

解像度の異なる複数の時間周波数表現を用いた独立低ランク行列分析*

☆細谷泰稚, 北村大地 (香川高専), 矢田部浩平 (早稲田大)

1 はじめに

ブラインド音源分離 (blind source separation: BSS) [1] は, 混合系や音源情報が未知の条件下で, 複数の音源が混合した観測信号から混合前の各音源信号を推定する技術である. BSS は補聴器や自動採譜, 音声認識等の様々な技術に応用されている.

チャンネル数が音源数以上となる観測信号を扱う優決定条件 BSS は, 周波数領域独立成分分析 (frequency-domain independent component analysis: FDICA) [2] 及び周波数毎の分離信号の順番を適切に並び替えるパーミュテーション問題の解決法が基礎技術となる [3]. 2006 年に, FDICA に対して音源の時間周波数構造仮定を導入し, パーミュテーション問題を回避しつつ分離信号を推定する独立ベクトル分析 (independent vector analysis: IVA) [4] が登場した. その後, 補助関数法 [5] 及び反復射影法 (iterative projection: IP) [6] に基づく安定かつ高速な IVA [7] が提案されている. 2016 年には, 非負値行列因子分解 (nonnegative matrix factorization: NMF) [8] に基づく低ランク時間周波数構造を音源モデルに取り入れた独立低ランク行列分析 (independent low-rank matrix analysis: ILRMA) [9, 10, 1] が提案された. また, 音源モデルを plug-and-play で変更可能な BSS [11] も提案されている. さらに, 時間周波数領域におけるスペクトログラム無矛盾性 [12] と呼ばれる性質を FDICA 及び IVA に導入した BSS [13] や ILRMA に導入した BSS (consistent ILRMA) [14] も提案されている.

ILRMA の最適化は, 時間周波数領域における空間モデル (周波数毎の分離行列) の更新と音源モデル (NMF による低ランク時間周波数構造) の更新からなる. 信号の時間周波数表現は短時間フーリエ変換 (short-time Fourier transform: STFT) によって得られるが, 過去の実験的な調査 [15] より, ILRMA の分離性能は STFT の窓長に強く依存することが分かっている. 具体的には, STFT の窓長が短すぎる場合, 周波数領域での瞬時混合仮定が成立せず性能が劣化 [16] し, 逆に窓長が長すぎる場合, 時間フレーム数が減少し統計的推定が不安定となり性能が劣化する. 従って, STFT の窓長にはトレードオフが存在する.

本稿では, 前述の STFT の窓長に関する傾向に基づき, ILRMA の性能向上を目的として, 空間モデル及び音源モデルの最適化に異なる時間周波数表現を導

入したアルゴリズムを提案する. また, 各モデルの最適化で同一の時間周波数表現を用いる従来の ILRMA が常に最良とは限らないことを実験的に示す.

2 提案手法

2.1 定式化と優決定条件 BSS

N 個の音源信号が M 個のマイクロホンで観測される状況を考える. 時間領域の多チャンネルの音源信号, 観測信号, 及び分離信号をそれぞれ次式で表す. なお, 信号の時間領域及び時間周波数領域における二つの表現の混同を避けるため, それぞれの領域でのベクトルをローマン体及びイタリック体で示す.

$$\mathbf{s}[l] = [s_1[l], \dots, s_n[l], \dots, s_N[l]]^T \in \mathbb{R}^N \quad (1)$$

$$\mathbf{x}[l] = [x_1[l], \dots, x_m[l], \dots, x_M[l]]^T \in \mathbb{R}^M \quad (2)$$

$$\mathbf{y}[l] = [y_1[l], \dots, y_n[l], \dots, y_N[l]]^T \in \mathbb{R}^N \quad (3)$$

ここで, $n = 1, 2, \dots, N$, $m = 1, 2, \dots, M$, 及び $l = 1, 2, \dots, L$ はそれぞれ音源, チャンネル, 及び離散時間のインデックスであり, $\cdot^T$ は転置を表す. また, 時間領域の信号 $\mathbf{z} = [z[1], \dots, z[l], \dots, z[L]]^T \in \mathbb{R}^L$ の STFT を次式で表記する.

