



NTT Communication Science Laboratories

音学シンポジウム 2013年5月12日

音声生成過程と信号観測過程のモデルに 基づくマルチチャンネル音声強調

中谷智広

NTTコミュニケーション科学基礎研究所

Contributed by NTT CS研 信号処理研究グループのメンバ

伊藤信貴, 吉岡拓也, 木下慶介, 荒木章子, 藤本雅清, エスピミケル,
デルクロア マーク, 久保陽太郎, 小川厚徳, 堀貴明, 中村篤



目次

- **研究のモチベーション**
 - 実世界で目的音声を聞き分け理解する技術: 音声強調+音声認識

- **目的音声を聞き分ける技術(=音声強調)**
 - 『生成モデル』の考え方に基づく音声強調
 - 代表的な音声強調手法

- **音声強調+音声認識の応用例**
 - 生活雑音環境下における遠隔発話音声認識
 - 複数人会話の音声認識

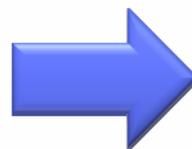
音声インタフェース —現状と未来—

■ 現状

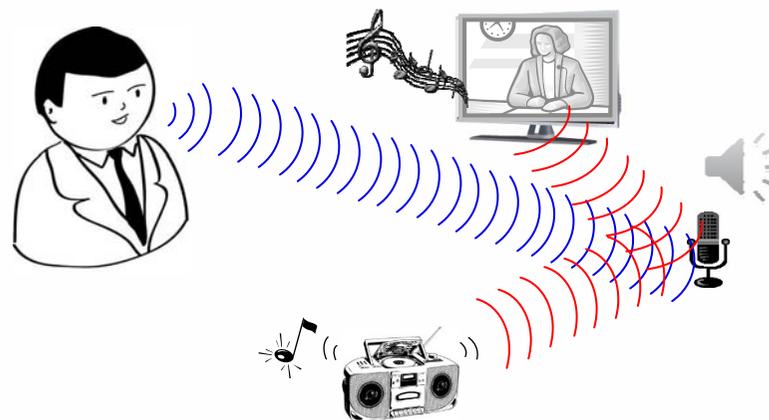


例: ボイスサーチ,
しゃべってコンシェル

- マイクの近くで話す
- 雑音が少ない



■ 未来



どんな場所でも、話している内容を
理解できる

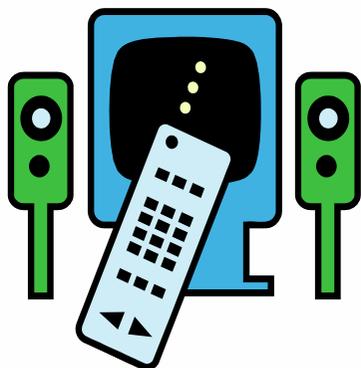
- マイクから離れてもOK
- 目的音声以外に
音があってもOK

研究のモチベーション

様々な音が聞こえる実世界で、
人の声を聞き分け・理解する
コンピュータの実現

- 人どうしなら不自由なく会話できる環境での
音声の認識（利用環境を選ばない技術）
- **音声を聞き分ける能力（音声強調）**
＋ロボスト音声認識／話し言葉認識

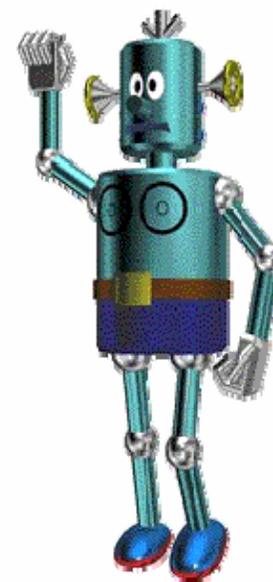
音声を聞き分け理解する技術の応用先



家電・住宅機器の操作



会議録の自動作成



共生型ロボット

字幕の自動付与



つまり音声認識とは…



インタラクティブ・エージェント

音声(言語)は人間にとって最も基本的な情報伝達手段

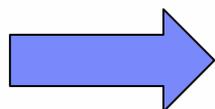
本日のトーク:二つの研究シナリオ

■ 生活雑音環境下での遠隔コマンド音声認識

- 人がコンピュータに話す音声の認識
- 応用例:カーナビ, 家電・ゲーム機の操作...

