0.5 segundos (van der Baan, 2008; Zhou, 2014; Herrera y van der Baan, 2014). En los ejemplos estudiados, tanto para los datos pseudo-sintéticos como para los datos de campo, las ventanas de tiempo fueron aproximadamente de esta dimensión. No obstante, en el caso de tener que utilizar ventanas de tiempo más grandes se pueden implementar distintas estrategias para superar los problemas asociados a la no estacionariedad de la ondícula como por ejemplo, subdividir en ventanas más pequeñas la región de análisis. Esta consideración debería ser abordada al realizar el amarre y la estimación de la ondícula tanto de manera manual como de manera automática.

La adaptación del método para el amarre de pozos *blocky* permite realizar el amarre respetando la información interpretada sobre las capas que conforman el subsuelo. En el ejemplo propuesto se utilizó un algoritmo de segmentación de pozos para definir el perfil *blocky*. Este algoritmo se apoya en una base estadística para definir los puntos de quiebre en el perfil y poder hacerlo *blocky*. Para el propósito de esta tesis, el algoritmo utilizado es suficiente para mostrar el alcance del proceso de automatización propuesto. Sin embargo, existen otras alternativas para obtener perfiles con estas características (Davis, 1986; Ligges et al., 2002) que se podrían utilizar sin afectar al método de amarre.

El fin del algoritmo propuesto es facilitar y optimizar el tiempo en las tareas de amarre de pozos y ajuste de la ondícula sísmica, en caso de no contar con una primera



**Figura 5.10.** Ejemplo dato de campo blocky: en gris el perfil observado, en negro el perfil observado *blocky* y en rojo el perfil perturbado luego del amarre, b) curva  $\rho(z)$  con  $M = 10$  y  $P = 0.1$ , c) y d) en rojo trazas sintética y en negro traza observada antes y después de aplicar el método propuesto.

estimación apropiada. En este caso, esto se lleva a cabo planteando estos dos procesos en simultáneo como un único proceso de optimización. El algoritmo requiere ajustar dos parámetros de entrada para su funcionamiento. Estos podrían estar definidos por defecto y permitir que se modifiquen como opciones avanzadas según las necesidades del intérprete.

Es importante mencionar que la estrategia detrás del algoritmo propuesto para perturbar el perfil sísmico tiene gran potencial para ser utilizada en otras aplicaciones en el campo de la geofísica. Particularmente, en aquellas donde DTW y LSIM han tenido éxito. Estas incluyen tareas como correlaciones entre perfiles de pozos (Anderson y Gaby, 1983), calibración de VSP y conversión a profundidad (Hackert y Parra, 2002) o correlaciones entre perfiles y núcleos de rocas extraídos de perforaciones (Price et al., 2008).

## 5.7. Conclusiones

El método propuesto permite llevar a cabo el proceso automático del amarre de pozos y, en simultáneo, estimar la fase de la ondícula sísmica. El uso de los splines cúbicos monotónicos como método de interpolación entre los nodos para perturbar suavemente el perfil de velocidades observado permite obtener cambios en la velocidad controlados, garantizando que las mediciones del perfil registrado sean respetadas dentro de cierta tolerancia. Por medio de ejemplos, se mostró que el método es estable y permite obtener resultados confiables, especialmente cuando la selección de los parámetros (número de nodos y cambios máximos permitidos en la velocidad) es conservadora.

Los resultados en datos pseudo-sintéticos y de campo muestran que es posible obtener valores altos del coeficiente de correlación entre las trazas sintéticas y sísmicas, así como estimaciones aceptables de la fase de la ondícula sísmica. Además, se mostró que el método propuesto puede ser utilizado para realizar el amarre de pozos cuando los perfiles observados son de tipo *blocky*. En este caso, mediante un ejemplo de datos de campo, se observa que también se logra mejorar la correlación entre las trazas sintética y observada, obteniendo una estimación confiable de la ondícula.

Una ventaja adicional de este método es que la traza sintética resultante no es estirada ni comprimida durante el proceso de amarre, como puede ocurrir en el caso manual o con DTW. El sintético final preserva la forma de la ondícula en todo momento, característica que contribuye a una mejor interpretación del dato sísmico.

# Capítulo 6

## Deconvolución *sparse-spike* basada en información de pozos y realce en frecuencias

### 6.1. Introducción

La estimación de la reflectividad a partir de datos sísmicos puede verse como un problema inverso (Robinson y Treitel, 2008), donde el objetivo es eliminar el efecto de la ondícula sísmica. Sin embargo, debido a que los datos sísmicos son de banda limitada y generalmente contienen ruido, este es un problema inverso mal condicionado que admite muchas soluciones que se ajustan al dato observado, es decir, no hay unicidad en la solución. Además, estas soluciones a menudo muestran valores altos de la norma  $l_2$  que las hace inestables y carentes de significado físico. Por lo tanto, como se discutió en el Capítulo 3, es necesario incorporar algún tipo de restricción y/o información *a priori* para reducir la no-unicidad del problema. Los métodos para incorporar este tipo de información al problema de inversión están en constante desarrollo, especialmente en problemas geofísicos (Tarantola, 2005; Menke, 2018).

En los últimos años, se han desarrollado varios algoritmos de deconvolución con el objetivo de impartir características deseables a las soluciones estimadas. En particular, las soluciones *sparse-spike* o ralas son preferidas porque presentan reflectores bien resueltos que mejoran el ancho de banda de las soluciones clásicas obtenidas mediante el uso de la norma  $l_2$  (Debye y van Riel, 1990). Como ejemplo, se pueden mencionar los trabajos de Taylor et al. (1979), quienes utilizaron programación lineal y regularizaron el problema mediante la norma  $l_1$  para estimar soluciones tipo *sparse-spike* de la reflectividad, mientras estimaba simultáneamente la ondícula, proceso conocido como deconvolución a ciegas (*blind deconvolution*). Oldenburg et al. (1983) estimaron reflectividades *sparse* usando programación lineal y técnicas autoregresivas para incorporar restricciones en la impedancia. Sacchi (1997), en lugar de utilizar la norma  $l_1$ , empleó un procedimiento de repesado (*reweighting*) de la solución para obtener reflectividades con un aumento en el ancho de banda. Pérez y Veils (2011) estimaron la

posición de un número fijo de *spikes* en datos *poststack* y *prestack* utilizando técnicas de optimización global. Esta estrategia permite ajustar otros parámetros como la fase de la ondícula durante el proceso de inversión; sin embargo, requiere estimar la cantidad de reflectores a ajustar y el uso de un algoritmo de optimización global, lo que la hace computacionalmente costosa. Utilizando FISTA (Beck y Teboulle, 2009) y mínimos cuadrados, Pérez et al. (2013) estimaron reflectividades *sparse-spike* a partir de datos *prestack*, regularizando el problema inverso mediante la norma  $l_{2,1}$ . También a partir de datos *prestack*, Pérez et al. (2017) encontraron soluciones de tipo *blocky* para las velocidades de las ondas P y S y la densidad, utilizando como regularización la norma mixta  $l_{2,1}$ , que conduce a soluciones de tipo *sparse-spike* con estructura. De manera similar, la regularización por *totalvariation* permite obtener imágenes de impedancia de alta resolución con continuidad lateral a partir de datos *poststack* (Pérez y Velis, 2018). En el contexto de la deconvolución a ciegas (*blind deconvolution*), Kazemi (2018) emplea un algoritmo modificado de mínimos cuadrados completos para estimar simultáneamente la reflectividad y la ondícula, mientras que Sui y Ma (2020) usa la norma atómica para estimar soluciones de tipo *sparse-spike* que preserven la continuidad lateral. En el campo de la inteligencia artificial, Pereg et al. (2020) utiliza redes neuronales recurrentes para explotar la información temporal que pueden extraer este tipo de arquitecturas y obtener soluciones de tipo *sparse-spike*. Arquitecturas como los *encoders-decoders* han sido utilizadas para realizar deconvoluciones de tipo *sparse-spike* multi-traza (Chai et al., 2021).

Aunque todas estas técnicas han demostrado ser útiles en diversas situaciones, la mayoría se basan únicamente en los datos sísmicos, ignorando otras fuentes de información como, por ejemplo, datos de registros de pozos. No incorporar esta información puede aumentar la ambigüedad en las soluciones y generar resultados que se aparten de la geología de la región donde se obtuvo el dato. En este contexto, dicha información puede integrarse a través de un modelo inicial que sea perturbado adecuadamente durante el proceso de inversión hasta converger a una solución aceptable, lo que permite restringir y estabilizar el problema de inversión (Cooke y Schneider, 1983). En el caso de datos de pozo, el modelo inicial generalmente es obtenido por un intérprete que identifica manualmente los horizontes, lo que puede afectar directamente los resultados de la inversión, dependiendo de las imprecisiones en la interpretación (Zhang y Castagna, 2011).

En este capítulo, presentamos un método de inversión *sparse-spike* con el fin de superar las limitaciones descritas anteriormente. El método propuesto fuerza a la solución a honrar cualquier modelo de reflectividad *sparse-spike* derivado de la información de pozo. La estrategia consiste en perturbar dicha reflectividad de manera iterativa para minimizar el error entre una traza sintética calculada y una traza observada. Para esto, se construye una función de deformación mediante un interpolador lineal a trozos con un número fijo de nodos. Se utiliza *Very Fast Simulated Annealing* (VFSA) (Ingber, 1989) para resolver el problema de optimización multimodal y no lineal, estimando las coordenadas óptimas de los nodos que minimicen el error cuadrático medio entre el dato observado y el sintético. La amplitud de los *spikes* se calcula

mediante mínimos cuadrados en cada iteración de VFSA. La traza sintética se obtiene convolucionando una ondícula, que asumimos conocida, con la reflectividad perturbada. El método descrito en el Capítulo 5 se utiliza para estimar la ondícula, basándose en la información de pozo. Entre las posiciones de los nodos, se impone una restricción que evita soluciones sin significado físico. El proceso de deconvolución comienza con la traza más cercana al pozo y se repite traza a traza a partir de ella. La reflectividad final obtenida para una traza se utiliza como modelo inicial para deconvolucionar la siguiente. De esta forma, los cambios en la reflectividad son suaves desde un punto de vista espacial, mientras que se conservan las características principales de la reflectividad en el pozo. La hipótesis principal es que dos reflectividades contiguas contienen el mismo número de *spikes*, con posiciones y amplitudes idénticas, lo que hace que esta estrategia sea óptima para procesar datos con una complejidad geológica de baja a moderada. Se demuestra, mediante datos sintéticos y de campo, que el método propuesto permite obtener reflectividades *sparse-spike* que se ajustan tanto al dato observado como a la información de pozo, incluso en presencia de ruido significativo o cuando la fase de la ondícula no es conocida con precisión. También se muestra que, al convolucionar la solución con ondículas de mayor ancho de banda que el de la señal original, se pueden obtener soluciones de alta resolución.

Este capítulo se estructura de la siguiente manera. En primer lugar, se presentan algunos conceptos teóricos fundamentales y se describe el método propuesto, detallando sus ecuaciones, hipótesis y el paso a paso del algoritmo. A continuación, se realizan pruebas con datos sintéticos, analizando los distintos parámetros y su impacto en la solución. Luego, se aplica la estrategia a datos de campo utilizando dos líneas sísmicas que comparten un mismo pozo. Finalmente, se presenta una discusión sobre la estrategia y se resumen las principales conclusiones.

## 6.2. Sobre la deconvolución *sparse-spike*

La estrategia propuesta se basa en el modelo convolucional presentado en el Capítulo 2. La  $i$ -ésima traza  $\mathbf{s}$  de dimensión  $L_s$  de una sección sísmica con  $N$  trazas se puede representar como

$$\mathbf{s}_i = \mathbf{W}\mathbf{r}_i + \mathbf{n}_i, \quad (6.1)$$

donde  $\mathbf{r}_i$  es la reflectividad de dimensión  $L_r$ ,  $\mathbf{W}$  es la matriz de convolución con dimensión  $L_s \times L_r$  que se construye con los elementos de la ondícula  $\mathbf{w}$  de dimensión  $L_w$ , y  $\mathbf{n}_i$  es ruido aleatorio con dimensión  $L_s$ . Sin pérdida de generalidad, se asume que la ondícula es la misma para todo el conjunto de trazas y que es conocida de antemano o al menos que se puede estimar de manera adecuada a partir de los datos.

Asumiendo ruido blanco gaussiano, una solución conservadora para la reflectividad  $\mathbf{r}_i$  se puede encontrar minimizando la función de costo

$$J(\mathbf{r}_i) = \|\mathbf{W}\mathbf{r}_i - \mathbf{s}_i\|_2^2 + \lambda \|\mathbf{r}_i\|_2^2. \quad (6.2)$$

Este enfoque, conocido como regularización de Thikhonov, lleva a la solución de mínimos cuadrados

$$\mathbf{r}_j = (\mathbf{W}^T \mathbf{W} + \lambda \mathbf{I})^{-1} \mathbf{W}^T \mathbf{s}_j, \quad (6.3)$$

donde  $\mathbf{I}$  es la matriz identidad,  $\lambda$  es el parámetro de *trade-off* que permite estabilizar la solución; sino, ante la presencia de ruido,  $\mathbf{r}_j$  sería inestable y sin utilidad. Este enfoque es frecuentemente de poca utilidad, dado que presenta una falta de resolución para valores de  $\lambda$  grandes y es inestable para valores pequeños. Ambas peticiones de estabilidad y alta resolución se pueden obtener forzando la solución a ser de tipo *sparse* en lugar de la norma mínima mediante distintos enfoques, como los propuestos por Oldenburg et al. (1983), Velis (2008), y Pérez et al. (2013). En particular, Velis (2008) propone una reflectividad con un número pequeño  $M$  de coeficientes distintos de cero, donde su posición en tiempo y amplitud son las incógnitas en un problema de optimización no lineal. El problema de encontrar la posición lo resuelve iterativamente con VFSA, mientras que las amplitudes las obtiene en cada iteración mediante

$$\mathbf{a}_j = (\mathbf{B}^T \mathbf{B} + \lambda \mathbf{I})^{-1} \mathbf{B}^T \mathbf{s}_j, \quad (6.4)$$

donde  $\mathbf{B}$  es una matriz  $L_s \times M$  formada con las columnas de  $\mathbf{W}$  cuyos índices son aquellos de los componentes no cero de  $\mathbf{x}$ . Esto es  $B_{jm} = w_{j-\tau_m+1}$ , donde  $\tau_m$  es la posición de los tiempos  $\mathbf{a}_m$ . Aún si el parámetro de *trade-off* fuera nulo, la estabilidad de la solución está asegurada si la reflectividad es lo suficientemente *sparse* ( $M \ll L_r$ ). Dado que,  $\mathbf{B}^T \mathbf{B}$  es una matriz pequeña el costo computacional asociado al resolver la ecuación 6.4 es muy bajo. La estrategia que se presenta tiene un objetivo similar, pero se fuerza a la solución a honrar no solo el dato sísmico sino también la información de pozo existente. Por otro lado, se estiman las posiciones en tiempo de los reflectores en forma progresiva mediante la perturbación de un modelo inicial *sparse-spike* con una función de deformación (*warping function*). Las coordenadas de los nodos que permiten crear esta función de deformación son incógnitas en este problema y se estiman usando VFSA. Por otro lado, las amplitudes de los *spikes* se computan mediante mínimos cuadrados con una restricción para conservar la continuidad lateral.

### 6.3. Deconvolución *sparse-spike* y realce en frecuencias

La inversión propuesta comienza con una reflectividad *sparse* obtenida a partir de los datos de pozo, que contiene  $M$  *spikes*. Esta reflectividad se ajusta adecuadamente a las trazas cercanas al pozo utilizando la técnica de atado de pozos, descrita en el Capítulo 5. Esta técnica también permite ajustar la fase de la ondícula a la cual se asume constante durante el proceso de amarre. La reflectividad inicial obtenida del pozo se genera mediante un algoritmo de zonificación que segmenta automáticamente los datos del registro en un número predefinido de intervalos, que son estadísticamente independientes (Velis, 2007).

Una vez que  $\mathbf{r}$  ha sido calibrada correctamente con los datos sísmicos, se procede a estimar las reflectividades traza por traza, perturbando ligeramente la reflectividad para usarla como punto de partida para la traza siguiente. Este proceso sigue un enfoque en dos etapas, que se describe a continuación.

### Primer etapa: función de deformación

Para cada traza  $i$ -ésima, se estima la posición de los *spikes* en  $\mathbf{r}_i$  perturbando los de  $\mathbf{r}_{i-1}$  mediante una función de deformación a trozos monotónica, definida a partir de los nodos  $(x_k, y_k)$ ,  $k = 1, \dots, K$ . Por simplicidad, los nodos externos  $(x_0, y_0)$  y  $(x_{K+1}, y_{K+1})$  se fijan en  $(t_0, t)$  y  $(t_f, t)$ , respectivamente, donde  $t_0$  y  $t_f$  son las muestras inicial y final de la ventana de tiempo considerada. Los  $K + 1$  segmentos de la función se definen como:

$$f_k(t) = y_k + \frac{y_{k+1} - y_k}{x_{k+1} - x_k} (t - x_k), \quad k = 0, 1, \dots, K. \quad (6.5)$$

Estas funciones se aplican elemento a elemento a los índices de tiempo de  $\mathbf{r}_i$  para  $t \in (x_k, x_{k+1}]$ . La salida es una nueva serie de índices temporales que se usan para mapear los elementos de  $\mathbf{r}_i$  a sus nuevas posiciones en  $\mathbf{r}_i$  (reflectividad perturbada). El objetivo de la perturbación es obtener una reflectividad  $\mathbf{r}_i$  que se ajuste a los datos  $\mathbf{s}_i$  después de la convolución con la ondícula. La búsqueda de las coordenadas óptimas de los nodos  $(x_k, y_k)$ , que minimicen la diferencia entre la traza sintética y la observada, es un problema de optimización no lineal y multimodal que se resuelve utilizando VFSA (Ingber, 1989). En el Apéndice A.3 se presenta una descripción más detallada de este algoritmo de optimización.