$$\mathbf{Z} = \text{STFT}_{\omega}(\mathbf{z}) \in \mathbb{C}^{I \times J} \quad (4)$$

ここで, ω は解析時の窓関数を表す. 合成時の窓関数を $\tilde{\omega}$ とおくと, 逆 STFT を $\text{ISTFT}_{\tilde{\omega}}(\cdot)$ と表記する. 本稿では, ω と $\tilde{\omega}$ のペアが次式の完全再構成条件を満たすことを仮定する.

$$\mathbf{z} = \text{ISTFT}_{\tilde{\omega}}(\text{STFT}_{\omega}(\mathbf{z})) \quad \forall \mathbf{z} \in \mathbb{R}^L \quad (5)$$

各チャンネルに STFT を適用して得られる音源信号, 観測信号, 及び分離信号のスペクトログラムの (i, j) 番目の要素をそれぞれ次式で表す.

$$\mathbf{s}_{ij} = [s_{ij1}, \dots, s_{ijn}, \dots, s_{ijN}]^T \in \mathbb{C}^N \quad (6)$$

$$\mathbf{x}_{ij} = [x_{ij1}, \dots, x_{ijm}, \dots, x_{ijM}]^T \in \mathbb{C}^M \quad (7)$$

$$\mathbf{y}_{ij} = [y_{ij1}, \dots, y_{ijn}, \dots, y_{ijN}]^T \in \mathbb{C}^N \quad (8)$$

ここで, $i = 1, 2, \dots, I$ 及び $j = 1, 2, \dots, J$ はそれぞれ周波数ビン及び時間フレームのインデックスを表す. ILRMA を含む周波数領域 BSS では, 次式で表される周波数領域での瞬時混合を仮定する.

$$\mathbf{x}_{ij} = \mathbf{A}_i \mathbf{s}_{ij} \quad (9)$$

*Independent low-rank matrix analysis using multiple time-frequency representations with different resolutions. by Taichi HOSOTANI, Daichi KITAMURA (NIT Kagawa), and Kohei YATABE (Waseda Univ.).




Fig. 1 Vocal spectrograms using (a) narrow (32 ms) and (b) wide (256 ms) windows.

ここで, $\mathbf{A}_i \in \mathbb{C}^{M \times N}$ は周波数毎の混合行列である.

優決定条件 BSS では $M = N$ を仮定でき, BSS は $\mathbf{A}_i$ の逆行列を推定する問題となる. この逆行列を $\mathbf{W}_i \approx \mathbf{A}_i^{-1}$ とすると, 分離信号は次式となる.

$$\mathbf{y}_{ij} = \mathbf{W}_i \mathbf{x}_{ij} \quad (10)$$

ここで, $\mathbf{W}_i = [\mathbf{w}_{i1}, \dots, \mathbf{w}_{in}, \dots, \mathbf{w}_{iN}]^H \in \mathbb{C}^{N \times M}$ は分離行列と呼ばれ, $\cdot^H$ はエルミート転置を表す. なお, 観測信号及び分離信号については, 時間周波数行列の表記も $\mathbf{X}_m \in \mathbb{C}^{I \times J}$ 及び $\mathbf{Y}_n \in \mathbb{C}^{I \times J}$ と定義する.

2.2 動機

STFT における窓長が観測信号の残響時間より短い場合, 時間領域の残響による畳み込み混合を時間周波数領域の瞬時混合に変換できず, 式 (9) の仮定が成り立たないため, 式 (10) での高精度な BSS は原理的に困難となる. そのため, STFT の窓長は残響時間を十分超える長さ (例えば 256 ms 以上) に設定されることが一般的である. 一方で, 音声や楽器音等の音響信号を時間周波数解析する場合は, 16~128 ms 程度の窓長で STFT を適用する場合が多い. ILRMA においても, 各音源のスペクトログラムを NMF でモデル化する関係上, 低ランク行列として良く近似できる窓長が存在するはずである. 例として, Fig. 1 (a) 及び (b) にボーカルの音響信号のスペクトログラムを異なる窓長で示している. この図から, NMF によるスペクトログラムの近似精度は窓長の長さに大きく依存することが予想される. 従って, ILRMA においては音源モデルの最適化の観点からも適切な窓長が存在し, それは前述の空間モデルの窓長の最適値とは異なる可能性がある.