観測信号 

音声強調結果 



人間に比肩する音声認識性能

■ 複数人会話の音声認識

- 人と人の会話, 誰がいつ何を話したのかを認識
- 応用例:議事録・要約, オンライン会話支援...

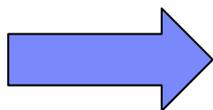
複数人会話の音声認識 (複数人・遠隔・自由会話音声認識)



観測信号



音声強調
結果



テーブルマイクを用いてヘッドセット並の音声認識性能

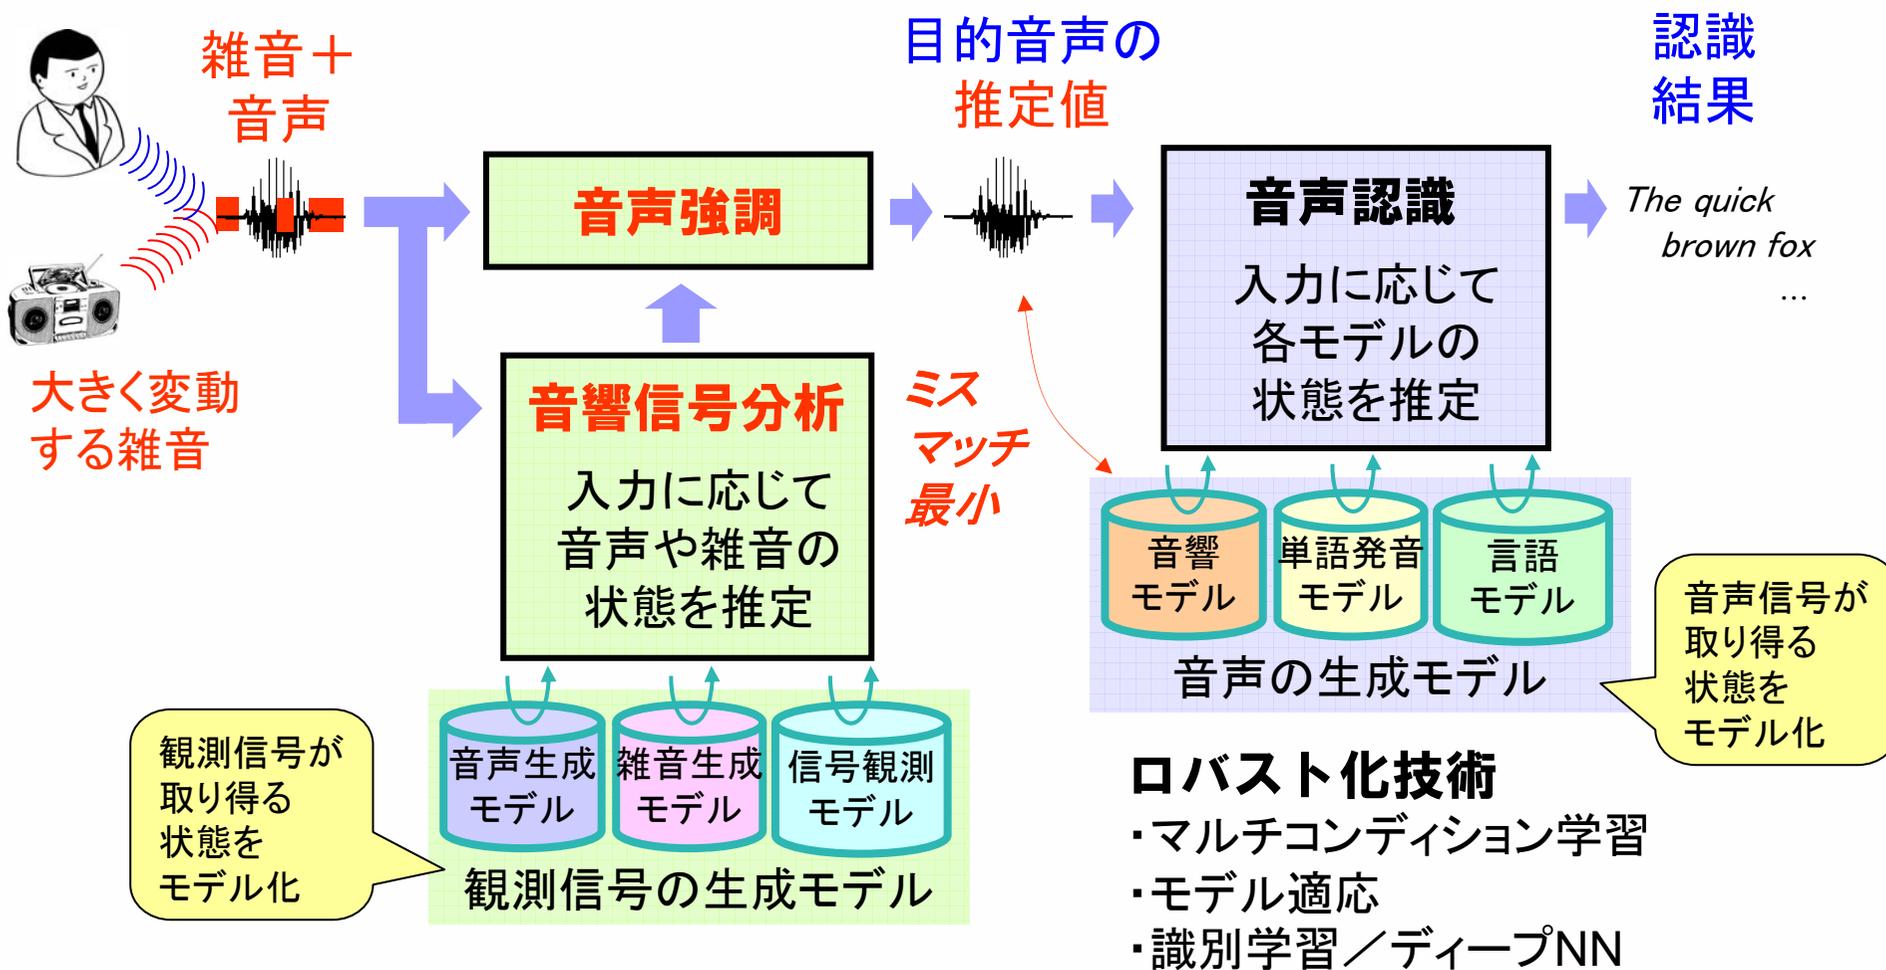
目次

- 研究のモチベーション
 - 実世界で目的音声を聞き分け理解する技術: 音声強調+音声認識