Para evitar que los *spikes* se crucen en el tiempo, el orden de los índices en  $\mathbf{r}_i$  debe ser el mismo que en  $\mathbf{r}_{i-1}$ . Esto requiere que la función de deformación sea monotónica. Además, dado que este es un proceso traza a traza, se espera que las variaciones de  $\mathbf{r}_i$  a  $\mathbf{r}_{i-1}$  sean pequeñas, lo que implica restringir la perturbación de los nodos. Para asegurar estos requerimientos, se introduce un esquema de restricción de borde dinámico dentro de la etapa de perturbación de VFSA, de manera que cada coordenada de los nodos esté limitada por las coordenadas de los nodos vecinos en cada iteración de VFSA.

En la práctica, primero se modifican las coordenadas  $y_k$  llevándolas a sus nuevas posiciones  $y'_k = y_k + \Delta y_k$ , de manera secuencial para  $k = 1, \dots, K$  donde  $\Delta y_k$  representa las correspondientes perturbaciones. En esta etapa, las coordenadas horizontales no se modifican. Para garantizar la monotonicidad, se requiere que  $y_{k-1} \leq y'_k \leq y_{k+1}$ ,  $\forall k$ . Además, para forzar pequeñas perturbaciones, se establece que  $x_k + d \leq y'_k \leq x_k - d$  donde  $d$  es una pequeña distancia de tolerancia (en milisegundos o muestras). Estas restricciones de borde son dinámicas y deben actualizarse antes de perturbar cada  $y_k$  en cada iteración de VFSA. Dichas restricciones para  $y_k$  se pueden expresar como:

$$\max(y_{k-1}, x_k - d) \leq y'_k \leq \min(y_{k+1}, x_k + d). \quad (6.6)$$

Una vez perturbadas todas las coordenadas  $\mathbf{y}_k$ , se procede a perturbar las coordenadas  $\mathbf{x}_k$  siguiendo un esquema de restricción similar:

$$\max(\mathbf{x}_{k-1}, \mathbf{y}_k - \mathbf{d}) \leq \mathbf{x}_k \leq \min(\mathbf{x}_{k+1}, \mathbf{y}_k + \mathbf{d}). \quad (6.7)$$

Alternativamente, se puede optar por perturbar primero las coordenadas  $\mathbf{x}_k$  y luego  $\mathbf{y}_k$ , sin afectar los resultados.

### Segunda etapa: ajuste de amplitudes

Para encontrar la amplitud óptima de los *spikes* en cada iteración del VFSA, se utiliza la ecuación 6.4, que se obtiene al minimizar  $\|\mathbf{B}\mathbf{a}_i - \mathbf{s}_i\|_2^2$ , añadiendo un término de regularización cuadrático para garantizar la estabilidad de la solución (Velis, 2008). Sin embargo, dado que se espera que  $\mathbf{r}$  sea similar a  $\mathbf{r}_{-1}$ , se incorpora un término adicional en la función de costo que contemple esta similitud. En la práctica, las amplitudes óptimas se determinan minimizando la siguiente función:

$$J(\mathbf{a}_i) = \|\mathbf{B}\mathbf{a}_i - \mathbf{s}_i\|_2^2 + \lambda \|\mathbf{a}_i - \mathbf{a}_{i-1}\|_2^2, \quad (6.8)$$

donde  $\mathbf{a}$  y  $\mathbf{a}_{i-1}$  son vectores que contienen  $M$  elementos distintos de cero de  $\mathbf{y}$  y  $\mathbf{r}_{-1}$ , respectivamente. El parámetro  $\lambda$  es el *trade-off* que permite controlar la continuidad lateral de la traza deconvolucionada. La solución final es:

$$\mathbf{a}_i = (\mathbf{B}^T\mathbf{B} + \lambda\mathbf{I})^{-1} \mathbf{B}^T\mathbf{s}_i + \lambda\mathbf{a}_{i-1}. \quad (6.9)$$

### Realce en frecuencias

Después de realizar la deconvolución, la sección de reflectividades *sparse* resultante puede convolucionarse con una ondícula sísmica de gran ancho de banda. Cualquier ondícula con lóbulos laterales moderados y un espectro plano debería producir un resultado aceptable. El intérprete puede experimentar con diferentes ondículas y anchos de banda. El realce en frecuencias óptimo, que es subjetivo, será determinado por la preferencia visual y el conocimiento de la zona de estudio (Ryan et al., 1994; Yilmaz, 2001).

### El algoritmo paso a paso

1. Dado los datos de pozo, seleccionar un número adecuado de bloques para segmentar los datos y construir la reflectividad inicial con  $M$  elementos distintos de cero (por ejemplo, utilizando el método propuesto por Velis (2007)).
2. Estimar la ondícula y la reflectividad inicial *sparse-spike*  $\mathbf{a}$  partir del atado de pozos de la reflectividad generada en el paso anterior y la traza observada más cercana (por ejemplo, utilizando el método descrito en el Capítulo 5).

3. Definir el número de nodos  $K$  para la función de deformación, el rango máximo de perturbación permitido  $d$ , y el parámetro de *trade-off*  $\lambda$  para controlar las variaciones de amplitud.
4. Para cada traza  $s$  y en cada iteración del VFSA, realizar lo siguiente:
  - a) Perturbar la reflectividad  $r_{-1}$  utilizando la ecuación 6.5 para obtener la nueva posición de los *spikes* (primer etapa).
  - b) Actualizar la matriz  $\mathbf{B}$  y estimar las amplitudes  $a$  utilizando la ecuación 6.9 (segunda etapa).
  - c) Construir la nueva reflectividad  $r$ , convolucionarla con la ondícula sísmica, y calcular el error (*misfit*) entre la traza sintética y la observada utilizando el primer término de la ecuación 6.2.
  - d) Revisar la convergencia o el criterio de corte.
5. Opcionalmente, convolucionar la sección de reflectividad *sparse-spike* final con una ondícula de mayor ancho de banda (Ej: Ormsby).

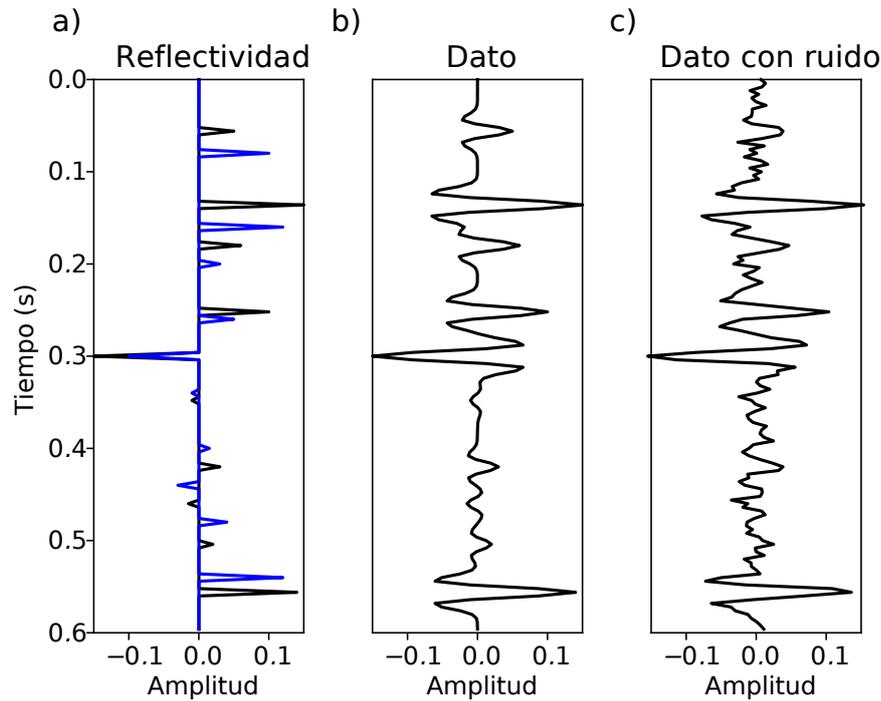
## 6.4. Resultados numéricos

Probamos la estrategia propuesta utilizando datos sintéticos y de campo. El primer ejemplo numérico ilustra la deconvolución *sparse-spike* 1D en un conjunto de datos ruidosos. El objetivo es demostrar la capacidad del esquema de perturbación en presencia de ruido, así como analizar el efecto del número de nodos en la consistencia y precisión de los resultados. Para ello, se llevó a cabo un estudio estadístico empleando diferentes realizaciones.

Posteriormente, el algoritmo se pone a prueba con datos sintéticos en 2D con ruido, donde se analiza el impacto del parámetro de *trade-off* en la continuidad lateral de las soluciones obtenidas. También se investiga cómo las variaciones en la fase de la ondícula afectan las soluciones estimadas. Finalmente, se aplica el método propuesto a datos de campo en 3D, realizando un realce en frecuencia al convolucionar las reflectividades obtenidas con dos ondículas de Ormsby apropiadas.

### 6.4.1. Ejemplo sintético 1D

La línea negra en la Figura 6.1a muestra la reflectividad *sparse-spike* utilizada para generar las trazas sintéticas en los paneles b y c de la misma figura. Estas trazas fueron creadas con una ondícula de Ricker de 30 Hz y ruido de banda limitada. La línea azul en la Figura 6.1a representa la reflectividad inicial que se utiliza como entrada para el algoritmo, la cual fue obtenida perturbando la reflectividad original con una función de deformación con  $K = 5$ . Esta reflectividad perturbada simula lo que sucedería en un escenario real, donde el modelo inicial de reflectividad obtenido a partir de información

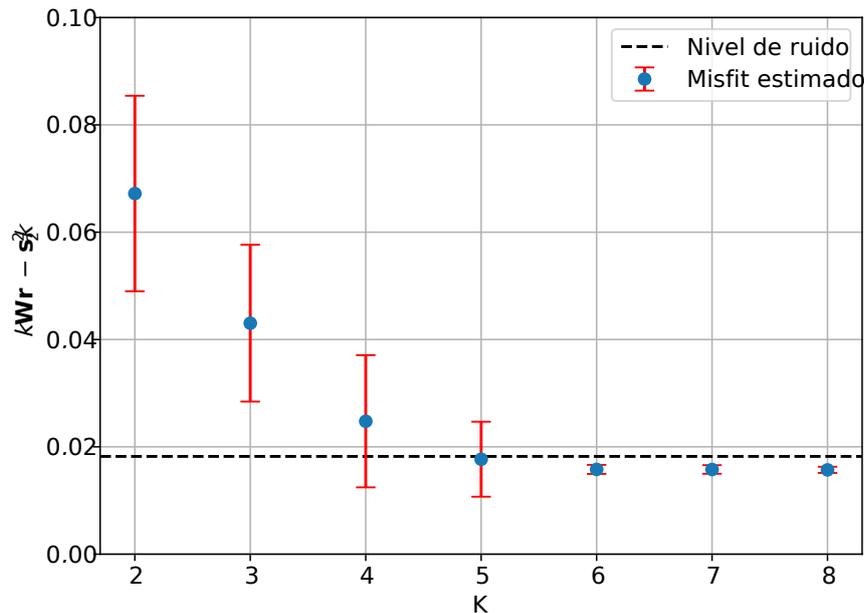


**Figura 6.1.** Dato sintético 1D. a) Reflectividad real (negro) e inicial (azul). b) Dato sin ruido. c) Dato con ruido ( $S/N=5$ ).

de pozos (o cualquier otra fuente) difiere de la reflectividad obtenida al procesar las trazas cercanas.

Para aplicar el algoritmo propuesto, primero se deben seleccionar los parámetros  $K$  y  $d$ . Al utilizar la función de deformación, estos parámetros regulan cuánto se puede estirar o acortar la reflectividad en el tiempo. La libertad para modificar la reflectividad aumenta al tomar valores más altos de estos parámetros, mientras que el *misfit* entre la traza sintética y la observada disminuye. Sin embargo, elegir valores grandes de  $d$  y  $K$  para obtener valores pequeños del *misfit* puede resultar en soluciones de reflectividad sin significado físico. Por el contrario, valores muy pequeños de estos parámetros podrían llevar a un ajuste incorrecto de los datos observados. Este es el mismo *trade-off* que se presenta al resolver el problema de amarre de pozos visto en el Capítulo 5. En general, los parámetros se eligen en función de varias consideraciones, como el nivel de ruido y la continuidad lateral de los datos, y dependen del análisis de las soluciones y del juicio personal. Dado que se asume que el modelo inicial es cercano a la reflectividad real, la selección de  $d$  es menos crítica que la de  $K$ , por lo que valores moderados a bajos de  $d$  son adecuados para imponer una restricción razonable en la solución final.

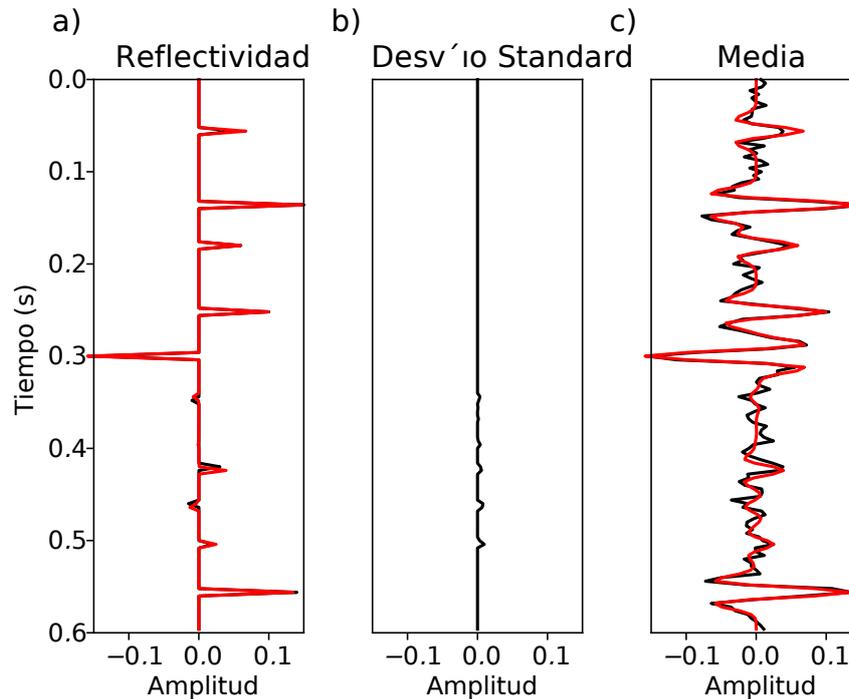
La Figura 6.2 muestra la media y el desvío estándar del *misfit* resultante tras resolver el problema de deconvolución para el dato ruidoso con valores  $K$  variables y  $d$  fijo en 10 muestras. Con fines estadísticos, se realizaron 100 realizaciones en cada caso, donde cada realización implicó el uso de diferentes semillas para la generación



**Figura 6.2.** Ejemplo sintético 1D. Media y desvío estándar del *misfit* vs. número de nodos (100 realizaciones).

aleatoria del ruido y la inicialización del VFSA. Al analizar la figura, se observa que para  $K < 5$ , la mayoría de las soluciones no ajustan correctamente el dato observado. Cuando  $K = 5$ , que es el número de nodos con el que se creó el dato sintético, el valor promedio está apenas por encima del nivel de ruido. Aún así, algunas soluciones no logran un ajuste satisfactorio. Para valores de  $K > 5$ , como era de esperarse, la mayoría de las soluciones están por debajo del nivel de ruido y sus desvíos estándar son muy pequeños. Es importante notar que el nivel de ruido es independiente de  $K$  y depende únicamente de los datos. Así, si el *misfit* entre el dato observado y el estimado está por encima del nivel de ruido, se trata de un subajuste; si está por debajo, se está ante un sobreajuste del ruido. Para los valores de  $K > 5$ , se puede observar que los valores del *misfit* están ligeramente por debajo del nivel de ruido, lo que indicaría un sobreajuste. Dado que la figura ilustra medias y desvíos estándar para las 100 soluciones de cada valor de  $K$ , se espera que no todas las soluciones para  $K > 5$  muestren sobreajuste.

Los mayores desvíos estándar observados para  $K \leq 5$  pueden explicarse por el ruido en los datos y el número limitado de iteraciones del VFSA. Para simplificar, se realizaron 10,000 iteraciones en todos los casos, un número que podría no ser suficiente para alcanzar el mínimo global, especialmente cuando el número de nodos es pequeño y la función de deformación no logra mover los *spikes* de manera adecuada. Por otro lado, la similitud en el comportamiento de las soluciones para  $K > 5$  es notable, lo que implica que aumentar el número de nodos no mejorará significativamente los resultados. Esto se debe a que, con muchos nodos, la función de deformación es lo suficientemente flexible como para mover los *spikes* a las ubicaciones correctas.