以上の動機より, 本稿では ILRMA の空間モデルと音源モデルの各変数の最適化において, 異なる時間周波数解像度のスペクトログラムを用いるアルゴリズムを新たに提案し, 性能の変化を実験的に調査する. 但し, STFT の窓長に依存して周波数ビン数 I




Fig. 2 Narrow and wide window functions used in proposed algorithm.

及び時間フレーム数 J が変化するため, ILRMA の最適化アルゴリズムにおいて異なる時間周波数解像度のスペクトログラムの扱い方には任意性が生じる. この任意性を回避するため, 提案手法では, Fig. 2 に示すように, STFT における窓関数の幅を変化させることにより, 見かけ上の窓長を変化させる.

2.3 最適化アルゴリズム

提案手法は, 従来の ILRMA における分離行列 $\mathbf{W}_i$ と NMF 音源モデル $\mathbf{T}_n \in \mathbb{R}_{\geq 0}^{I \times K}$ 及び $\mathbf{V}_n \in \mathbb{R}_{\geq 0}^{K \times J}$ の反復更新則に, プロジェクションバック法 (back projection: BP) [17] 及び時間周波数表現の変換を追加した形となる. ここで, K は NMF の基底数を表す. また時間周波数表現の変換とは, 分離信号 $\mathbf{Y}_n$ に関して, 窓関数 $\omega^{(\text{Ex})}$ で得られる空間モデル最適化用の表現 $\mathbf{Y}_n^{(\text{Ex})}$ から, 窓関数 $\omega^{(\text{In})}$ で得られる音源モデル最適化用の表現 $\mathbf{Y}_n^{(\text{In})}$ に変換する処理を指す.

提案手法の最適化アルゴリズムを Algorithm 1 に示す. ここで, 行列間の演算子 $\odot$ 及び分数はそれぞれ要素毎の積及び商, 行列に対する $|\cdot|$ 及びドット付き指数はそれぞれ要素毎の絶対値及び指数乗及び $[\cdot]_{r,c}$ は行列の (r, c) 番目の要素を表す. また, $\mathbf{e}_n \in \{0, 1\}^N$ は n 番目の要素のみ 1 の単位ベクトル, m_{ref} は BP のためのリファレンスチャンネルを表す. Algorithm 1 中の 6 及び 7 行目が NMF 音源モデルの更新, 8~10 行目が IP に基づく分離行列の更新, 11~14 行目が m_{ref}