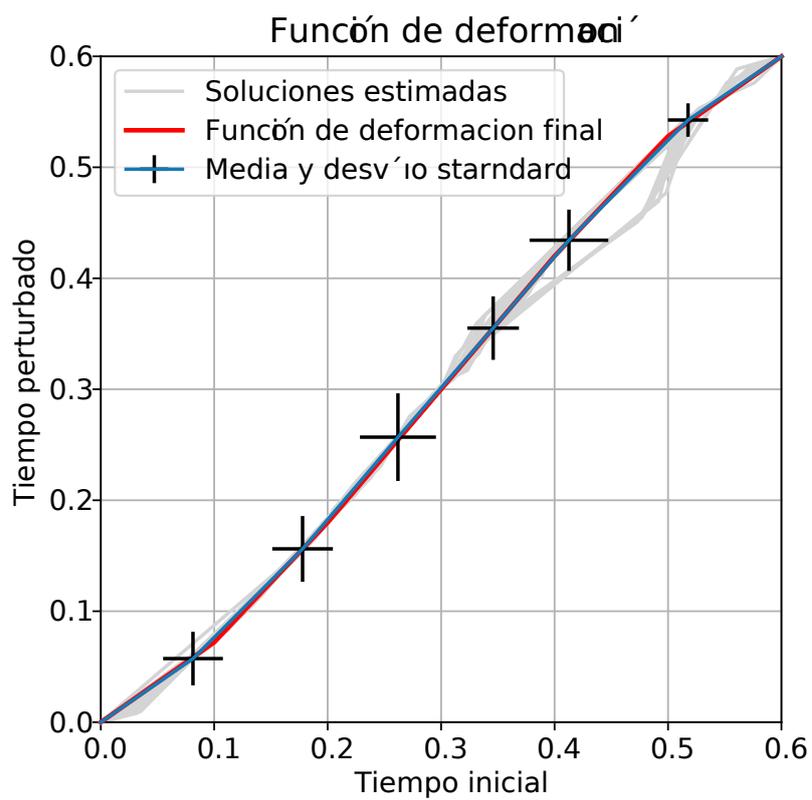
**Figura 6.3.** Ejemplo sintético 1D. a) Reflectividad real (negro) y estimada promedio luego de 100 realizaciones (rojo). b) Desvío estándar. c) Trazas observadas y promedio estimado (rojo).

La Figura 6.3 muestra los resultados para un caso de  $K = 6$ . Se puede observar que la solución promedio es prácticamente idéntica a la reflectividad real, mientras que los desvíos estándar individuales presentan valores muy pequeños, lo que indica una alta precisión. El tercer panel muestra que el ajuste con el dato observado es aceptable, como en la Figura 6.2. Sin embargo, entre 0.3 y 0.5 s, algunos reflectores son estimados con menor precisión, lo que genera un leve aumento en el desvío estándar. Este resultado es esperado, ya que la energía de la señal en esos tiempos es cercana al nivel de ruido (Figura 6.1).

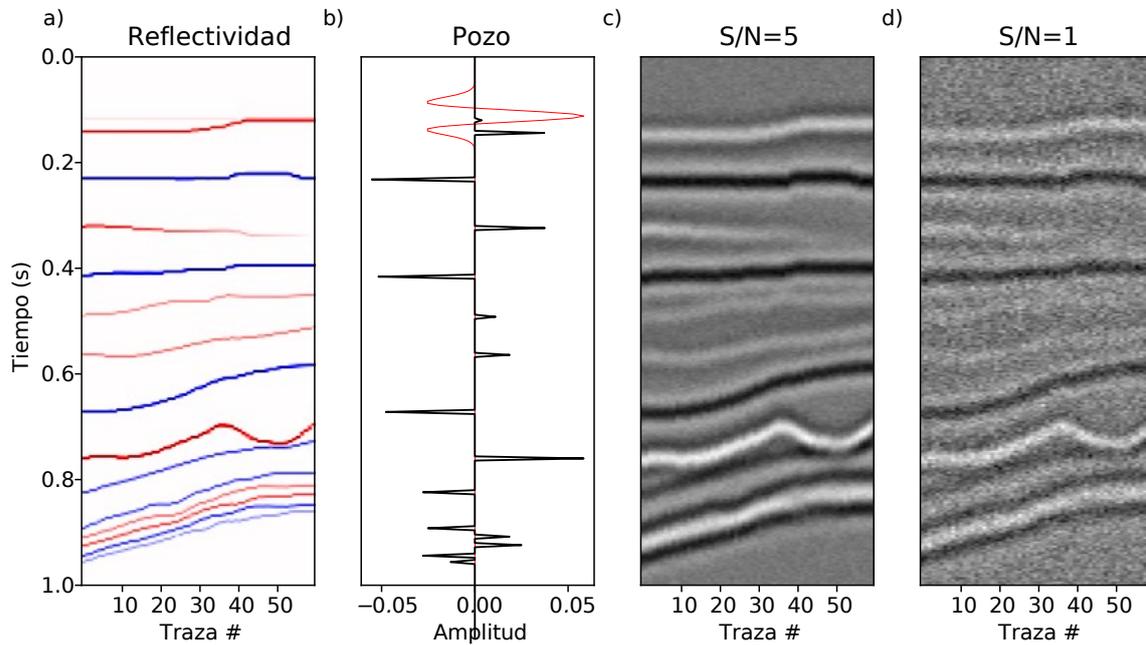
Finalmente, la Figura 6.4 muestra la función de deformación promedio junto con la función original y las 100 soluciones estimadas correspondientes. Se puede ver que, a pesar de la alta variabilidad en las coordenadas de los nodos entre los 0.3 y 0.5 s, existe una correspondencia estrecha entre las funciones de deformación reales y las estimadas.

### 6.4.2. Ejemplo sintético 2D

En este ejemplo se aplicó el algoritmo a un dato sintético 2D generado a partir del modelo Marmousi2 (Martin et al., 2006). Se analizó el efecto del parámetro de *trade-off*  $\lambda$ , el nivel de ruido y la ondícula en la continuidad lateral y las amplitudes de la reflectividad estimada. La Figura 6.5a muestra la reflectividad del modelo, la cual presenta dos partes con características diferentes. La parte superior está compuesta



**Figura 6.4.** Ejemplo sintético 1D. Función de deformación estimada (gris), real (rojo) y función de deformación promedio (azul) para  $K = 6$  (100 realizaciones). Las barras negras muestran los desvíos estándar para cada nodo.



**Figura 6.5.** Ejemplo sintético 2D. a) Sección reflectiva real. b) En negro, reflectividad inicial en la posición del pozo (ubicada en la primera traza), y en rojo, la ondícula utilizada. c) y d) Datos con ruido gaussiano  $S/N=5$  y  $S/N=1$ , respectivamente.

por reflectores bien definidos y separados, donde uno de ellos exhibe un decaimiento suave en amplitud hasta desaparecer. Aunque no es común que un reflector mantenga la misma polaridad y amplitud a lo largo de todas las trazas sísmicas, tampoco es esperable un cambio significativo de una traza a la otra. Por otro lado, la parte inferior de la sección muestra un paquete de reflectores muy cercanos entre sí, de amplitudes moderadas, con dos de ellos casi tocándose, lo que sugiere una formación de *pinch-out*.

La Figura 6.5b muestra la reflectividad inicial, que en este ejemplo corresponde a la reflectividad asociada a la primera traza del dato. Se asume que esta reflectividad representa el modelo *sparse-spike* obtenido a partir de la información de pozo en la ubicación de dicha traza, luego de ser calibrada mediante el amarre de pozos. Las Figuras 6.5c y d muestran secciones sintéticas con ruido blanco gaussiano con relaciones señal/ruido ( $S/N$ ) de 5 y 1, respectivamente. Estas secciones fueron generadas al convolucionar la reflectividad con una ondícula de Ricker de 30 Hz, que se muestra en rojo en la Figura 6.5b.

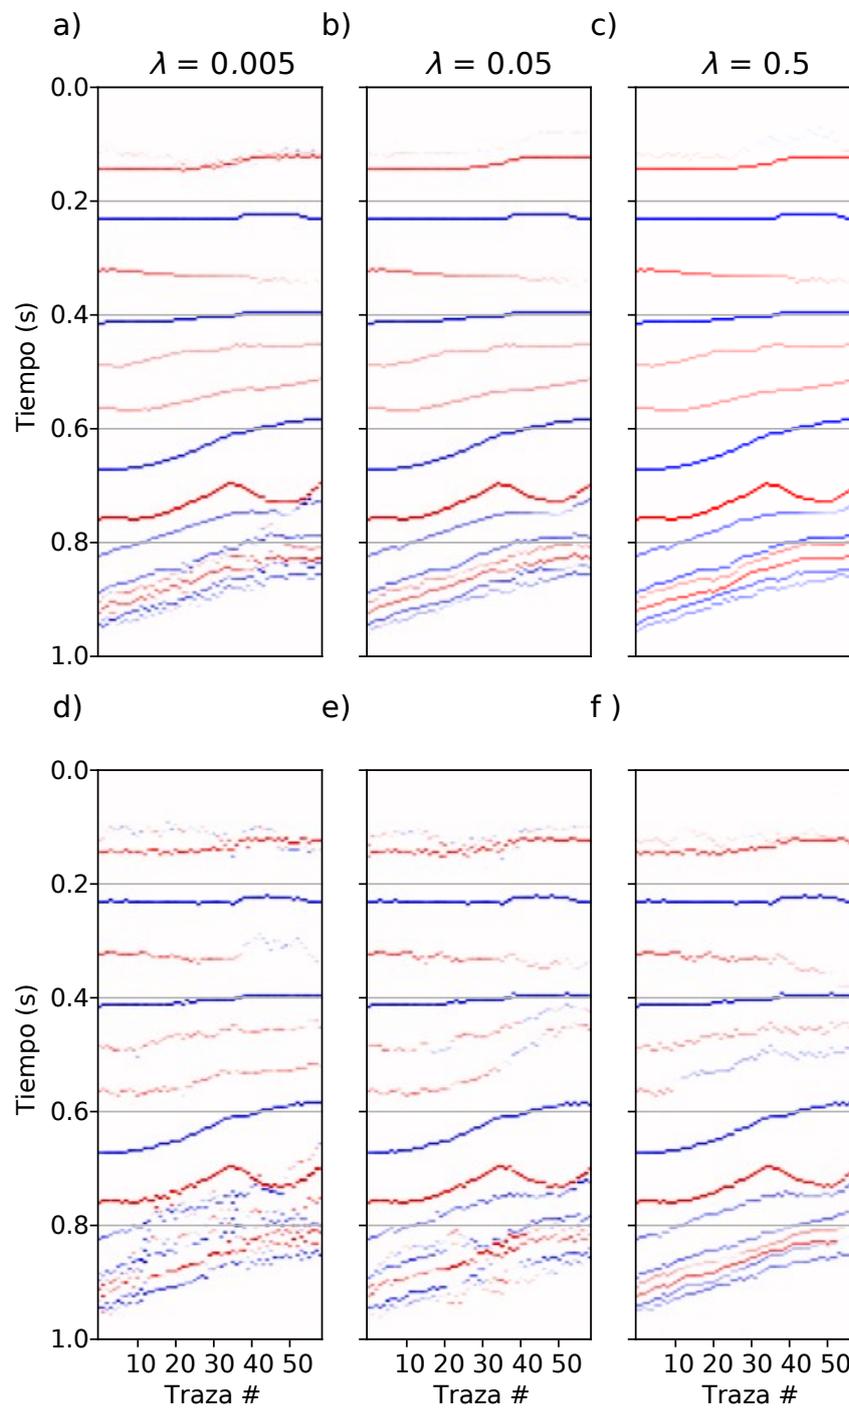
En todos los ejemplos se utilizó  $K = 10$  y  $d = 3$ . Al igual que en el ejemplo anterior, en el algoritmo de inversión se utilizó la misma ondícula con la que se creó el dato sintético. En cuanto al parámetro de *trade-off*, se consideraron tres casos:  $\lambda = 0.005$ ,  $\lambda = 0.05$  y  $\lambda = 0.5$ . Aunque existen diversas estrategias para seleccionar estos valores, como la curva-L, el principio de discrepancia o la validación cruzada (Farquharson y Oldenburg, 2004), en este caso los valores fueron elegidos manualmente. Cabe destacar

que los valores seleccionados cubren un rango amplio, lo que permite representar distintos escenarios y analizar su impacto en los resultados.

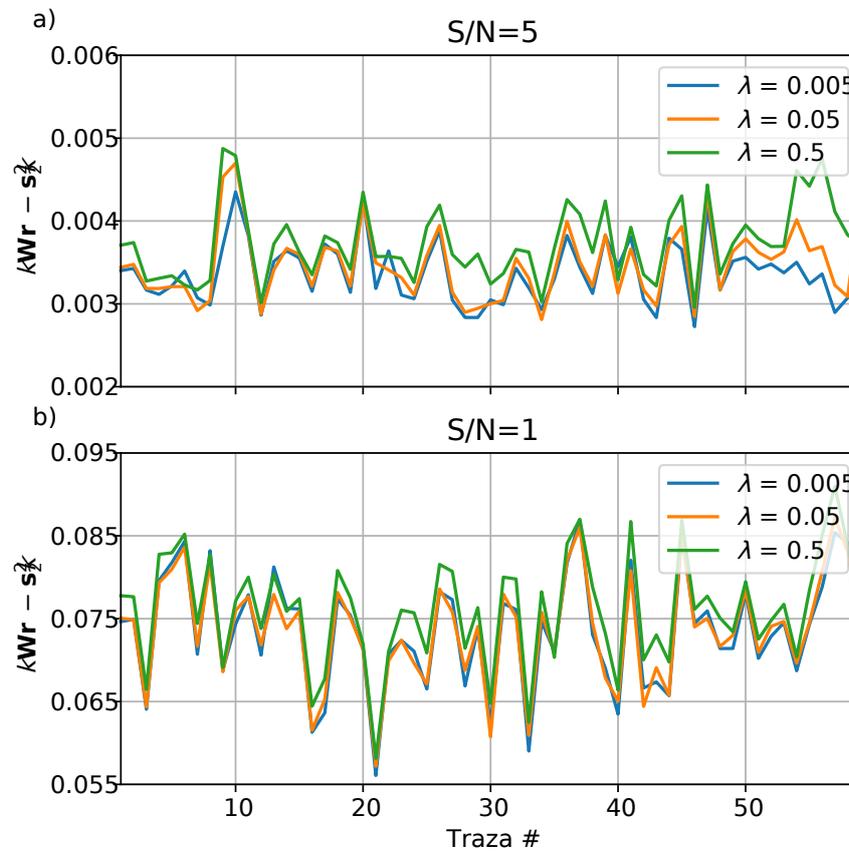
La primer fila de la Figura 6.6 muestra los resultados para el caso con  $S/N=5$ . En la parte superior de los datos, donde los reflectores están bien separados, el efecto de  $\lambda$  no es realmente significativo. En todos los casos, los reflectores principales se estiman correctamente, mostrando una continuidad lateral adecuada, incluso en el reflector con decaimiento de amplitud. A medida que se incrementa el valor de  $\lambda$ , la mejora en la continuidad lateral es casi imperceptible. En cuanto a la parte inferior de la sección, el efecto de este parámetro en la estimación de los reflectores es mucho más notable. Se puede observar que la calidad de la solución mejora con el aumento de  $\lambda$ . Para  $\lambda = 0.005$ , la continuidad lateral es deficiente, con reflectores que alternan posiciones de traza en traza e incluso desaparecen. Para  $\lambda = 0.05$ , hay una mejora en la estimación de las amplitudes, pero la continuidad lateral sigue siendo deficiente. Finalmente, para  $\lambda = 0.5$ , la solución estimada reproduce adecuadamente la reflectividad original, con buena continuidad lateral y estimación precisa de las amplitudes y posiciones.

La segunda fila de la Figura 6.6 muestra los resultados para el dato con  $S/N=1$ . Como era de esperarse, aunque se logra una estimación correcta de los rasgos principales, hay una disminución general en la calidad de los resultados. En la parte superior de la sección, donde los reflectores están bien definidos, las amplitudes se estiman de manera aceptable, pero la continuidad lateral es deficiente. El deterioro de la solución se hace más evidente con valores bajos de  $\lambda$ . En la parte media de los datos, entre los 0.4 s y 0.6 s, los reflectores no solo muestran poca continuidad lateral sino que también presentan cambios de polaridad, lo cual es esperable dado el bajo  $S/N$ . Finalmente, en la parte inferior, donde los reflectores están más cercanos entre sí, las soluciones con  $\lambda = 0.005$  y  $\lambda = 0.05$  prácticamente no tienen continuidad lateral y muestran amplitudes erráticas de traza en traza. Para  $\lambda = 0.5$ , hay una mejora considerable en la solución estimada. A pesar del alto nivel de ruido en los datos, la solución presenta una continuidad lateral aceptable y amplitudes consistentes.

La Figura 6.7 muestra el *misfit* entre las trazas observadas y estimadas para los valores de  $\lambda$  considerados y los dos niveles de ruido. A pesar de las diferencias entre las reflectividades estimadas en la Figura 6.6, los *misfits* son bastante similares, lo que indica que todas las soluciones honran el dato observado de manera similar. Sin embargo, se observa un ligero aumento general del error de ajuste con el incremento de  $\lambda$ . Esto es esperable, ya que mientras mayor sea este parámetro, mayor será el peso del segundo término en la ecuación 6.8, en detrimento del primer término. Como sucede con la mayoría de los parámetros de *trade-off*, es crítico seleccionarlo de manera conservadora: ni demasiado grande ni demasiado pequeño. Un valor muy grande puede forzar a las soluciones a mostrar una continuidad lateral exagerada, lo que resultaría en un mal ajuste del dato. Por otro lado, con un  $\lambda$  demasiado pequeño, el ajuste podría ser muy bueno, pero la continuidad lateral sería deficiente, como se observó en las Figuras 6.6a, d y e.



**Figura 6.6.** Ejemplo sintético 2D. Arriba: Reflectividades estimadas usando  $K = 10$ ,  $d = 3$  y a)  $\lambda = 0.005$ , b)  $\lambda = 0.05$  y c)  $\lambda = 0.5$ , para el caso de  $S/N=5$ . Abajo: idem para el caso de  $S/N=1$ .

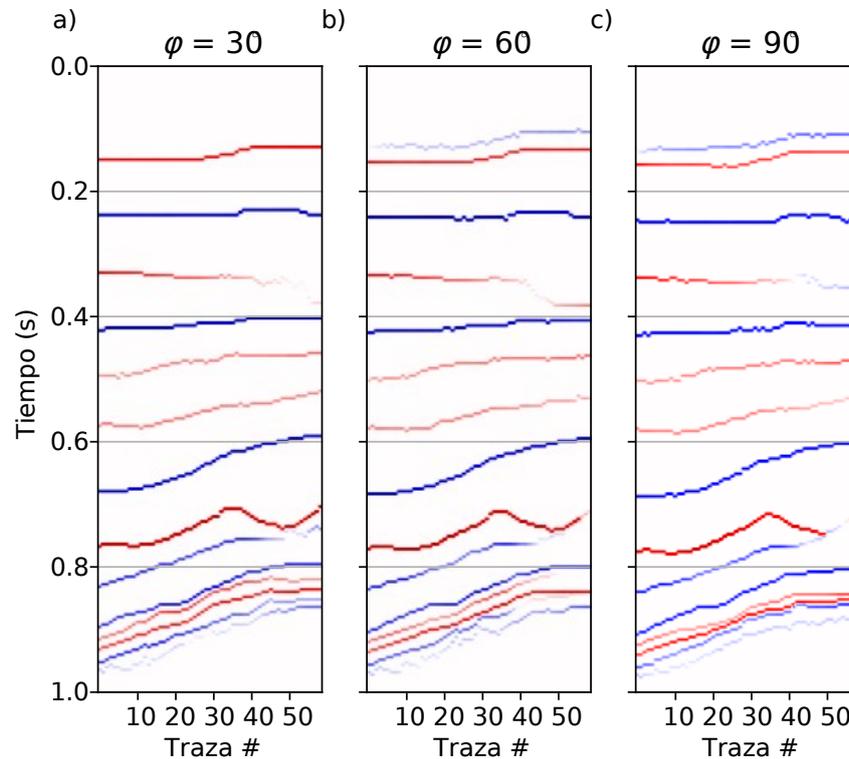


**Figura 6.7.** Ejemplo sintético 2D. Misfit traza a traza para los tres valores del parámetro de *trade-off* considerados para los datos con a)  $S/N=5$  y b)  $S/N=1$ .

### Análisis de sensibilidad en los errores de la ondícula

Se pone a prueba la robustez del algoritmo ante errores en la ondícula, repitiendo el ejemplo de la Figura 6.6c usando el mismo dato (Figura 6.5b) y los parámetros  $K = 10$ ,  $d = 3$ , y  $\lambda = 0.5$ , pero utilizando ondículas con una rotación de fase diferente a la utilizada para crear el dato. Los resultados se muestran en la Figura 6.8 para tres valores diferentes de la rotación.

Dado que una rotación de  $30^\circ$  no difiere demasiado de una ondícula de fase cero (Levy y Oldenburg, 1987), las reflectividades obtenidas son casi tan aceptables como las obtenidas con la ondícula original. La mayor diferencia se observa en los casos de rotación de  $60^\circ$  y  $90^\circ$ , donde el segundo lóbulo más grande se vuelve significativamente importante. Por ejemplo, el reflector superior parece separarse en dos reflectores opuestos con distinto signo. Esto se debe a que la reflectividad inicial presenta dos *spikes* en esa posición (uno más fuerte y otro más débil), y el algoritmo busca asignar un *spike* a cada lóbulo de la ondícula. Dado que el algoritmo no puede incorporar nuevos *spikes*, este problema de separación no se presenta en el reflector aislado alrededor de



**Figura 6.8.** Ejemplo sintético 2D. Reflectividades estimadas para los datos con  $S/N=5$  al utilizar una ondícula de Ricker de 30 Hz con tres rotaciones de fase constante.

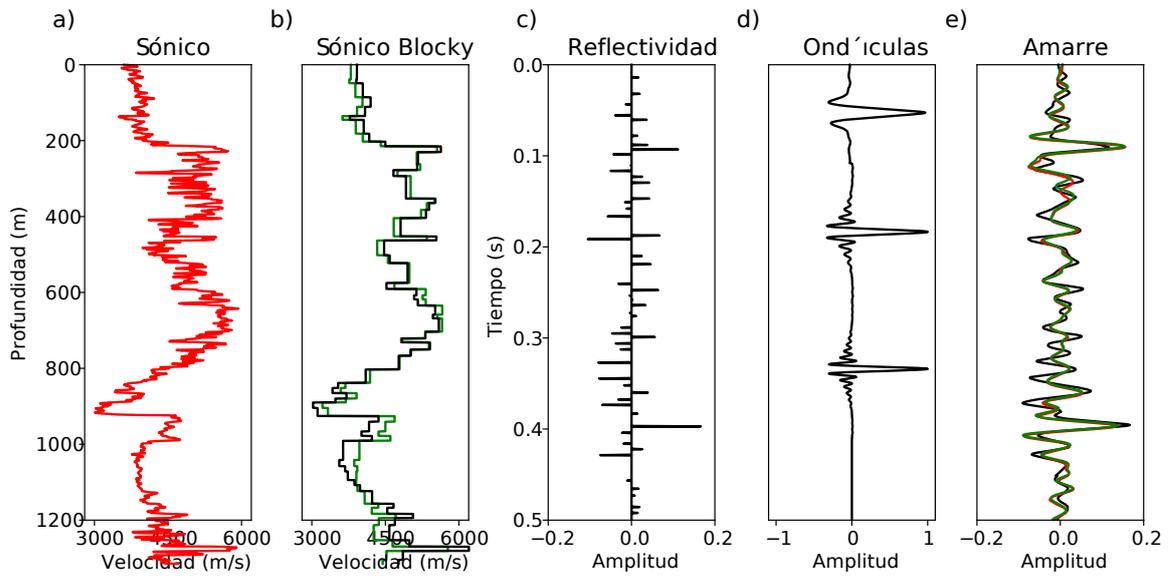
los 0.2-0.7 s. Aun así, dado que una rotación de fase es equivalente a aplicar un *time shift* (Robinson y Treitel, 2008), la mayoría de los reflectores se encuentran desplazados unos pocos milisegundos respecto a sus tiempos reales.

Como era de esperarse, la parte baja de los datos presenta el mayor desafío, dado que los reflectores cercanos interfieren con los lóbulos de la ondícula. Esto se observa claramente en las trazas a partir de la #40.

### 6.4.3. Datos de campo

En esta sección mostramos los resultados de aplicar el algoritmo en datos de campo. Para ello, utilizamos una *inline* y una *crossline* de un cubo sísmico migrado en tiempo. Además del dato sísmico, contamos con un pozo ubicado en la intersección de las dos líneas. La *inline* está compuesta por 50 trazas, mientras que la *crossline* presenta 200 trazas. Ambas líneas abarcan una ventana de tiempo de 0.5 s, y el dato tiene un intervalo de muestreo de 2 ms.

Como primer paso para poder utilizar el algoritmo propuesto, se debe obtener una reflectividad inicial y una ondícula apropiadas. El proceso para esto se ilustra en la Figura 6.9. El primer panel muestra en rojo el perfil sónico observado. En el segundo



**Figura 6.9.** Ejemplo de dato de campo. a) Perfil de velocidad observado. b) Perfiles de velocidad *blocky* y perturbado (negro y verde respectivamente). c) Reflectividad *sparse* inicial obtenida a partir del perfil perturbado. d) Ondícula estimada y las dos ondículas de Ormsby utilizadas para el realce en frecuencias. e) Amarre: Trazas sintética (negro), *inline* (rojo) y *crossline* (verde).

panel, con línea negra, se ve el perfil sónico *blocky* obtenido tras aplicar el método de zonificación descrito por Velis (2007). En el mismo panel, pero en color verde, se ve el modelo *blocky* obtenido luego de utilizar el método de atado de pozos descrito en el Capítulo 5.

El tercer panel muestra la reflectividad *sparse* inicial obtenida de dicho perfil sónico *blocky*. El cuarto panel muestra tres ondículas: la primera es la estimada simultáneamente al atar el pozo, garantizando un ajuste adecuado con las trazas observadas dentro de un margen de error aceptable. Las otras dos ondículas se utilizarán para el realce en frecuencia después de la deconvolución. El quinto panel muestra el ajuste entre las trazas observadas de las *inline* y *crossline* con la traza sintética, donde se puede ver que la construcción de la reflectividad *sparse-spike* es satisfactoria y sirve como un buen punto de partida para el proceso de deconvolución de las trazas restantes.

La Figura 6.10a muestra el dato observado, *crossline* e *inline*, y la reflectividad inicial. Como se puede observar, en el dato hay algunos reflectores fuertes con buena continuidad lateral, características deseadas dentro de las hipótesis del método propuesto. Para obtener la reflectividad *sparse-spike*, se aplicó el algoritmo utilizando  $k_0 = 10$ ,  $d = 3$  y  $\lambda = 0.1$ . La reflectividad estimada se muestra en la Figura 6.10b, y es consistente con los reflectores observados en el pozo, mostrando además una buena continuidad lateral.

Las Figuras 6.10c y d presentan los resultados del realce en frecuencia obtenido al convolucionar la reflectividad estimada con dos ondículas de Ormsby, que se muestran

en la Figura 6.9d. Estas ondículas tienen un ancho de banda en frecuencia de 5-15-100-120 Hz y 5-15-130-150 Hz respectivamente. La elección de estas ondículas se basó en que son de fase cero y presentan un espectro plano que se puede controlar fácilmente (Ryan et al., 1994). En las imágenes realizadas se observa una mejor definición de algunos reflectores, particularmente entre los 0.3 y 0.5 s, y en las trazas 80-150 de la *crossline*. La Figura 6.11 muestra en detalle esta zona.

Es importante destacar que estos reflectores son consistentes con la información de los registros de pozo. Aunque los datos originales de baja resolución no contienen suficiente información para ser resueltos correctamente, las imágenes realizadas, que se apoyan en los registros de pozo para la información faltante, sí lo logran.

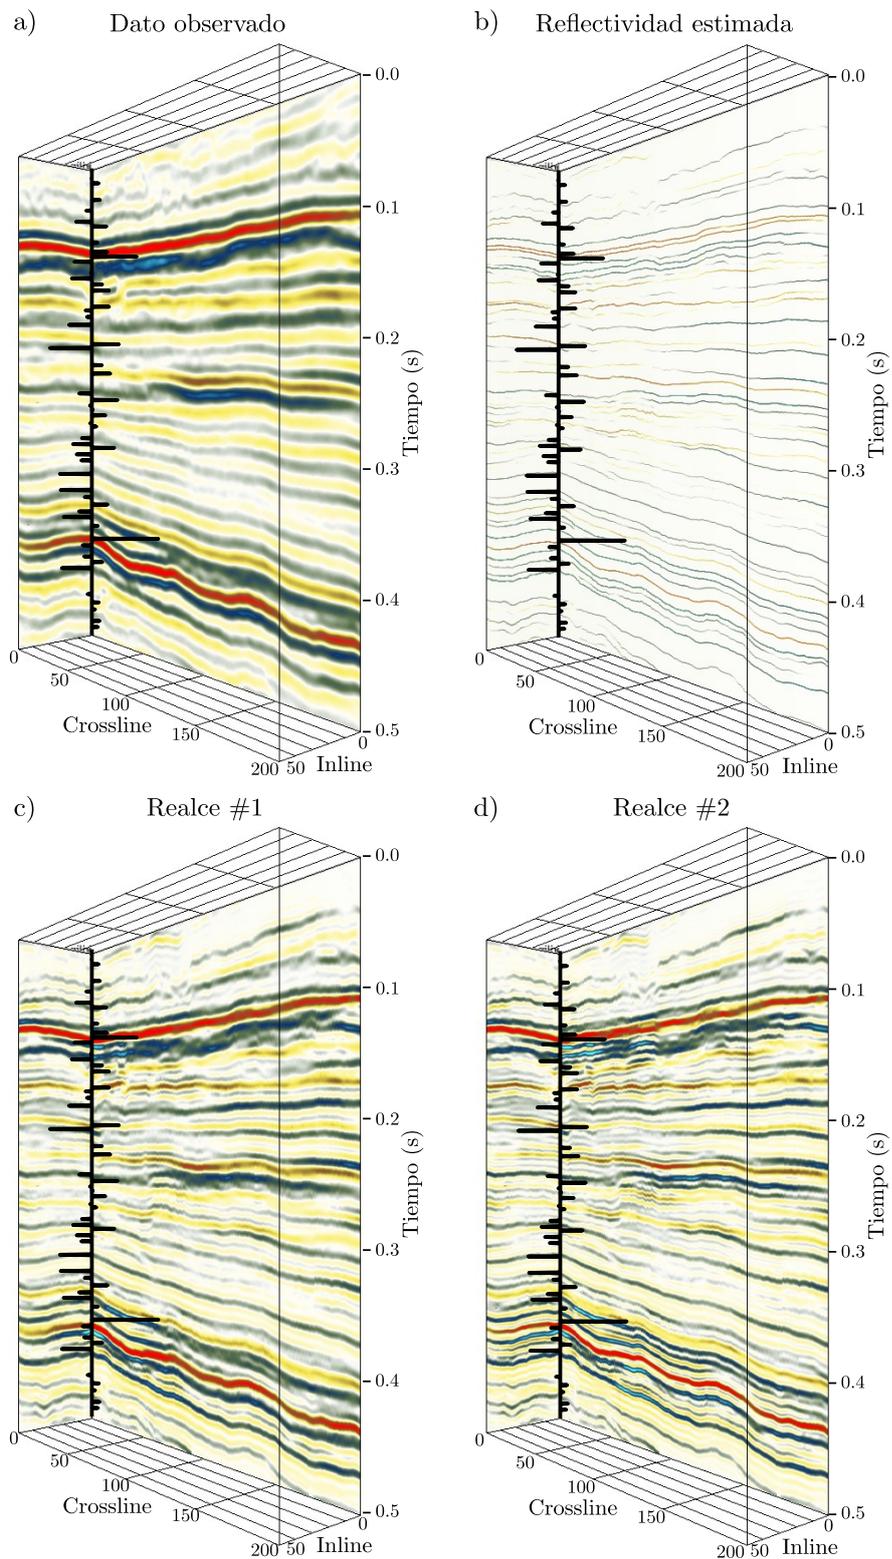
En la Figura 6.12 se compara la reflectividad resultante con la obtenida utilizando FISTA (Pérez et al., 2013). Aunque FISTA proporciona una solución de alta resolución aceptable, falla en recuperar apropiadamente algunos horizontes que se correlacionan con la información proporcionada por el pozo. Con la estrategia propuesta, todos los *spikes* presentes en el pozo se preservan a lo largo de la imagen.

Por completitud, la Figura 6.13 muestra los espectros de amplitud para las ondículas, junto con el dato observado y las secciones con realce. Como se puede ver, el contenido original en frecuencias se preserva bien con un incremento del ancho de banda. El ancho de banda resultante puede modificarse fácilmente según las necesidades del intérprete, utilizando otras ondículas que considere convenientes.

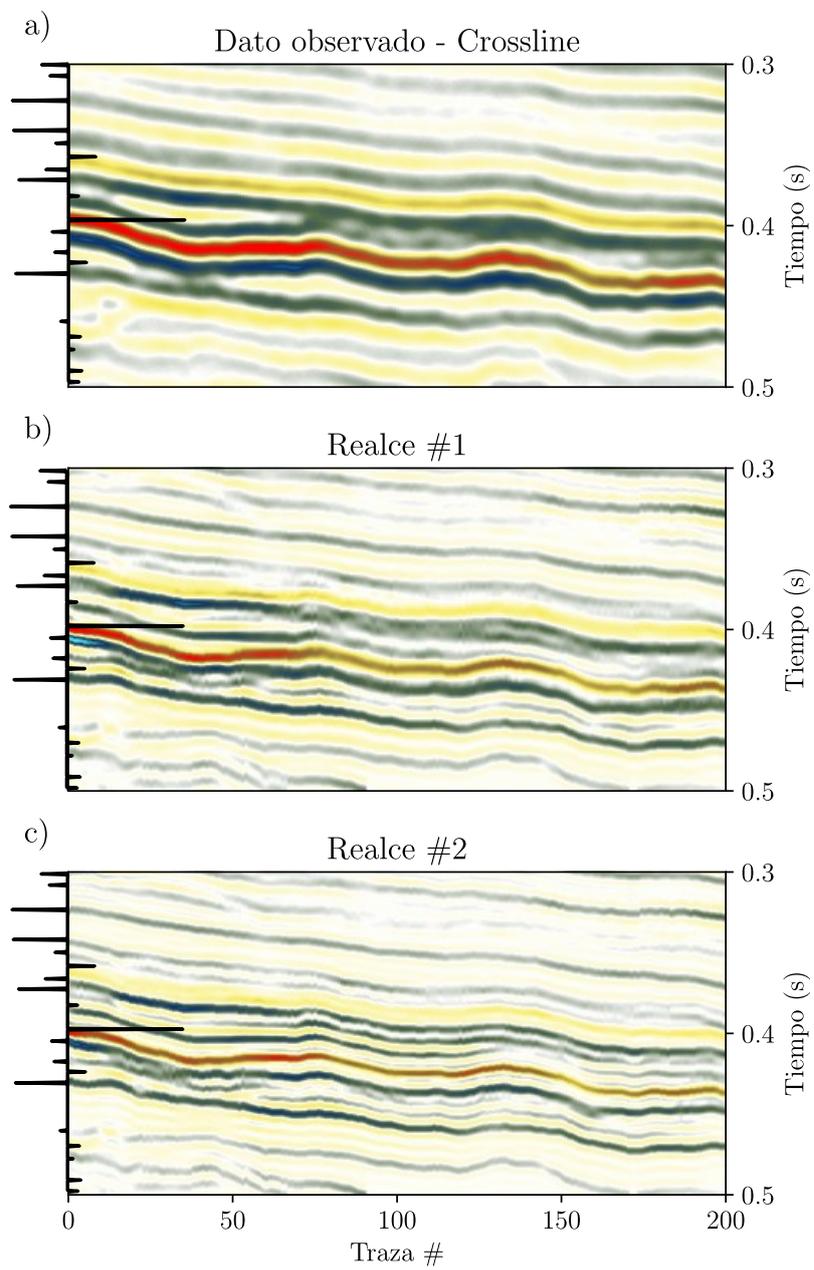
## 6.5. Discusión y consideraciones

Por simplicidad, el método propuesto asume que la ondícula es conocida, y el ejemplo sintético 2D muestra cómo la ondícula puede afectar al resultado final. Como se vio en los Capítulos 4 y 5, una forma típica de obtener una estimación de la ondícula es a través de su espectro, ya sea estadísticamente a partir de las trazas sísmicas o determinísticamente usando información de pozos. En cuanto a la fase, una técnica común es asumir que es constante, lo que permite incluirla como una variable más dentro del proceso iterativo del VFSA. Además, dado que una rotación de fase de aproximadamente  $30^\circ$  no afecta significativamente la forma de la ondícula, una estimación preliminar de la misma es aceptable. Se asume también que la ondícula es estacionaria; sin embargo, dado que puede variar tanto en el tiempo como en el *offset*, se podría trabajar por ventanas, estimando una ondícula para cada una de ellas, como se hizo en el Capítulo 4.