Algorithm 1 Proposed ILRMA

Input: $\{\mathbf{x}[l]\}_{l=1}^L, \text{maxlter}$
Output: $\{\mathbf{y}[l]\}_{l=1}^L$

```

1: Initialize  $\{\mathbf{T}_n\}_{n=1}^N, \{\mathbf{V}_n\}_{n=1}^N, \{\mathbf{W}_i\}_{i=1}^I$ 
2:  $\mathbf{X}_n^{(\text{In})} = \text{STFT}_{\omega^{(\text{In})}}(\mathbf{x})$ 
3:  $\mathbf{X}_n^{(\text{Ex})} = \text{STFT}_{\omega^{(\text{Ex})}}(\mathbf{x})$ 
4:  $y_{ijn}^{(\text{In})} = \mathbf{w}_{in}^H \mathbf{x}_{ij}^{(\text{In})} \forall i, j, n$ 
5: for iter = 1, 2, ..., maxlter do
6:    $\mathbf{T}_n \leftarrow \mathbf{T}_n \odot \left\{ \frac{[|\mathbf{Y}_n^{(\text{In})}|^2 \odot (\mathbf{T}_n \mathbf{V}_n)^{-2}] \mathbf{V}_n^T}{(\mathbf{T}_n \mathbf{V}_n)^{-1} \mathbf{V}_n^T} \right\}^{\frac{1}{2}} \forall n$ 
7:    $\mathbf{V}_n \leftarrow \mathbf{V}_n \odot \left\{ \frac{\mathbf{T}_n^T [|\mathbf{Y}_n^{(\text{In})}|^2 \odot (\mathbf{T}_n \mathbf{V}_n)^{-2}]}{\mathbf{T}_n^T (\mathbf{T}_n \mathbf{V}_n)^{-1}} \right\}^{\frac{1}{2}} \forall n$ 
8:    $\mathbf{U}_{in} \leftarrow \frac{1}{J} \sum_j \frac{1}{[\mathbf{T}_n \mathbf{V}_n]_{i,j}} \mathbf{x}_{ij}^{(\text{Ex})} \mathbf{x}_{ij}^{(\text{Ex})H} \forall i, n$ 
9:    $\mathbf{w}_{in} \leftarrow (\mathbf{W}_i \mathbf{U}_{in})^{-1} \mathbf{e}_n \forall i, n$ 
10:   $\mathbf{w}_{in} \leftarrow \mathbf{w}_{in} (\mathbf{w}_{in}^H \mathbf{U}_{in} \mathbf{w}_{in})^{-\frac{1}{2}} \forall i, n$ 
11:   $\lambda_{in} \leftarrow [\mathbf{W}_i^{-1}]_{m_{\text{ref}}, n} \forall i, n$ 
12:   $\mathbf{w}_{in} \leftarrow \lambda_{in} \mathbf{w}_{in} \forall i, n$ 
13:   $y_{ijn}^{(\text{Ex})} \leftarrow \mathbf{w}_{in}^H \mathbf{x}_{ij}^{(\text{Ex})} \forall i, j, n$ 
14:   $[\mathbf{T}_n]_{i,k} \leftarrow |\lambda_{in}|^2 [\mathbf{T}_n]_{i,k} \forall i, k, n$ 
15:   $\mathbf{Y}_n^{(\text{In})} \leftarrow \text{STFT}_{\omega^{(\text{In})}}(\text{ISTFT}_{\omega^{(\text{Ex})}}(\mathbf{Y}_n^{(\text{Ex})})) \forall n$ 
16: end for
17:  $\mathbf{y} = \text{ISTFT}_{\omega^{(\text{Ex})}}(\mathbf{Y}_n^{(\text{Ex})})$ 

```

番目のチャネルへのBP, 15行目が異なる解像度の時間周波数表現の変換を表す。この最適化アルゴリズムにおいて、空間モデル用の窓関数 $\omega^{(\text{Ex})}$ と音源モデル用の窓関数 $\omega^{(\text{In})}$ が一致する場合は、14行目の時間領域への変換及び時間周波数領域への変換（スペクトログラム無矛盾性を保証する処理）が挿入されているため、consistent ILRMA のアルゴリズムに一致する。従って、提案手法は consistent ILRMA を窓関数に関して一般化した手法とも解釈できる。

3 実験

3.1 実験条件

RWCP データベース [18] 収録のインパルス応答 E2A ($T_{60} = 300$ ms) による2音源の畳み込み混合を行い、10曲分の2チャネル観測信号を生成した。そして、これらの観測信号に対するBSS性能を consistent ILRMA と比較した。評価指標は音源対歪み比 (source-to-distortion ratio: SDR) [19] の改善量 (SDRi) を用いた。STFTにおける窓関数 $\omega^{(\text{Ex})}$ 及び $\omega^{(\text{In})}$ には長さ256 msのChebyshev窓を用い、サイドローブレベルパラメタを変化させることにより、窓関数の見かけ上の幅を変更した。空間モデル及び音源モデルの最適化における両方のChebyshev窓のサイドローブレベルには、Table 1に示す値を用い、これらを総当たり的に変化させた。その他の実験条件はTable 1に示す通りである。なお、STFTの実装に

Table 1 Experimental conditions

Window shift length	32 ms
Side lobe level of Chebyshev window [dB]	{40, 50, 60, 70, 80, 90, 100, 120, 150, 200, 300, 500, 700, 1000, 1500}
Number of bases K	10
Initialization of parameters	$\mathbf{W}_i$: identity matrix $\mathbf{T}_n$ and $\mathbf{V}_n$: random matrices
Number of iterations	200
Number of trials	10 with different random seeds
Reference channel m_{ref}	1