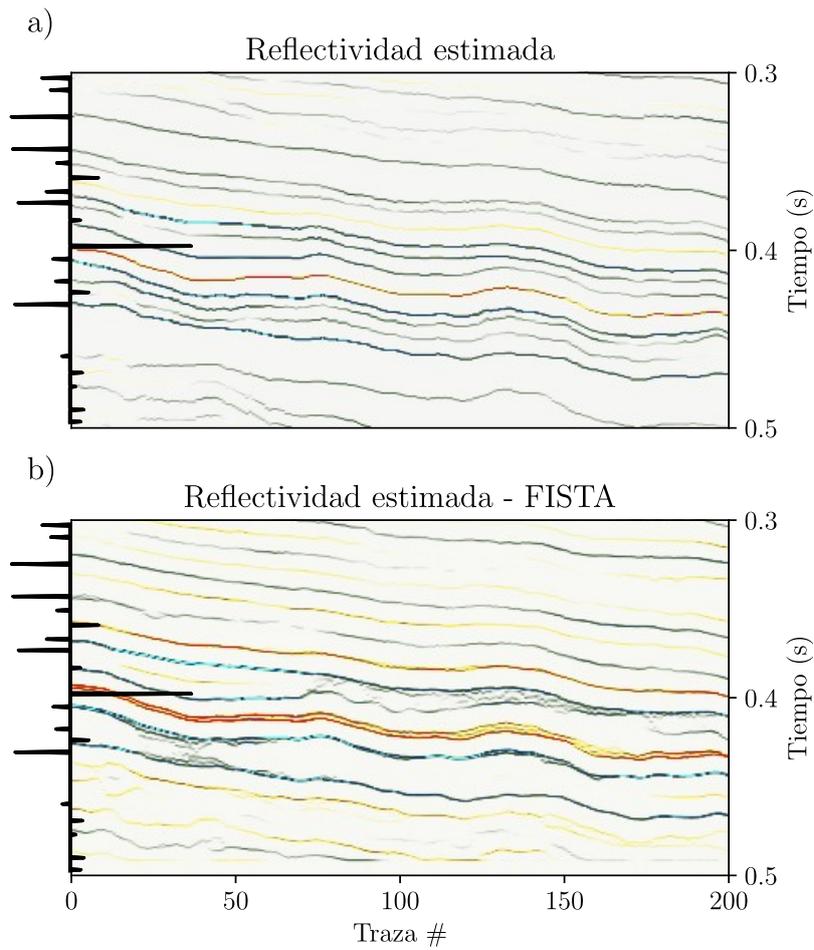
Para estimar la reflectividad de tipo *sparse-spike* inicial, se utilizan dos técnicas: un algoritmo de zonificación propuesto por (Velis, 2007), que segmenta los datos de pozo en un número predeterminado de intervalos, y la técnica de atado automático de pozos, que ajusta las reflectividades resultantes a las trazas cercanas al pozo. Ambas técnicas fueron presentadas en el Capítulo 5. Es importante destacar que no es estrictamente necesario que un usuario utilice estas mismas estrategias para que la deconvolución propuesta funcione adecuadamente. La construcción de un buen modelo inicial dependerá de las



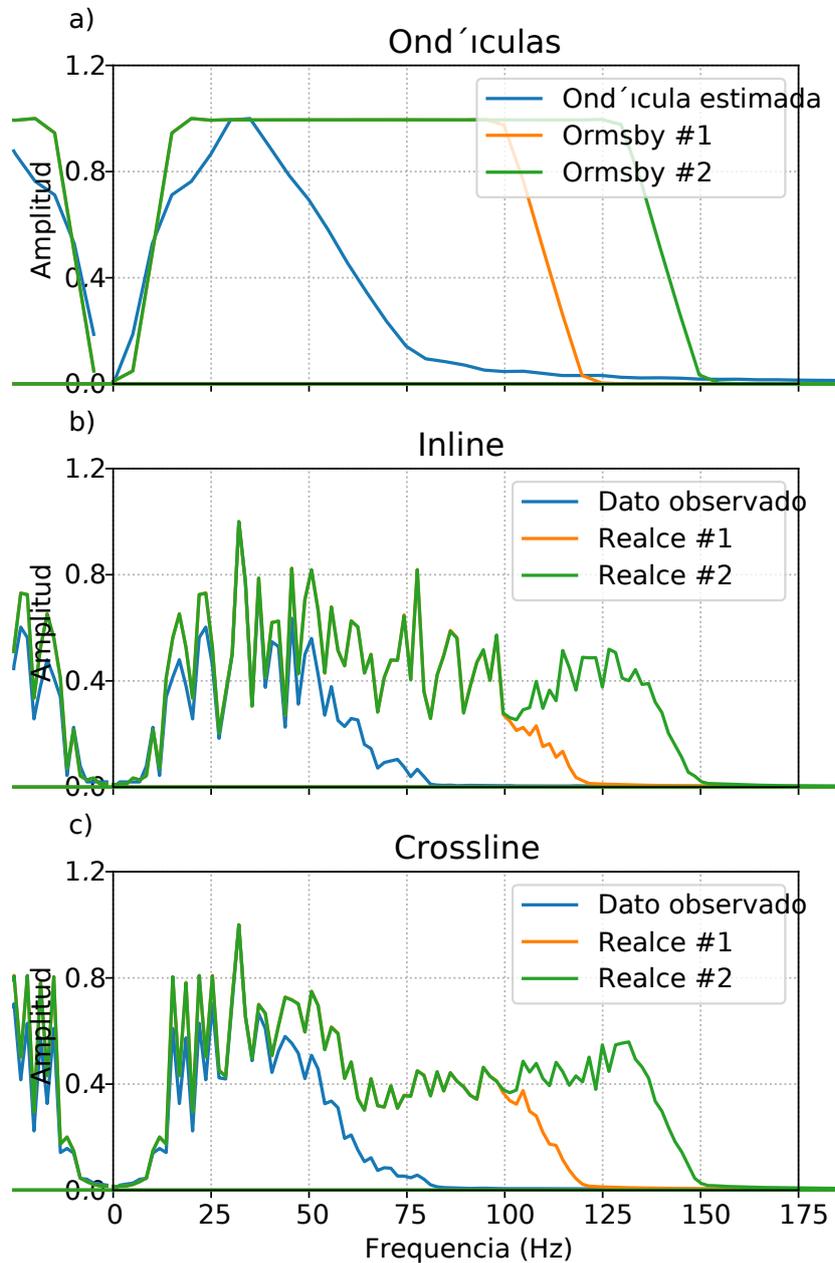
**Figura 6.10.** Ejemplo de dato de campo. a) Dato observado. b) Reflectividad estimada. c) y d) Datos con realce en frecuencia utilizando las dos ondículas de Ormsby consideradas.



**Figura 6.11.** Ejemplo de dato de campo. Ventana ampliada de la *crossline*. a) Dato observado, b) y c) Datos con realce en frecuencias usando las ondículas de Ormsby consideradas.



**Figura 6.12.** Ejemplo de dato de campo. Ventana ampliada de la *crossline*. Imagen de la reflectividad obtenida usando a) método propuesto y b) el método propuesto por Pérez et al. (2013).



**Figura 6.13.** Ejemplo de dato de campo. a) Ondículas estimadas y de Ormsby utilizadas para los reales en frecuencia. b) y c) Espectro de amplitud promedio correspondiente al dato observado y los reales en frecuencia de las *inline* y *crossline*.

preferencias del usuario, la disponibilidad de software y las características de los datos de pozos.

Al igual que la mayoría de las técnicas de optimización global el VFSA puede volverse lento al estimar muchos parámetros o si la función de costo no es sensible a ellos. A pesar de esto, para el tamaño de los datos utilizados en los distintos ejemplos de este capítulo, incluidos los ejemplos con datos de campo, los tiempos de cálculo no fueron un problema. Las limitaciones e hipótesis de que la reflectividad varía suavemente entre traza y traza permiten optimizar la función de costo de manera computacionalmente eficiente. Por lo tanto, la convergencia ocurre de forma rápida, ya que se asume que las posiciones de los *spikes* son consistentes a través de las trazas. El otro cálculo requerido es la estimación de las amplitudes óptimas, lo que requiere relativamente poco tiempo porque el número de reflectividades no nulas es pequeño. Como resultado, el método puede encontrar soluciones aceptables en unas pocas miles de iteraciones por traza, lo que se traduce en pocos segundos en una PC estándar con el código en Python. Se debe tener en cuenta que las técnicas de computación de alto rendimiento, no consideradas aquí, podrían mejorar el desempeño del algoritmo.

La reflectividad *sparse-spike* resultante puede ser considerada como un producto final en sí misma. Sin embargo, los intérpretes pueden preferir simplemente extender el ancho de banda del dato convolucionando este resultado con una ondícula de ancho de banda determinado, que generalmente será igual o mayor al del dato original. El método se adapta mejor a datos con una complejidad estructural baja o moderada, o a regiones cercanas a zonas donde se dispone de información de pozos. La técnica propuesta probablemente no funcione de manera eficiente si los datos de pozo son escasos o si hay cambios laterales significativos en los horizontes, como fallas o otras discontinuidades geológicas.

## 6.6. Conclusiones

Dado que los datos sísmicos son de banda limitada, los detalles y rasgos pequeños en la sísmica no suelen ser resueltos con precisión. Por otro lado, la alta resolución de los datos de pozo permite identificar reflectores de manera adecuada y precisa. En el método propuesto, se utiliza la información provista por los perfiles de pozo para generar imágenes sísmicas de alta resolución que sean consistentes con dicha información.

Para lograr esto, primero se obtiene una reflectividad a partir de un perfil de pozo y, de manera progresiva, se modifica traza a traza mediante una función de deformación. Luego, al convolucionar esta reflectividad modificada con una ondícula adecuada, se busca ajustar el resultado al dato observado en cada etapa del proceso. Además, al imponer restricciones sobre los movimientos permitidos, se garantiza la continuidad lateral de los eventos.

Las pruebas realizadas en datos sintéticos y de campo muestran que el método tiene un alto grado de éxito al construir reflectividades de tipo *sparse-spike* que honran el dato observado y son consistentes con la información del pozo, incluso en presencia

de altos niveles de ruido o con ondículas mal estimadas. Dado que se espera que la reflectividad no cambie mucho de traza a traza, el método es ideal para procesar datos de baja a moderada complejidad estructural.

La salida final de tipo *sparse-spike*, al ser convolucionada con ondículas de mayor ancho de banda, genera imágenes de alta resolución que permiten analizar rasgos que no estaban presentes en los datos originalmente observados.

# Capítulo 7

## Conclusiones

El objetivo principal de esta tesis fue el desarrollo de herramientas computacionales para el realce en frecuencia de las señales sísmicas con el fin de incrementar su resolución y mejorar la interpretación del dato sísmico con fines exploratorios. A partir de los resultados obtenidos mediante las herramientas y estrategias presentadas en los capítulos previos, tanto en datos sintéticos como en datos de campo, se puede considerar que dichos objetivos fueron alcanzados satisfactoriamente. Estas herramientas permitieron incrementar la resolución de los datos en los cuales fueron aplicadas, mejorando su contenido en frecuencia y obteniendo mejores estimaciones de la ondícula, un elemento fundamental en la sísmica de exploración. Las estrategias propuestas y desarrolladas se aplicaron en datos sísmicos post-stack, asumiendo la disponibilidad de información confiable y de calidad proveniente de pozos (ej., perfiles sónicos, densidad, *caliper*, etc.).

Las diversas pruebas numéricas se llevaron a cabo aplicando algoritmos programados en lenguaje Python, tanto en datos sintéticos y pseudo-sintéticos, como en datos de campo proporcionados por YPF S.A. y Pluspetrol S.A. Los resultados fueron presentados en congresos y publicados en revistas con referato, tanto nacionales como internacionales. A diferencia de las herramientas provistas por *software* comerciales, que son costosas y de código cerrado, las desarrolladas en esta tesis son accesibles y están disponibles para quien las solicite como una alternativa para el procesamiento de datos sísmicos.

A continuación, se resumen las conclusiones más importantes obtenidas luego de aplicar cada una de las estrategias propuestas en datos sintéticos y de campo que constituyen el principal aporte de esta tesis.

### Capítulo 4: Estimación de la ondícula sísmica

En este capítulo se presentó una estrategia para estimar la ondícula sísmica a partir de datos sísmicos sin necesidad de contar con información *a priori*, como podrían ser los datos de pozos exploratorios. La estrategia se basa en dos hipótesis: 1) la fase de la ondícula puede ser considerada constante, y 2) el subsuelo puede ser representado por una serie de coeficientes de reflexión que sigue un modelo no-gaussiano y/o tipo *sparse-spike*. La fase óptima de la ondícula se obtiene buscando la traza deconvolucionada

que presente el menor valor de la norma  $l_1$ . A partir de la segunda hipótesis, el proceso de deconvolución utilizado fue de tipo *sparse-spike*.

La nueva estrategia se puso a prueba en datos sintéticos y de campo. En el caso de los sintéticos, se utilizaron modelos 1D y 2D con diferentes niveles de ruido, diferentes anchos de banda de la ondícula sísmica y diferentes porcentajes de *spikes* en las reflectividades asociadas. Se demostró que la estimación de la fase no es del todo exacta cuando no se cumple satisfactoriamente la hipótesis de no-gaussianidad. Sin embargo, el método propuesto permitió obtener buenas estimaciones incluso para reflectividades poco *sparse*. En todos los casos, la estrategia basada en la norma  $l_1$  mostró una mayor consistencia y mejor desempeño en la estimación de la fase en comparación con el clásico método de maximización de la curtosis. Si bien este último fue más robusto ante la presencia de ruido, su desempeño empeoró al disminuir tanto el ancho de banda como el grado de *sparsity* de la reflectividad. Por último, se presentó un ejemplo de campo donde se utilizó una estrategia de ventanas temporales solapadas para disminuir el efecto de la no-estacionaridad de la ondícula en los resultados. Se observó que las ondículas estimadas mediante la estrategia de la norma  $l_1$  condujeron, tras la deconvolución, a una reflectividad más *sparse* y con reflectores mejor definidos que los obtenidos al utilizar ondículas obtenidas con métodos basados en la curtosis.

## Capítulo 5: Amarre de pozos y estimación de la fase de la ondícula sísmica

En este capítulo se presentó una estrategia para el amarre de pozos y la estimación de la ondícula sísmica de manera automática. El método propuesto permite llevar a cabo el proceso de amarre entre la información de pozos y la sísmica y, simultáneamente, estimar la fase de la ondícula cuando no se tiene información de ésta. La estrategia propuesta es iterativa, perturbando el perfil de velocidades del pozo y la fase de la ondícula sísmica de manera tal que se incremente el coeficiente de correlación entre las trazas sintéticas y las observadas. Para perturbar la velocidad observada, se utiliza una función de deformación construida a partir de un número fijo de nodos. En particular, el uso de *splines* cúbicos monotónicos para crear dicha función permite aplicar perturbaciones suaves y controladas de los valores de velocidad observados, lo que respeta las mediciones dentro de una tolerancia razonable. Por su parte, la fase de la ondícula se perturba mediante la transformada de Hilbert generalizada.

A través de ejemplos se mostró que el método es estable y brinda resultados confiables, especialmente cuando la selección de los parámetros del algoritmo, como el número de nodos y el porcentaje del cambio en la velocidad permitido, es conservadora. Los resultados en datos pseudo-sintéticos y de campo demostraron que es posible obtener valores altos de correlación entre las trazas sintéticas y las observadas, así como estimaciones aceptables de la fase de la ondícula simultáneamente. Además, dado que el algoritmo propuesto no modifica la traza sintética final en términos de estiramiento o compresión, como sucede durante el amarre manual con el algoritmo DTW, la traza sintética final preserva la forma de la ondícula, una característica deseada para el análisis e interpretación del dato sísmico.

También se presentó una estrategia simple para adaptar el método propuesto para el amarre de pozos cuando los perfiles son de tipo *blocky*. Mediante un ejemplo de campo con un perfil sísmico *blocky*, se demostró su buen desempeño tanto para el amarre como para la estimación de la ondícula, mostrando la versatilidad de esta estrategia.

## Capítulo 6: Deconvolución *sparse-spike* basada en información de pozos y realce en frecuencias

En este capítulo se presentó un nuevo método para realizar la deconvolución *sparse-spike* de datos sísmicos de manera consistente con información *a priori* proveniente de perfiles de pozos, y extender el ancho de banda de la señal para mejorar la resolución. El algoritmo parte de la deconvolución de un modelo inicial de la reflectividad, obtenido a partir de perfiles de pozo disponibles y realizando el amarre con la estrategia presentada en el Capítulo 5. Luego, de manera iterativa, se perturba esta reflectividad, la cual se convoluciona con una ondícula apropiada y se compara con la traza a deconvolucionar. La perturbación de la reflectividad se realiza mediante una función de deformación construida a partir de un número de nodos y una interpolación lineal entre ellos. En este paso se busca la nueva posición de los *spikes* y se realiza un ajuste de amplitudes mediante mínimos cuadrados regularizados. El proceso iterativo concluye cuando se minimiza el error entre la traza calculada y la observada. Como resultado de este proceso iterativo se obtiene una reflectividad asociada a la traza observada, que será utilizada como modelo inicial para deconvolucionar la siguiente traza. Finalmente, la reflectividad final se convoluciona con una ondícula de mayor ancho de banda que el del dato observado.

A partir de ejemplos sintéticos 1D y 2D, así como de datos de campo, se corroboró el correcto desempeño del algoritmo propuesto. Este es capaz de brindar imágenes de alta resolución consistentes con la información de pozo. Además, al poder restringir adecuadamente las perturbaciones a aplicar, se puede obtener una solución con buena continuidad lateral en toda la sección sísmica. Estos resultados, como se mostró en los ejemplos sintéticos, se mantienen incluso en presencia de datos con altos niveles de ruido y errores en la estimación de la fase de la ondícula. Dado que se espera que entre traza y traza no haya grandes variaciones en las reflectividades, la estrategia propuesta es ideal para escenarios de baja a mediana complejidad geológica. La reflectividad final obtenida tras este proceso puede ser convolucionada con una ondícula de mayor ancho de banda que la señal original, lo que permite observar características en el dato que no eran visibles originalmente, mejorando el análisis e interpretación.

## 7.1. Contribuciones

Durante el desarrollo del plan de tesis se escribieron 3 artículos en revistas de circulación internacional con referato (en 2 de ellos como primer autor) y se presentaron 4 trabajos en congresos científicos (2 trabajos completos y 2 resúmenes). Además, se presentaron resultados parciales en 2 jornadas abiertas en universidades nacionales y

en 5 jornadas internas de la Facultad de Ciencias Astronómicas y Geofísicas (UNLP). En todos los congresos y jornadas, el autor de esta tesis fue el primer autor de los trabajos presentados, además de expositor.

La estrategia de estimación de la ondícula sísmica a partir de datos sísmicos sin información de pozos fue presentada de manera parcial en la *XXVII Reunión Científica de la Asociación Argentina de Geofísicos y Geodestas* (Gelpi y Velis, 2017) y de manera completa en la *XVII Reunión de Trabajo en Procesamiento de la Información y Control* (Gelpi et al., 2017). Luego, los resultados fueron publicados en la revista internacional *Journal of Seismic Exploration* (Gelpi et al., 2019b).

El proceso de automatización para el amarre de pozos se presentó en las *Terceras Jornadas de Geociencias para la Ingeniería* (Gelpi et al., 2018) y en la *AAPG 2019 International Conference and Exhibition* (Gelpi et al., 2019a). El método automático completo, con la estimación simultánea de la ondícula y el amarre de pozo, se presentó en la *89th Society of Exploration Geophysicists International Exhibition and Annual Meeting* (Gelpi et al., 2019c), antes de ser publicado en la revista internacional *Geophysics* (Gelpi et al., 2020a).

Finalmente, los resultados preliminares del método presentado en el Capítulo 6 fueron presentados en las jornadas abiertas de la UNLP (Gelpi et al., 2020b) y en la primera conferencia virtual para estudiantes de la SEG en Latinoamérica (Gelpi et al., 2021b). El desarrollo final se presentó en la *First International Meeting for Applied Geoscience & Energy* (Gelpi et al., 2021a), y finalmente fue publicado en la revista *Geophysics* (Pérez et al., 2024).

# Apéndice A

## Algoritmos de optimización

### A.1. Introducción

Los diferentes fenómenos físicos que tienen lugar en el subsuelo dan lugar a señales que puede ser observadas en la superficie mediante distintas técnicas e instrumentos. Dichos fenómenos físicos pueden ser representados, con mayor o menor complejidad, mediante un conjunto de parámetros que definen un modelo del mismo. Encontrar las relaciones físico-matemáticas que permitan predecir observaciones a partir del modelo constituye lo que se denomina problema directo (Sen y Stoffa, 2013; Tarantola, 2005). Luego, resolver el problema inverso consiste en estimar parámetros de un modelo a partir de un conjunto de observaciones, tal que las predicciones hechas con dicho modelo honren a las observaciones con cierta tolerancia. Sin embargo, al resolver el problema inverso se tiene que tener especial consideración en la existencia, unicidad y estabilidad de las soluciones estimadas (Aster et al., 2013). Al resolver un problema inverso, la existencia de la solución no está garantizada, y en caso de existir, ésta podría no ser única. Además, los problemas de inversión están en general mal condicionados; es decir, existen muchas soluciones que honran al dato con igual precisión, pero algunas de éstas pueden ser inestables y carecer de significado físico.

Desde el punto de vista matemático, la resolución del problema inverso se plantea como un problema de optimización, tanto de minimización como de maximización. La función a ser optimizada es llamada función objetivo o función de costo, y permite evaluar el modelo a través de alguna medida de distancia en el espacio de los datos observados. Esta función puede ser de gran complejidad, presentando múltiples mínimos y/o máximos locales, ser discontinua, no diferenciable e incluso no lineal respecto a los parámetros que la definen. Debido a esto, al momento de resolver el problema inverso es fundamental elegir correctamente el algoritmo de optimización para obtener resultados satisfactorios. Además, debido a los costos computacionales asociados al resolver numéricamente el problema, se debe contemplar la cantidad de parámetros, complejidad del modelo directo y dimensiones del espacio de búsqueda.

A continuación se presentan los tres algoritmos de optimización utilizados en esta tesis: *very fast simulated annealing* (VFSA), *fast iterative shrinkage-thresholding*

*algorithm* (FISTA) y *differential evolution* (DE). Estos algoritmos fueron desarrollados originalmente con objetivos diferentes a los tratados en esta tesis. Sin embargo, todos ellos ya han sido utilizados satisfactoriamente en problemas de inversión en geofísica (Velis, 2008; Wang y Gao, 2010; Pérez et al., 2013; Brunini et al., 2017; Gelpi et al., 2020a; Ekinici et al., 2023).

## A.2. *Differential evolution*

DE es un algoritmo de optimización inspirado en los procesos evolutivos de la naturaleza. Pertenece a la familia de algoritmos evolutivos metaheurísticos basados en poblaciones y permite trabajar con funciones objetivo no diferenciables, no lineales y multimodales. Es un método de optimización estocástico que necesita de pocos hiperparámetros para llevar a cabo la minimización de una función objetivo y logra converger hacia su mínimo global de manera eficiente y precisa (Storn y Price, 1997). DE fue propuesto inicialmente para resolver problemas como la optimización de coeficientes de filtros digitales (Storn, 1996). Su diseño permite optimizar funciones en un dominio continuo  $n$ -dimensional y dada su capacidad de explorar el espacio de búsqueda evita quedar atrapado en mínimos locales.

El algoritmo inicia la búsqueda del mínimo global con una población inicial de posibles soluciones que irá evolucionando iterativamente. En cada iteración la nueva población se integrará con la actual, en forma parcial o total, utilizando algún mecanismo de selección y dependiendo de los valores al evaluar la función objetivo. Esto se repite hasta que se satisfaga algún criterio de corte establecido. De manera similar a los algoritmos genéticos (GA), DE utiliza operadores de mutación, *crossover* y selección para hacer evolucionar las soluciones. Sin embargo, la principal diferencia entre GA y DE se encuentra en los procesos de selección y el esquema de mutación (Abou El Ela et al., 2010).

El algoritmo involucra una población inicial de soluciones candidatas generada aleatoriamente dentro de ciertos límites definidos por el usuario. De esta forma, si la función a minimizar depende de  $K$  variables, los  $n$  miembros de la generación  $g$  de dichas variables pueden ser expresados como

$$\mathbf{x}_{n,g} = (x_{n,g}^1, x_{n,g}^2, \dots, x_{n,g}^K), \quad (\text{A.1})$$

con  $n = 1, \dots, N$  y  $g = 1, \dots, G$  donde  $N$  es el tamaño de la población para una dada generación  $g$ . En cada nueva generación los vectores de dimensión  $K$  son una combinación lineal de vectores de la generación anterior creados por medio de tres procesos llamados mutación, *crossover* y selección que detallamos a continuación.

### Mutación

En esta etapa se genera un vector mutante de soluciones a partir de los elementos de la población de una cierta generación. Dado un vector  $\mathbf{x}_{n,g}$  de dicha generación

se seleccionan aleatoriamente otros tres vectores,  $\mathbf{x}_{j,g}$  y  $\mathbf{x}_{k,g}$ , tales que  $i, j, k \leq n$ . Luego el vector mutado  $\mathbf{y}_{j,g}$  es

$$\mathbf{y}_{j,g} = \mathbf{x}_{i,g} + F(\mathbf{x}_{j,g} - \mathbf{x}_{k,g}), \quad (\text{A.2})$$

donde  $F$  es un número positivo seleccionado *a priori* que controla la velocidad de evolución de la población. Este procedimiento se realiza para  $M$  vectores de la generación.

### Crossover

Luego de la fase de mutación se aplica el operador de *crossover* que produce un intercambio entre los elementos de los vectores  $\mathbf{y}_{j,g}$  y sus correspondientes vectores mutados  $\mathbf{y}_{n,g}$ . El operador de *crossover* da como resultado un nuevo vector  $\mathbf{z}_{n,g}$  cuyos elemento  $k$ -ésimo, con  $k = 1, \dots, K$  está dado por

$$z_{n,g}^k = \begin{cases} y_{n,g}^k & \text{si } c \leq C_r \text{ o } k = \hat{k}, \\ x_{n,g}^k & \text{caso contrario} \end{cases} \quad (\text{A.3})$$

donde  $C_r$  es el parámetro de *crossover* que indica la probabilidad de que haya recombinación y debe de ser elegido *a priori* es un número entero seleccionado aleatoriamente en el rango  $[1, K]$  y  $c$  es un número seleccionado aleatoriamente de una distribución uniforme en el rango  $[0,1]$ .

### Selección

En esta instancia se selecciona qué miembros pasarán a la próxima generación. Para esto se comparan los valores de evaluar la función objetivo  $J(\mathbf{v})$  en  $\mathbf{x}_{n,g}$  y  $\mathbf{z}_{n,g}$ . El vector que minimice la función de costo pasará a la próxima generación, es decir

$$\mathbf{x}_{n,g+1} = \begin{cases} \mathbf{z}_{n,g} & \text{si } J(\mathbf{z}_{n,g}) \leq J(\mathbf{x}_{n,g}), \\ \mathbf{x}_{n,g} & \text{caso contrario} \end{cases} \quad (\text{A.4})$$

Esto es considerado una elección de reemplazo elitista (Talbi, 2009). El algoritmo se detiene cuando se alcanza el número máximo de generaciones o la tasa de convergencia es menor a un límite preestablecido.

Para más detalles y variaciones de este algoritmo el lector puede referirse a Brunini Garcia (2023) y las referencias de este apéndice.

## A.3. Very fast simulated annealing

VFSA es un algoritmo iterativo estocástico para estimar soluciones casi-óptimas de problemas de optimización complejos, siendo capaz de estimar mínimos globales de funciones multimodales y/o discontinuas. El mecanismo que usa VFSA para estimar

el mínimo global de una función está inspirado en el proceso de recocido de metales, una técnica metalúrgica que consiste en calentar y luego enfriar el metal de manera controlada con el objetivo de variar sus propiedades físicas y conseguir una estructura cristalina más fuerte. La dureza de la estructura está relacionada con la tasa de enfriamiento que se utilice. En la analogía que se hace entre el proceso metalúrgico y el problema de optimización, las partículas del metal sometido al recocido equivalen a los parámetros del modelo matemático y el estado de energía del sistema representa la función de costo a minimizar. Un recocido óptimo es aquel en el cual se enfría el metal de tal manera que sus partículas alcancen un mínimo estado de energía y por lo tanto máxima dureza, lo que equivaldría a haber encontrado el mínimo absoluto de la función de costo. Sin embargo, si el sistema se enfría muy rápidamente las partículas del material no alcanzarán la configuración de mínima energía, lo que equivaldría a no converger al mínimo global de la función de costo.

VFSA es un proceso iterativo y en cada paso la configuración del modelo, que equivale al estado de energía de las partículas del metal, se selecciona a través de una distribución de probabilidad que depende de un parámetro de control llamado temperatura. Esta temperatura decrece gradualmente durante el proceso de optimización siguiendo un esquema de enfriamiento predefinido. Cuando la temperatura es alta, el espacio de donde se escogen los parámetros del modelo es explorado de forma aproximadamente uniforme y casi todas las configuraciones son aceptadas. Por el contrario, a bajas temperaturas se escoge preferentemente un modelo cuyo valor de energía es más bajo. El esquema de enfriamiento es clave para una correcta optimización. El proceso concluye cuando se satisface algún criterio de corte preestablecido, como puede ser haber alcanzado un número máximo de iteraciones o cuando ya no se observan cambios importantes en la función de costo.

La Figura A.1 muestra el diagrama de flujo del algoritmo VFSA. Suponiendo que se busca el mínimo global de una función de costo  $\Phi$  que depende de  $M$  parámetros el algoritmo comienza el proceso iterativo, con número de iteración  $k=1$ , a partir de una solución inicial  $\mathbf{x}$  y temperatura inicial  $T_0$ . Una nueva configuración  $\mathbf{x}$  de los  $M$  parámetros del modelo se obtiene perturbando la configuración de la actual iteración en una cantidad  $\Delta\mathbf{x}$  que se calcula mediante

$$\Delta\mathbf{x} = \mathbf{y}(\mathbf{B} - \mathbf{A}), \quad (\text{A.5})$$

donde  $\mathbf{A}$  y  $\mathbf{B}$  son constantes a definir que restringen el espacio de perturbación y donde los valores de  $\mathbf{y}$  son

$$y_i = \text{sign} \left( u_i - \frac{1}{2} \right) \frac{T_i}{1 + \frac{1}{T_i}^{(2u_i-1)}} \quad , \quad i = 1, \dots, M \quad (\text{A.6})$$

siendo  $u_i \in [0, 1]$  valores aleatorios que se obtienen de una distribución uniforme y

$$T_i = T_0 \exp \left( -\alpha k^{(1/M)} \right) \quad , \quad (\text{A.7})$$

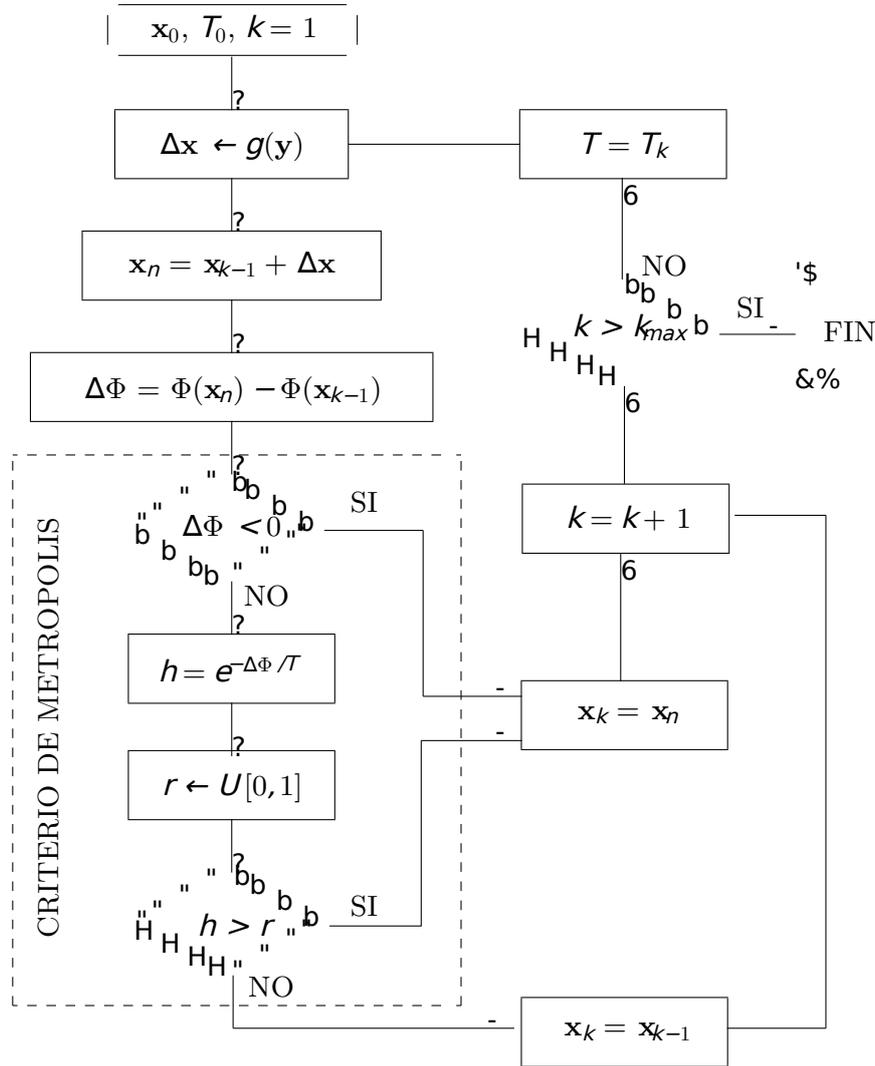


Figura A.1. Diagrama de flujo del algoritmo VFSA (Velis, 1998).

es el esquema de enfriado que garantiza estadísticamente la convergencia al mínimo global. Las constantes  $\alpha_i$  no afectan la convergencia del algoritmo y su finalidad depende de cada aplicación en particular. Luego de perturbar los parámetros del modelo se calcula la variación  $\Delta\Phi$  de la función de costo. La nueva configuración de los parámetros  $\mathbf{x}_n$  será aceptada o rechazada dependiendo del valor de  $\Delta\Phi$ , por medio del *Criterio de Metropolis* (Metropolis et al., 1953). Este criterio rechaza o acepta la solución dependiendo de una función de aceptación  $h$  definida como

$$h(\Delta\Phi) = \frac{1}{1 + \exp \frac{\Delta\Phi}{T}} \approx \exp \frac{-\Delta\Phi}{T} \quad (A.8)$$

Esta expresión se basa en el cambio de la función de costo  $\Phi$  respecto de los parámetros del modelo, es decir  $\Delta\Phi = \Phi(\mathbf{x}_n) - \Phi(\mathbf{x}_{k-1})$ . Siguiendo a Metropolis, una nueva configuración es aceptada sin condición si  $\Delta\Phi \leq 0$ , y aceptada con probabilidad  $\exp(-\Delta\Phi)$  en caso contrario. Si la temperatura se acerca a cero la probabilidad de aceptación decrece exponencialmente y sólo los estados más bajos de energía son aceptados. Esto es fundamental en el funcionamiento de VFSA, ya que mientras otros algoritmos de optimización sólo buscan modelos que hacen disminuir la función de costo VFSA permite explorar modelos que incrementan el valor de la misma. Este comportamiento permite explorar de manera más amplia el espacio del modelo, evitando quedar atrapado en mínimos locales.