はDGTtool [20, 21] を用いた。

3.2 実験結果

各サイドローブレベルに対して、異なる乱数シードを用いて10回実験を行った際の平均SDRiをFig. 3に示す。なお、Fig. 3 (a)は10曲の観測信号全ての平均SDRi, Fig. 3 (b)~(d)は10曲の観測信号から選んだ3曲の平均SDRiを示している。Fig. 3 (b)~(d)の音源はそれぞれギターとボーカルの混合音源 (Song 1), バイオリンとボーカルの混合音源 (Song 2), ドラムとボーカルの混合音源 (Song 3) である。Fig. 3の太線で囲んだ対角部分は従来の consistent ILRMA の結果、それ以外の部分は異なる解像度の時間周波数表現を用いる提案手法の結果に対応している。

Fig. 3 (b)~(d)において、最も高い平均SDRiを示しているのは、空間モデル用の窓関数 $\omega^{(\text{Ex})}$ 、及び音源モデル用の窓関数 $\omega^{(\text{In})}$ のサイドローブレベルがそれぞれ50 dBと60 dB, 60 dBと90 dB及び70 dBと120 dBの場合であり、対角成分 (consistent ILRMAの結果) から外れた場所に位置していることが分かる。また、Fig. 3 (a)より、10曲の観測信号全ての平均SDRiにおいても、空間モデル用の窓関数 $\omega^{(\text{Ex})}$ のサイドローブレベルが80 dBや90 dBの場合は、音源モデル用の窓関数 $\omega^{(\text{In})}$ のサイドローブレベルを100 dBや120 dBとした方が、consistent ILRMA よりも高い性能を示すことが読み取れる。以上から、音源モデル及び空間モデルの最適化に同一の窓関数を用いることが常に最善の結果を与えるとは限らないことが分かる。

4 おわりに

本稿では、ILRMAにおいて、空間モデル及び音源モデルの最適化にそれぞれ異なる窓長の窓関数を導入する手法を提案した。実験結果から、提案手法は consistent ILRMA と比較して、分離精度が向上する場合があることが確認された。今後の課題として、観測信号ごとに両モデルで用いる窓関数を最適化することが挙げられる。

Average SDRi		Side lobe level used in spatial model optimization [dB]																	
		40	50	60	70	80	90	100	120	150	200	300	500	700	1000	1500			
Side lobe level used in source model optimization [dB]	40	3.25	4.55	1.21	1.24	1.66	1.64	1.80	1.70	1.61	1.69	2.09	2.25	2.00	1.73	0.89			
	50	3.89	6.86	4.77	4.73	4.76	4.43	4.33	4.53	5.05	5.74	5.72	5.82	5.18	4.62	3.96			
	60	2.68	6.83	9.17	7.92	7.87	6.88	6.78	6.80	6.99	6.91	6.73	6.34	6.13	5.29	4.22			
	70	2.02	5.87	6.96	8.42	6.96	6.85	6.50	6.20	5.80	5.41	5.16	5.29	5.30	5.19	4.07			
	80	1.18	3.28	7.20	8.10	7.58	7.66	7.60	6.63	6.28	5.84	5.30	4.96	4.92	4.73	3.82			
	90	0.58	1.16	6.61	8.39	7.62	7.61	7.32	6.80	6.47	6.07	5.32	4.79	4.87	4.52	3.66			
	100	0.22	0.80	5.86	7.72	8.19	7.62	7.38	6.89	6.41	5.82	5.27	4.93	4.86	4.42	3.44			
	120	-0.45	0.00	4.60	6.68	8.30	8.03	7.38	6.75	6.33	5.70	5.22	5.01	4.80	4.33	3.46			
	150	-1.32	-0.56	4.08	4.20	6.56	6.23	7.49	6.65	6.21	5.64	5.10	4.84	4.81	4.22	3.16			
	200	-2.41	-1.92	5.19	4.29	4.93	6.73	7.12	6.15	6.22	5.67	5.14	4.61	4.25	4.14	3.26			
	300	-1.12	2.08	5.38	5.07	4.95	4.56	5.07	4.08	5.85	5.42	5.10	4.34	4.04	4.18	3.35			
	500	0.34	2.31	4.46	4.13	4.35	4.19	3.63	2.93	3.53	4.80	4.48	4.25	3.99	3.88	3.24			
	700	-0.91	3.34	5.33	4.13	4.62	4.50	3.85	3.35	3.41	4.01	3.56	4.40	3.89	3.84	2.92			
	1000	-0.49	3.70	4.74	4.33	4.32	3.97	3.70	3.45	3.55	2.95	3.07	4.44	3.80	3.65	2.96			
	1500	1.43	3.79	4.53	3.90	3.96	4.21	3.93	4.10	3.50	2.38	2.32	3.82	3.45	3.48	2.94			