Si la nueva configuración de los parámetros es aceptada, esta pasa a ser el punto de partida de la siguiente iteración, en caso contrario se mantiene la configuración de la actual iteración para ser perturbada y evaluada nuevamente. El proceso iterativo termina cuando se alcanza algún criterio de corte preestablecido, como por ejemplo al alcanzar un número máximo de iteraciones  $k_{max}$  o un valor determinado de  $\Phi$ .

#### A.4. Fast iterative shrinkage-thresholding algorithm

FISTA es un poderoso algoritmo iterativo que permite minimizar funciones objetivo de la forma

$$J(\mathbf{x}) = \|\mathbf{Ax} - \mathbf{d}\|_2^2 + \mu\|\mathbf{x}\|_1, \quad (\text{A.9})$$

donde  $\mathbf{d}$  es un vector de dimensión  $n$  representando al dato observado  $\mathbf{x}$  un vector de dimensión  $m$  representando los parámetros del modelo  $\mathbf{A}$  es una matriz de dimensión  $n \times m$  que relaciona  $\mathbf{x}$  y  $\mathbf{d}$ . Este algoritmo está basado en el algoritmo *iterative shrinkage-thresholding algorithm* (ISTA) de Daubechies et al. (2004), el cual a su vez es una extensión del algoritmo del gradiente clásico utilizado para resolver problemas de inversión lineales de gran escala (Beck y Teboulle, 2009). FISTA es un algoritmo que permite abordar problemas de optimización convexos no diferenciables (Bauschke et al., 2011). En cuanto a las soluciones brindadas por este algoritmo, se observa que por el tipo de regularización utilizado, van a ser de tipo *sparse-spike*.

El paso a paso del algoritmo puede resumirse de la siguiente manera:

1. Establecer  $\eta \geq \kappa_{max}$ , donde  $\kappa_{max}$  es el máximo autovalor de la matriz  $\mathbf{A}^T\mathbf{A}$ .
2. Establecer una solución inicial  $\mathbf{z} = \mathbf{x}_0$  y  $t_0 = 1$ .
3. Para cada iteración  $k = 0, 1, 2, \dots$

$$a) \quad \mathbf{x}_{k+1} = T_{\mu/2\eta} \left( \mathbf{x}_k + \frac{1}{\eta} \mathbf{A}^T (\mathbf{d} - \mathbf{Ax}_k) \right), \quad (\text{A.10})$$

donde  $T_v\{\cdot\}$  es una función suave que actúa como umbral (*soft-thresholding function*). Esta función se aplica a cada elemento de su argumento vectorial y está definida como:

$$T_v(g) = \begin{cases} g(1 - v/|g|), & |g| \geq v \\ 0, & |g| < v \end{cases} \quad (\text{A.11})$$

donde  $g$  es una variable genérica y  $v$  es el valor umbral.

b)

$$t_{k+1} = \frac{1 + \frac{1}{1 + t_k^2}}{2}, \quad (\text{A.12})$$

c)

$$\mathbf{z}_{k+1} = \mathbf{x}_{k+1} + \frac{t_k - 1}{t_{k+1}}(\mathbf{x}_{k+1} - \mathbf{x}_k). \quad (\text{A.13})$$

d)

$$k = k + 1, \quad (\text{A.14})$$

e) Verificar convergencia o criterio de corte.

Para determinar el  $K_{max}$  en el primer paso del algoritmo puede utilizarse algún método clásico como el de las potencias de Rayleigh (Larson y Edwards, 1999). Puede verse que en cada iteración de FISTA solamente se realizan multiplicaciones entre matrices y vectores, sin necesidad de invertir matrices. Debido a esto el algoritmo provee soluciones de tipo *sparse-spike* de una manera simple y efectiva, siendo económico desde el punto de vista computacional. En ese sentido, FISTA demostró ser varios órdenes de magnitud más veloz que otros algoritmos, como por ejemplo el ISTA (Bredies y Lorenz, 2008).

Para más detalles sobre FISTA y su implementación de código puede referirse a Pérez (2015) o las citas en este apéndice.

# Bibliografía

- Abou El Ela, A., M. Abido, y S. Spea, 2010, Optimal power flow using differential evolution algorithm: *Electric Power Systems Research*, **80**, 878–885.
- Aki, K., y P. G. Richards, 2002, *Quantitative seismology*: University Science Books.
- Anderson, K. R., y J. E. Gaby, 1983, Dynamic waveform matching: *Information Sciences*, **31**, 221–242.
- Anderson, P., y R. Newrick, 2008, Strange but true stories of synthetic seismograms: *CSEG Recorder*, **12**, 51–56.
- Arons, A. B., y D. R. Yennie, 1950, Phase distortion of acoustic pulses obliquely reflected from a medium of higher sound velocity: *Journal of the Acoustical Society of America*, **22**, 231–327.
- Ashburner, C. A., y I. C. White, 1885, The geology of natural gas: *Science*, **6**, 42–44.
- Aster, R., B. Borchers, y C. Thurber, 2013, *Parameter estimation and inverse problems*: Academic Press.
- Aster, R. C., B. Borchers, y C. H. Thurber, 2018, *Parameter estimation and inverse problems*: Elsevier.
- Babasafari, A. A., D. P. Ghosh, A. M. A. Salim, S. H. Kazemeini, y T. Ratnam, 2019, Blueing reflectivity integration (BRI) for seismic spectral enhancement and its application in seismic data interpretation: *Petroleum & Coal*, **61**, 1395–1402.
- Bauschke, H. H., R. S. Burachik, P. L. Combettes, V. Elser, D. R. Luke, y H. Wolkowicz, 2011, *Fixed-point algorithms for inverse problems in science and engineering*: Springer Science & Business Media.
- Beaton, A., y J. Turkey, 1974, The fitting of power series, meaning polynomials, illustrated on band-spectroscopic data: *Technometrics*, **16**, 147–185.
- Beck, A., y M. Teboulle, 2009, A fast iterative shrinkage-thresholding algorithm for linear inverse problems: *SIAM Journal of Imaging Sciences*, **2**, 183–202.
- Berndt, D., y J. Clifford, 1994, Using dynamic time warping to find patterns in time series: *Workshop on Knowledge Discovery in Databases*, Technical Report, AAAI, 359–370.
- Bianco, E., 2016, Tutorial: Wavelet estimation for well ties: *The Leading Edge*, **35**, 541–543.
- Bioucas-Dias, J. M., y M. A. T. Figueiredo, 2007, A new twist: Two-step iterative shrinkage/thresholding algorithms for image restoration *IEEE Transactions on Image Processing*, **16**, 2992–3004.
- Blache-Fraser, G., y J. Neep, 2004, Increasing seismic resolution using spectral blueing and colored inversion: Cannonball field, Trinidad, *in* *SEG Technical Program Expanded Abstracts 2004*: Society of Exploration Geophysicists, 1794–1797.
- Bo, Y. Y., G. H. Lee, H.-J. Kim, H.-T. Jou, D. G. Yoo, B. J. Ryu, y K. Lee, 2013, Comparison of wavelet estimation methods: *Geosciences Journal*, **17**, 55–63.

- Bredies, K., y D. A. Lorenz, 2008, Linear convergence of iterative soft-thresholding: *Journal of Fourier Analysis and Applications*, **14**, 813–837.
- Brown, S. P., y M. S. Thorne, 2013, Viterbi sparse spike detection: *Geophysics*, **78**, V157–V169.
- Brunini, G., J. Sabbione, y D. Velis, 2017, Differential evolution for microseismic event location: XVII Workshop on Information Processing and Control (RPIC), Expanded Abstracts, IEEE, 1–6.
- Brunini Garcia, G. I., 2023, Caracterización de eventos microsísmicos: procesamiento y algoritmos: PhD thesis, Universidad Nacional de La Plata.
- Cary, P., 2006, Reflections on the deconvolution of land seismic data: CSEG RECORDER, Special Edition, 24–28.
- Chai, X., G. Tang, K. Lin, Z. Yan, H. Gu, R. Peng, X. Sun, y W. Cao, 2021, Deep learning for multitrace sparse-spike deconvolution: *Geophysics*, **86**, V207–V218.
- Chen, S. S., D. L. Donoho, y M. A. Saunders, 2001, Atomic decomposition by basis pursuit: *SIAM review*, **43**, 129–159.
- Chen, Z., X. Chen, Y. Wang, y J. Li, 2014, Estimation of Q factors from reflection seismic data for a band-limited and stabilized inverse Q filter driven by an average-Q model: *Journal of Applied Geophysics*, **101**, 86–94.
- Chengzao, J., 2017, Breakthrough and significance of unconventional oil and gas to classical petroleum geology theory: *Petroleum Exploration and Development*, **44**, 1–10.
- Chávez-Pérez, S., y M. A. Centeno-Miranda, 2013, Does frequency enhancement imply vertical resolution improvement?: International Exposition and 83th Annual Meeting, Expanded Abstracts, SEG, 1487–1491.
- Cooke, D., y W. Schneider, 1983, Generalized linear inversion of reflection seismic data: *Geophysics*, **46**, 665–676.
- Daubechies, I., M. Defrise, y C. D. Mol, 2004, An iterative thresholding algorithm for linear inverse problems with a sparsity constraint: *Communications on Pure and Applied Mathematics*, **57**, 1413–1457.
- Davis, J., 1986, *Statistics and data analysis in geology*.
- Debye, H. W. J., y P. van Riel, 1990, Lp-norm deconvolution: *Geophysical Prospecting*, **38**, 381–403.
- Duchesne, M., y P. Gaillot, 2011, Did you smooth your welllogs the right way for seismic interpretation?: *Journal of Geophysics and Engineering*, **8**, 514–523.
- Edgar, J., y M. van der Baan, 2011, How reliable is statistical wavelet estimation?: *Geophysics*, **76**, V59–V68.
- Ekinci, Y. L., Ç. Balkaya, G. Göktürkler, y H. Ai, 2023, 3-d gravity inversion for the basement relief reconstruction through modified success-history-based adaptive differential evolution: *Geophysical Journal International*, **235**, 377–400.
- Farquharson, C. G., y D. W. Oldenburg, 2004, A comparison of automatic techniques for estimating the regularization parameter in non-linear inverse problems: *Geophysical Journal International*, **156**, 411–425.
- Figueiredo, M., 2003, Adaptive sparseness for supervised learning: *IEEE transactions on pattern analysis and machine intelligence*, **25**, 1150–1159.
- Figueiredo, M. A. T., R. D. Nowak, y S. J. Wright, 2007, Gradient projection for sparse reconstruction: Application to compressed sensing and other inverse problems: *IEEE Journal of selected topics in signal processing*, **1**, 586–597.
- Fomel, S., 2007, Local seismic attributes: *Geophysics*, **72**, A29–A33.

- Fomel, S., y M. van der Baan, 2014, Local skewness attribute as a seismic phase detector: Interpretation, **2**, SA49–SA56.
- Fritsch, F., y R. Carlson, 1980, Monotone piecewise cubic interpolation: SIAM, **17**.
- Futterman, W. I., 1962, Dispersive body waves: Journal of Geophysical Research, **67**, 5279–5291.
- Gabor, D., 1946, Theory of communication. part 1: The analysis of information: Journal of the Institution of Electrical Engineers-part III: radio and communication engineering, **93**, 429–441.
- Gass, S. I., 1958, Linear programming methods and applications: McGraw-Hill.
- Gelpi, G., D. Pérez, y D. Velis, 2018, Una nueva estrategia para el ajuste automático entre perfiles de pozo y datos sísmicos: Terceras Jornadas de Geociencias para la Ingeniería, FIUBA, 47–48.
- , 2019a, Automatic seismic-to-well tie by restricted adjustment of sonic logs: Presentado en AAPG 2019 International Convention & Exhibition, Extended Abstracts, AAPG.
- Gelpi, G. R., D. O. Pérez, y D. R. Velis, 2019b, Seismic wavelet phase estimation by 11-norm minimization: Journal of Seismic Exploration, **28**, 393–411.
- , 2021a, Borehole-consistent sparse-spike seismic deconvolution and frequency enhancement: First International Meeting for Applied Geoscience & Energy, Society of Exploration Geophysicists, 3301–3305.
- Gelpi, G. R., D. O. Pérez, y D. R. Velis, 2017, Seismic wavelet phase estimation by 11 norm minimization: 2017 XVII Workshop on Information Processing and Control (RPIC), 1–6.
- , 2019c, Simultaneous automatic well-to-seismic tie and wavelet phase estimation: 89th Annual International Meeting, Expanded Abstracts, Society of Exploration Geophysicists, 4 pages.
- , 2020a, Automatic well tying and wavelet phase estimation with no waveform stretching or squeezing: Geophysics, **85**, D83–D91.
- , 2021b, Borehole-guided sparse spike deconvolution: 1st SEG Latin America Virtual Student Conference, Expanded Abstracts, Society of Exploration Geophysicists, 1 page.
- Gelpi, G. R., D. Velis, y D. Pérez, 2020b, Un nuevo método para la deconvolución sísmica y realce en frecuencias: Investigación Joven, **7**, 107–108.
- Gelpi, G. R., y D. R. Velis, 2017, Estimación de la fase de la ondícula sísmica mediante la minimización de las normas  $l_1$  y  $l_{2,1}$ : Presentado en IPSES'17-XXVIII Reunión Científica de la Asociación Argentina de Geofísicos y Geodestas, Libro de resúmenes.
- Gholami, A., y M. D. Sacchi, 2012, A fast and automatic sparse deconvolution in the presence of outliers: IEEE Transactions on Geoscience and Remote Sensing, **50**, 4105–4116.
- Gill, D., 1970, Application of a statistical zonation method to reservoir evaluation and digitized-log analysis: AAPG Bulletin, **54**, 719–729.
- Gill, D., A. Shomrony, y H. Fligelman, 1993, Numerical zonation of log suites and logfacies recognition by multivariate clustering: AAPG bulletin, **77**, 1781–1791.
- Gramfort, A., D. Strohmeier, J. Haueisen, M. Hämäläinen, y M. Kowalski, 2013, Time-frequency mixed-norm estimates: Sparse M/EEG imaging with non-stationary source activations: NeuroImage, **70**, 410–422.
- Hackert, C. L., y J. O. Parra, 2002, Calibrating well logs to VSP attributes interval velocity and amplitude: The Leading Edge, **21**, 52–57.