(a)

Average SDRi		Side lobe level used in spatial model optimization [dB]																	
		40	50	60	70	80	90	100	120	150	200	300	500	700	1000	1500			
Side lobe level used in source model optimization [dB]	40	3.17	3.84	1.26	2.50	1.90	1.32	1.01	1.14	1.27	1.29	1.00	1.45	0.21	0.16	-1.02			
	50	3.49	12.49	3.62	3.66	3.00	1.74	2.11	2.79	2.78	3.86	5.26	5.85	5.25	4.69	2.83			
	60	-1.10	13.06	12.61	10.14	9.43	9.50	9.19	8.66	8.41	7.01	7.76	5.25	4.61	4.23	3.36			
	70	2.32	7.98	1.49	11.91	11.11	9.64	9.57	8.80	8.11	7.74	6.73	5.55	5.20	3.61	4.38			
	80	-1.90	-0.53	6.16	12.78	11.81	10.81	10.34	9.45	9.07	8.60	7.57	6.14	5.23	4.49	3.77			
	90	-2.11	-2.51	9.62	12.62	11.77	11.35	9.70	9.03	8.67	8.49	7.38	6.50	5.83	4.51	4.28			
	100	-0.56	-0.35	8.74	12.32	12.02	10.81	10.12	9.51	8.95	7.99	6.89	6.22	5.64	4.40	4.53			
	120	-3.54	-1.26	10.88	9.76	11.94	10.85	10.63	9.27	8.81	7.77	6.84	6.66	6.31	5.62	4.71			
	150	-3.86	-2.29	8.20	9.23	11.36	11.42	10.61	9.23	8.73	7.82	6.83	6.41	6.33	6.11	4.58			
	200	-7.45	-7.61	5.11	5.29	6.89	9.98	10.87	10.36	9.05	8.22	6.75	6.32	6.32	6.64	5.05			
	300	-3.94	10.08	5.20	5.59	4.86	4.82	6.39	8.89	10.10	8.46	7.17	6.58	6.47	6.58	5.29			
	500	2.28	11.98	4.38	-1.31	2.83	2.55	2.57	4.05	4.82	8.43	7.69	6.69	6.22	6.11	5.52			
	700	-4.74	12.43	3.96	3.22	3.33	4.03	2.74	2.65	3.68	4.96	7.61	6.26	5.56	5.48	4.12			
	1000	-5.30	11.65	3.60	3.39	2.91	3.46	3.06	3.32	3.50	3.34	5.36	7.01	5.86	4.86	4.29			
	1500	2.78	10.72	2.55	2.67	2.18	2.51	2.11	2.06	2.49	2.89	4.13	5.66	6.40	4.45	4.22			

(b)

Average SDRi		Side lobe level used in spatial model optimization [dB]																	
		40	50	60	70	80	90	100	120	150	200	300	500	700	1000	1500			
Side lobe level used in source model optimization [dB]	40	-0.23	3.26	0.16	-0.64	-1.76	-1.73	-1.44	-1.57	-1.22	0.04	1.13	0.79	0.43	0.17	-1.21			
	50	3.05	13.08	3.50	2.26	2.67	1.92	2.42	2.92	3.13	4.42	5.11	6.49	7.27	4.74	4.77			
	60	5.77	10.95	12.21	8.31	10.03	11.18	10.76	10.72	11.54	10.76	8.69	9.92	9.31	8.46	6.86			
	70	4.26	12.67	13.33	10.48	11.26	11.36	11.03	11.12	11.13	10.79	10.32	10.12	9.04	9.34	7.19			
	80	1.48	8.30	13.54	10.80	11.78	12.24	10.56	10.87	10.49	10.56	10.16	9.83	9.72	8.89	7.32			
	90	0.20	4.17	13.78	12.04	12.29	11.22	11.19	10.35	10.42	9.82	9.25	9.09	9.66	9.32	7.43			
	100	-1.51	0.52	13.49	12.54	11.14	11.73	11.39	10.27	10.45	9.87	9.29	9.66	9.93	9.41	7.02			
	120	-0.35	-0.45	11.52	13.20	12.82	11.23	11.56	10.62	10.55	9.89	9.19	9.94	9.46	9.34	7.09			
	150	-1.70	0.06	5.56	6.66	11.54	11.96	12.43	11.13	11.09	9.61	9.22	9.40	9.25	8.98	6.39			
	200	-3.82	-1.97	5.94	9.05	3.76	7.28	9.77	11.91	11.51	11.22	9.75	8.91	7.93	8.76	6.38			
	300	-2.70	-1.64	7.15	7.62	5.71	5.25	3.82	6.28	8.53	9.94	9.92	7.94	7.78	8.18	6.50			
	500	-1.36	-1.14	7.65	5.67	4.16	2.87	2.20	4.43	4.55	4.61	9.55	8.57	8.06	7.37	7.14			
	700	-1.76	0.99	4.69	4.52	4.32	5.21	4.69	4.72	3.56	3.46	3.49	9.85	8.30	7.56	5.90			
	1000	-1.88	-0.02	4.78	3.61	5.87	4.46	4.25	4.08	3.43	2.61	-0.57	7.79	7.90	7.85	5.94			
	1500	-0.08	-0.90	-0.73	2.26	4.49	4.88	4.88	4.08	4.82	2.07	3.10	6.55	7.26	7.15	5.51			

(c)

Average SDRi		Side lobe level used in spatial model optimization [dB]															
SDRI		40	50	60	70	80	90	100	120	150	200	300	500	700	1000	1500	
Side lobe level used in source model optimization [dB]	40	1.32	8.62	5.02	4.58	4.60	4.61	4.68	4.78	4.94	4.80	5.45	5.79	5.75	5.56	5.03	
	50	1.93	10.03	10.07	10.10	10.37	10.25	10.21	10.25	10.00	9.87	9.99	9.81	8.85	9.90	9.42	
	60	2.06	1.77	12.19	10.13	7.60	7.88	8.63	9.02	9.32	10.00	9.59	9.32	10.56	10.63	8.02	
	70	1.78	1.05	13.64	6.33	5.81	5.54	5.09	4.91	3.86	3.40	3.77	6.51	7.46	9.54	7.03	
	80	1.58	-0.17	14.25	8.07	5.86	6.80	5.84	4.50	4.61	3.51	3.55	4.87	5.97	6.48	6.99	
	90	1.35	0.74	9.63	13.17	3.78	5.45	5.57	4.30	3.98	3.30	2.89	4.45	5.01	6.62	6.20	
	100	-1.02	1.38	9.78	8.21	10.59	4.74	4.92	4.55	3.52	3.17	3.00	4.53	4.76	5.95	6.21	
	120	0.31	-0.08	13.65	15.32	12.84	11.30	4.49	3.95	2.59	2.56	2.45	4.25	4.74	5.28	6.26	
	150	-1.96	-0.36	12.88	11.96	6.78	2.90	6.37	3.74	2.44	2.24	2.53	3.29	4.21	4.20	4.51	
	200	-2.20	0.22	12.75	10.26	10.68	12.53	11.68	3.70	2.07	2.04	2.53	3.29	3.60	3.96	4.46	
	300	-0.42	5.74	12.31	11.95	12.35	11.43	11.70	9.83	8.39	3.02	2.53	3.37	3.36	3.56	4.26	
	500	-0.09	4.27	4.15	11.16	3.84	9.17	4.61	5.59	11.12	11.92	1.44	3.40	3.51	3.21	2.67	
700	0.53	6.77	13.89	12.79	11.61	11.72	11.13	10.27	10.59	10.99	7.11	4.00	3.42	3.23	2.51		
1000	1.08	6.96	13.10	12.43	12.41	11.74	11.64	10.31	10.49	10.39	9.78	2.83	3.31	3.39	3.26		
1500	1.65	9.04	12.67	11.61	12.15	12.30	12.05	10.92	8.81	3.20	5.46	2.54	2.01	3.46	3.37		