- Hargreaves, N., y A. Calvert, 1991, Inverse Q filtering by Fourier transform: *Geophysics*, **56**, 519–527.
- Hastie, T., R. Tibshirani, y J. Friedman, 2009, *The elements of statistical learning: data mining, inference, and prediction*: Springer Science & Business Media.
- Hennenfent, G., E. van den Berg, M. P. Friedlander, y F. J. Hermann, 2008, New insights into one-norm solvers from the Pareto curve: *Geophysics*, **73**, 23–26.
- Henry, S. G., 1997, Catch the (seismic) wavelet: *AAPG Explorer*, **18**, 36–38.
- Herrera, H., S. Fomel, y M. van der Baan, 2014, Automatic approaches for seismic to well tying: *Interpretation*, **2**, SD101–SD109.
- Herrera, H., y M. van der Baan, 2014, A semiautomatic method to tie welllogs to seismic data: *Geophysics*, **79**, V47–V54.
- Herron, D., 2011, *First steps in seismic interpretation*: Society of Exploration Geophysicists.
- IEA, 2023, *World energy outlook 2023*: IEA.
- Ingber, L., 1989, Very fast simulated re-annealing: *Journal of Mathematical Computation and Modelling*, **12**, 967–973.
- Jaynes, E. T., 1957, Information theory and statistical mechanics: *Physical review*, **106**, 620.
- Johnston, D. H., 2010, *Methods and applications in reservoir geophysics*: Society of Exploration Geophysicists.
- Kaarsen, K. F., y T. Taxt, 1998, Multichannel blind deconvolution of seismic signals: *Geophysics*, **63**, 2093–2107.
- Kahoo, A., y S. Gholtashi, 2015, An improvement in temporal resolution of seismic data using logarithmic time-frequency transform method: *Iranian Journal of Oil and Gas Science and Technology*, **4**, 27–39.
- Kallweit, R., y L. Wood, 1982, The limits of resolution of zero-phase wavelets: *Geophysics*, **47**, P1035–P1046.
- Kazemini, S. H., C. Yang, C. Juhlin, S. Fomel, y C. Cosma, 2010, Enhancing seismic data resolution using the prestack blueing technique: An example from the ketzin CO<sub>2</sub> injection site, Germany: *Geophysics*, **75**, V101–V110.
- Kazemi, N., 2018, Automatic blind deconvolution with Toeplitz-structured sparse total least squares: *Geophysics*, **83**, V345–V357.
- Kazemi, N., y M. D. Sacchi, 2014, Sparse multichannel blind deconvolution: *Geophysics*, **79**, V143–V152.
- Kjartansson, E., 1979, Constant Q-wave propagation and attenuation: *Journal of Geophysical Research: Solid Earth*, **84**, 4737–4748.
- Kroode, F. T., S. Bergler, C. Corsten, J. W. de Maag, F. Strijbos, y H. Tjihof, 2013, Broadband seismic data - the importance of low frequencies: *Geophysics*, **78**, WA3–WA14.
- Kumar, S., K. Kumari, y A. Biswal, 2008, Frequency enhancement of seismic data - a comparative study: *CSEG RECORDER, Expanded Abstracts, CSEG*, 33–43.
- Larson, R., y B. H. Edwards, 1999, *Elementary linear algebra*, 4th ed.: Houghton Mifflin Company.
- Leaney, W., y T. Ulrych, 1987, Compound median filtering applied to sonic logs: Presentado en SEG International Exposition and 57th Annual Meeting, Expanded Abstracts, SEG.
- Levy, S., y P. K. Fullagar, 1981, Reconstruction of a sparse spike train from a portion of its spectrum and application to high-resolution deconvolution: *Geophysics*, **46**,

- 1235–1243.
- Levy, S., y D. W. Oldenburg, 1987, Automatic phase correction of common-midpoints stacked data: *Geophysics*, **52**, P51–P59.
- Liang, C., J. Castagna, y R. Zavala Torres, 2017, Tutorial: Spectral bandwidth extension—invention versus harmonic extrapolation: *Geophysics*, **82**, W1–W16.
- Ligges, U., C. Weihs, y P. Hasse-Becker, 2002, Detection of locally stationary segments in time series: *Compstat: Proceedings in Computational Statistics*, Springer, 285–290.
- Lillie, R. J., 1999, *Whole earth geophysics: An introductory textbook for geologists and geophysicists*: Prentice Hall.
- Lindsey, J., 1989, The Fresnel zone and its interpretive significance: *The Leading Edge*, **8**, 33–39.
- Longbottom, J., A. T. Walden, y R. E. White, 1988, Principles and application of maximum kurtosis phase estimation: *Geophysical Prospecting*, **36**, 115–138.
- Lu, W., 2005, Non-minimum-phase wavelet estimation using second and third order moments: *Geophysical Prospecting*, **53**, 149–158.
- Ma, M., S. Wang, S. Yuan, J. Wang, T. Wang, J. Haueisen, M. Hämäläinen, y M. Kowalski, 2015, The comparison of skewness and kurtosis criteria for wavelet phase estimation: *SEG Technical Program Expanded Abstracts*, 5164–5168.
- Mamasani, M., N. Manaman, K. Kazemi, y M. Mirzakhani, 2017, Resolution enhancement of seismic data using spectral modeling based on Ricker components and separable nonlinear least squares: *The Leading Edge*, 480–486.
- Marfurt, K., y M. de Matos, 2014, Spectral balancing can enhance vertical resolution: *Search and Discovery Article*, **41357**.
- Martin, G. S., R. Wiley, y K. J. Marfurt, 2006, Marmousi2: An elastic upgrade for Marmousi: *The Leading Edge*, **25**, 156–166.
- Menke, W., 2018, *Geophysical data analysis: Discrete inverse theory*: Academic Press.
- Metropolis, N., A. Rosenbluth, M. Rosenbluth, A. Teller, y E. Teller, 1953, Equation of state calculations by fast computing machines: *Journal of Chemical Physics*, **21**, 1087–1092.
- Monk, D. J., 2020, *Survey design and seismic acquisition for landmarine, and in-between in light of new technology and techniques*: Society of Exploration Geophysicists.
- Mueller, M., 2007, *Dynamic time warping in information retrieval for music and motion*: Springer.
- Muñoz, A., y D. Hale, 2012, *Automatically tying well logs to seismic data*: Technical Report 725, Center for Wave Phenomena, Colorado School of Mines.
- , 2015, Automatic simultaneous multiple well ties: *Geophysics*, **80**, IM45–IM51.
- Murphy, K. P., 2012, *Machine learning: a probabilistic perspective*: MIT press.
- Neidell, N., 1991, Could the processed seismic wavelet be simpler than we think?: *Geophysics*, **56**, P681–P690.
- Newrick, R., 2012, *Well tie perfection - 52 things you should know about Geophysics*: Agile Libre.
- Oldenburg, D. W., T. Scheuer, y S. Levy, 1983, Recovery of the acoustic impedance from reflection seismograms: *Geophysics*, **48**, 1318–1337.
- Peacock, K. L., y S. Treitel, 1969, *Predictive deconvolution-theory and practice*: *Geophysics*, **34**, 155–169.
- Pereg, D., I. Cohen, y A. A. Vassiliou, 2020, Sparse seismic deconvolution via recurrent neural network: *Journal of Applied Geophysics*, **175**, 103979.

- Pérez, D. O., 2015, Nuevas estrategias para la inversión sparse de datos sísmicos prestack: PhD thesis, Facultad de Ciencias Astronómicas y Geofísicas, Universidad Nacional de La Plata, Argentina.
- Pérez, D. O., G. R. Gelpi, y D. R. Velis, 2024, Borehole-driven sparse-spike deconvolution and seismic bandwidth enhancement: *Geophysics*, **89**, V25–V35.
- Pérez, D. O., y D. R. Veils, 2011, Sparse-spike avo/ava attributes from prestack data, *in* SEG Technical Program Expanded Abstracts 2011: Society of Exploration Geophysicists, 340–344.
- Pérez, D. O., y D. R. Velis, 2018, Simple and fast gradient-based impedance inversion using total variation regularization: *Journal of Seismic Exploration*, **27**.
- Pérez, D. O., D. R. Velis, y M. D. Sacchi, 2013, High-resolution prestack seismic inversion using a hybrid FISTA least-squares strategy: *Geophysics*, **78**, R185–R195.
- , 2017, Three-term inversion of prestack seismic data using a weighted mixed norm: *Geophysical Prospecting*, **65**, 1477–1495.
- Price, D., A. Curtis, y R. Wood, 2008, Statistical correlation between geophysical logs and extracted core: *Geophysics*, **73**, E97–E106.
- Puryear, C. I., y J. P. Castagna, 2008, Layer-thickness determination and stratigraphic interpretation using spectral inversion: Theory and application: *Geophysics*, **73**, R28–R37.
- Qi, C., y F. Hilterman, 2017, Well ties for seismic with severe stratigraphic filtering: *Geophysics*, **82**, IM31–IM39.
- Ricker, N., 1940, The form and nature of seismic waves and the structure of seismograms: *Geophysics*, **5**, 348–366.
- , 1953, Wavelet contraction, wavelet expansion, and the control of seismic resolution: *Geophysics*, **18**, 769–792.
- Robinson, E. A., y S. Treitel, 2002, *Geophysical Signal Analysis*: Society of Exploration Geophysicists.
- , 2008, *Digital imaging and deconvolution: The ABCs of seismic exploration and processing*: Society of Exploration Geophysicists.
- Ryan, H., O. Ricker, y B.-A. Klaunder, 1994, A choice of wavelets: *CSEG Recorder*, **9**.
- Sacchi, M., 1997, Reweighting strategies in seismic deconvolution: *Geophysical Journal International*, **129**, 651–656.
- Sacchi, M. D., y T. J. Ulrych, 2000, Nonminimum-phase wavelet estimation using higher order statistics: *The Leading Edge*, **19**, 80–83.
- Sacchi, M. D., D. R. Velis, y A. H. Comínguez, 1994, Minimum entropy deconvolution with frequency domain constraints: *Geophysics*, **6**, 938–945.
- Sacchi, M. D., D. R. Velis, y T. J. Ulrych, 1996, Wavelet via polycepstra: 66th Annual International Meeting, Expanded Abstracts, SEG, 1583–1586.
- Sajid, M., y D. Ghosh, 2014, A fast and simple method of spectral enhancement: *Geophysics*, **79**, V75–V80.
- Schoenberger, M., 1974, Resolution comparison of minimum-phase and zero-phase signals: *Geophysics*, **39**, 826–833.
- Sen, M. K., y P. L. Stoffa, 2013, *Global optimization methods in geophysical inversion*: Cambridge University Press.
- Shearer, P. M., 2019, *Introduction to seismology*: Cambridge University Press.
- Sheriff, R., y L. Geldart, 1995, *Exploration seismology*: Cambridge University Press.
- Simm, R., y M. Bacon, 2014, *Seismic amplitude: An interpreter's handbook*: Cambridge University Press.

- Soldo, J., D. Velis, y P. Lafourcade, 2008, Estrategias de post-procesamiento para el aumento de resolución sísmica vertical basada en algoritmos: VII Congreso de Exploración y Desarrollo de Hidrocarburos (Simposio La Geofísica: Integradora del Conocimiento del Subsuelo), European Association of Geoscientists & Engineers, cp-261.
- Somasundaram, S., A. Das, y S. Kumar, 2015, Delineating thin sand connectivity in a complex fluvial system in Mangala field, India, using high resolution seismic data: *First Break*, **33**.
- Stark, T. J., et al., 2009, Frequency enhancement via an integer multiplier or just another geowizardry attribute?: Presentado en 2009 SEG Annual Meeting, Society of Exploration Geophysicists.
- Storn, R., 1996, Differential evolution design of an iir-filter: Proceedings of IEEE international conference on evolutionary computation, IEEE, 268–273.
- Storn, R., y K. Price, 1997, Differential evolution: A simple and efficient heuristic for global optimization over continuous spaces *Journal of Global Optimization*, **11**, 341–359.
- Sui, Y., y J. Ma, 2020, Blind sparse-spike deconvolution with thin layers and structure: *Geophysics*, **85**, V481–V496.
- Talbi, E. G., 2009, *Metaheuristics: from design to implementation*: John Wiley and Sons.
- Tarantola, A., 2005, *Inverse problem theory and methods for model parameter estimation*: SIAM. (Available at the Web).
- Tarback, E., y F. Lutgens, 2005, *Ciencias de la tierra, una introducción a la geología física*: Pearson Prentice Hall.
- Taylor, H. L., S. C. Banks, y J. F. McCoy, 1979, Deconvolution with the  $l_1$  norm: *Geophysics*, **44**, 39–52.
- Tellier, N., 2015, Vibrator evolutions for broadband performance: accomplishments and remaining issues: EAGE Workshop on Broadband Seismic, European Association of Geoscientists & Engineers, 1–4.
- Tibshirani, R., 1996, Regression shrinkage and selection via the Lasso: *Journal of the Royal Statistical Society: Series B (Methodological)*, **58**, 267–288.
- Tikhonov, A. N., 1963, On the solution of ill-posed problems and the method of regularization: *Doklady Akademii Nauk, Russian Academy of Sciences*, 501–504.
- Torben Hoy, P., 2013, A step change in seismic imaging using a unique ghost free source and receiver system: CSEG GeoConvention.
- Trantham, E. C., 1994, Controlled-phase acquisition and processing, *in* SEG Technical Program Expanded Abstracts 1994: Society of Exploration Geophysicists, 890–894.
- Udías, A., y Y. Mezcuá, 1986, *Fundamentos de Geofísica*: Ed. Alambra, SA, Madrid, España.
- Ulrych, T. J., y M. D. Sacchi, 2005, *Information-based inversion and processing with applications*: Elsevier.
- Ulrych, T. J., D. R. Velis, y M. D. Sacchi, 1995, Wavelet estimation revisited: *The Leading Edge*, **10**, 1139–1143.
- van den Berg, E., y M. Friedlander, 2008, Probing the Pareto frontier for basis pursuit solutions: *SIAM Journal of Scientific Computing*, **31**, 890–912.
- van der Baan, M., 2008, Time-varying wavelet estimation and deconvolution by kurtosis maximization: *Geophysics*, **73**, V11–V18.

- , 2012, Bandwidth enhancement: Inverse Q filtering or time-varying Wiener deconvolution?: *Geophysics*, **77**, V133–V142.
- Velis, D. R., 1998, Application of simulated annealing to some seismic problems: PhD thesis, University of British Columbia, Vancouver, Canada.
- , 2003, Estimating the distribution of primary reflection coefficients: *Geophysics*, **68**, 1417–1422.
- , 2007, Statistical segmentation of geophysical log data: *Mathematical geology*, **39**, 409–417.
- , 2008, Stochastic sparse-spike deconvolution: *Geophysics*, **73**, R1–R9.
- Velis, D. R., y T. J. Ulrych, 1996, Simulated annealing wavelet estimation via fourth-order cumulant matching: *Geophysics*, **61**, 1939–1948.
- Walden, A., y J. Hosken, 1986, The nature of the non-Gaussianity of primary reflection coefficients and its significance for deconvolution: *Geophysical Prospecting*, **34**, 1038–1066.
- Walden, A., y R. White, 1984, On errors of fit and accuracy in matching synthetic seismograms and seismic traces: *Geophysical Prospecting*, **32**, 871–891.
- Walden, A. T., 1985, Non-gaussian reflectivity, entropy, and deconvolution: *Geophysics*, **12**, 2862–2888.
- Wang, C., y J. Gao, 2010, A new differentialevolution algorithm with cooperative coevolutionary selection operator for waveform inversion: 2010 IEEE International Geoscience and Remote Sensing Symposium, IEEE, 688–690.
- Wang, K., J. Lomask, y F. Segovia, 2017, Automatic, geologic layer-constrained well-seismic tie through blocked dynamic warping: *Interpretation*, **5**, SJ81–SJ90.
- Wang, Y., 2009, *Seismic inverse Q filtering*: John Wiley & Sons.
- Wang, Z., B. Zhang, y J. Gao, 2014, The residual phase estimation of a seismic wavelet using a Rényi divergence-based criterion: *Journal of Applied Geophysics*, **106**, 96–105.
- Webster, R., 1973, Automatic soil-boundary location from transect data: *Journal of the International Association for Mathematical Geology*, **5**, 27–37.
- Welayaturromadhona, W. Utama, F. Syaifuddin, y H. W. Chen, 2017, Resolution enhancement for hydrate imaging by loop reconvolution: International Geophysical Conference, Qingdao, China, 17–20 April 2017, Society of Exploration Geophysicists and Chinese Petroleum Society, 928–931.
- White, R., 1988, Maximum kurtosis phase correction: *Geophysical Journal International*, **95**, 371–389.
- White, R., y T. Hu, 1998, How accurate can a well tie be?: *The Leading Edge*, **17**, 993–1176.
- White, R., y R. Simm, 2003, Tutorial: Good practice in wellties: *First Break*, **21**, 75–83.
- Widess, M., 1973, How thin is a thin bed?: *Geophysics*, **38**, 1176–1180.
- Wiggins, R., 1978, Minimum entropy deconvolution: *Geoexploration*, **16**, 21–35.
- Wu, H., B. Zhang, R. Liu, y N. Liu, 2017, Seismic wavelet phase estimation by semi-automatic seismic-well tying: International Exposition and 87th Annual Meeting, Expanded Abstracts, SEG, 651–655.
- Xu, Y., P. Thore, y S. Duchenne, 2012, The reliability of the kurtosis-based wavelet estimation: SEG Expanded Abstract.
- Yilmaz, Ö., 2001, *Seismic data analysis: processing, inversion, and interpretation of seismic data*: Society of Exploration Geophysicists Investigations in Geophysics.

- Young, P., A. Wild, y U. Nexen Petroleum, 2005, Cosmetic enhancement of seismic data by loop reconvolution: Presentado en CSEG convention.
- Yuan, S. Y., y X. Wang, 2011, Influence of inaccurate wavelet phase estimation on seismic inversion: *Applied Geophysics*, **8**, 48–59.
- Zhang, R., y J. Castagna, 2011, Seismic sparse-layer reflectivity inversion using basis pursuit decomposition: *Geophysics*, **76**, R147–R158.
- Zhou, H.-W., 2014, *Practical seismic data analysis*: Cambridge University Press.
- Ziolkowski, A., J. R. Underhill, y R. G. K. Johnston, 1998, Wavelets, well ties, and the search for subtle stratigraphic traps: *Geophysics*, **63**, P297–P313.