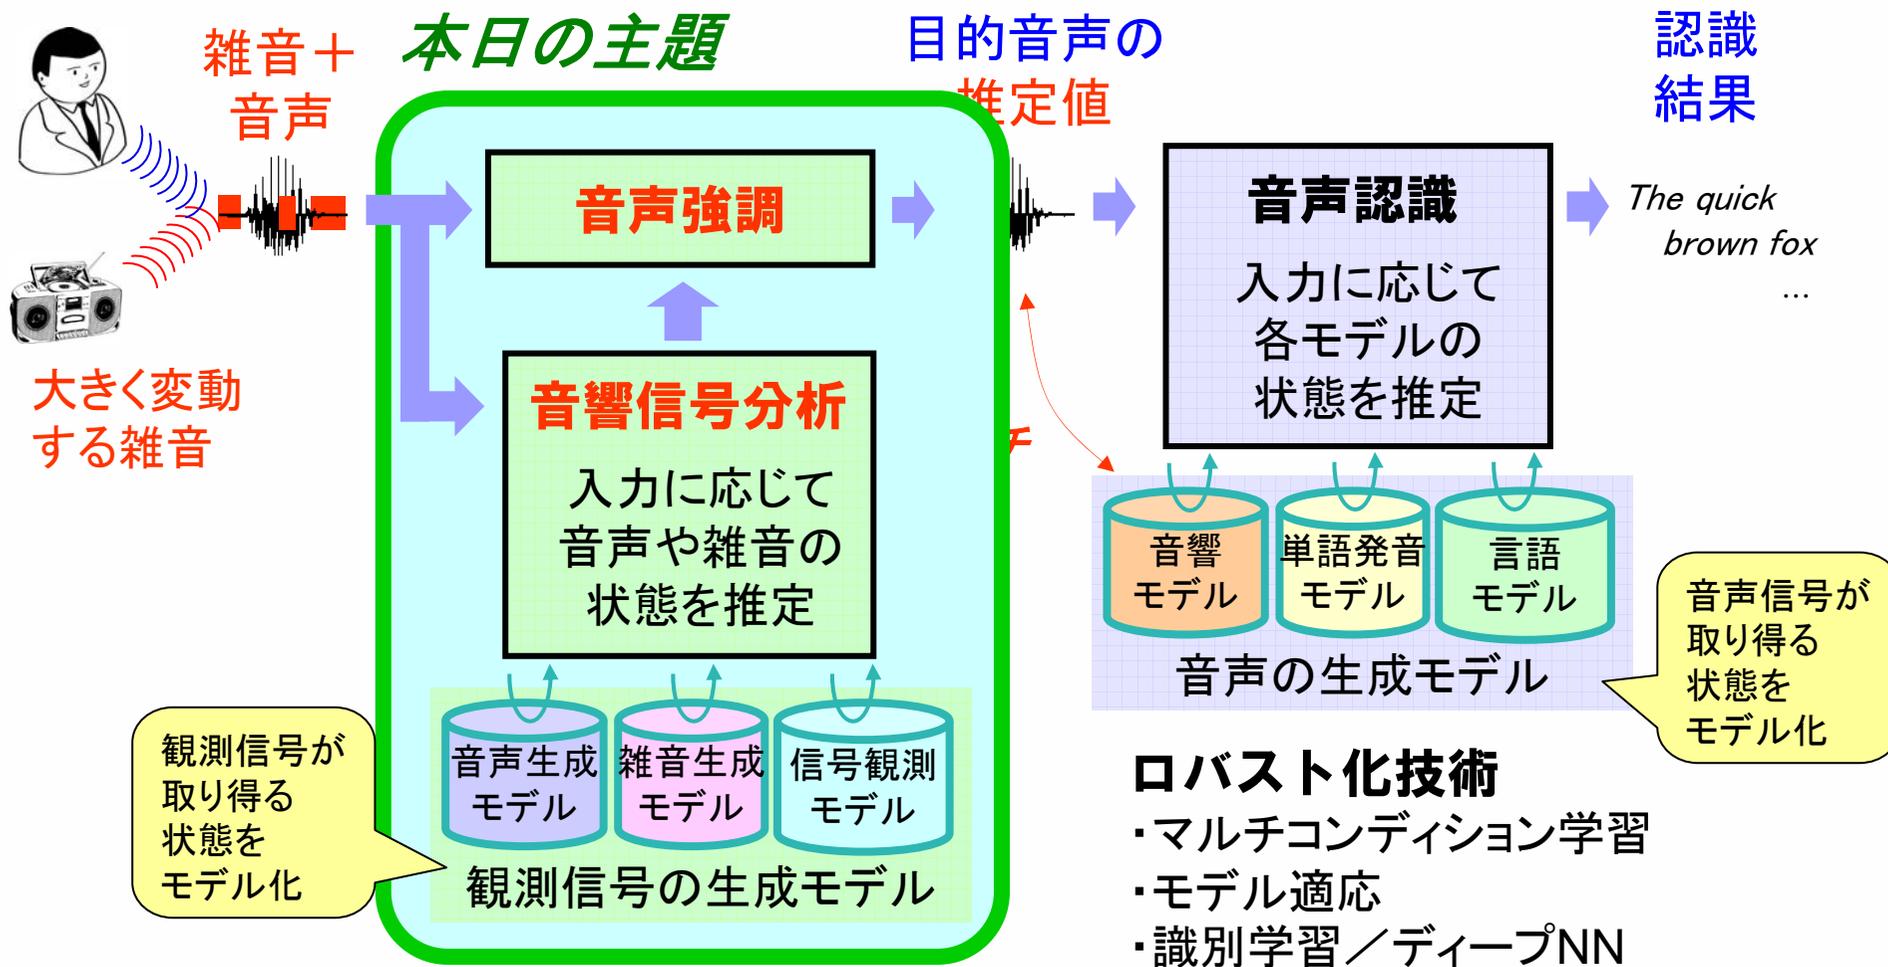
- 目的音声を聞き分ける技術(=音声強調)
 - 『生成モデル』の考え方に基づく音声強調
 - 代表的な音声強調手法

- 音声強調+音声認識の応用例
 - 生活雑音環境下における遠隔発話音声認識
 - 複数人会話の音声認識

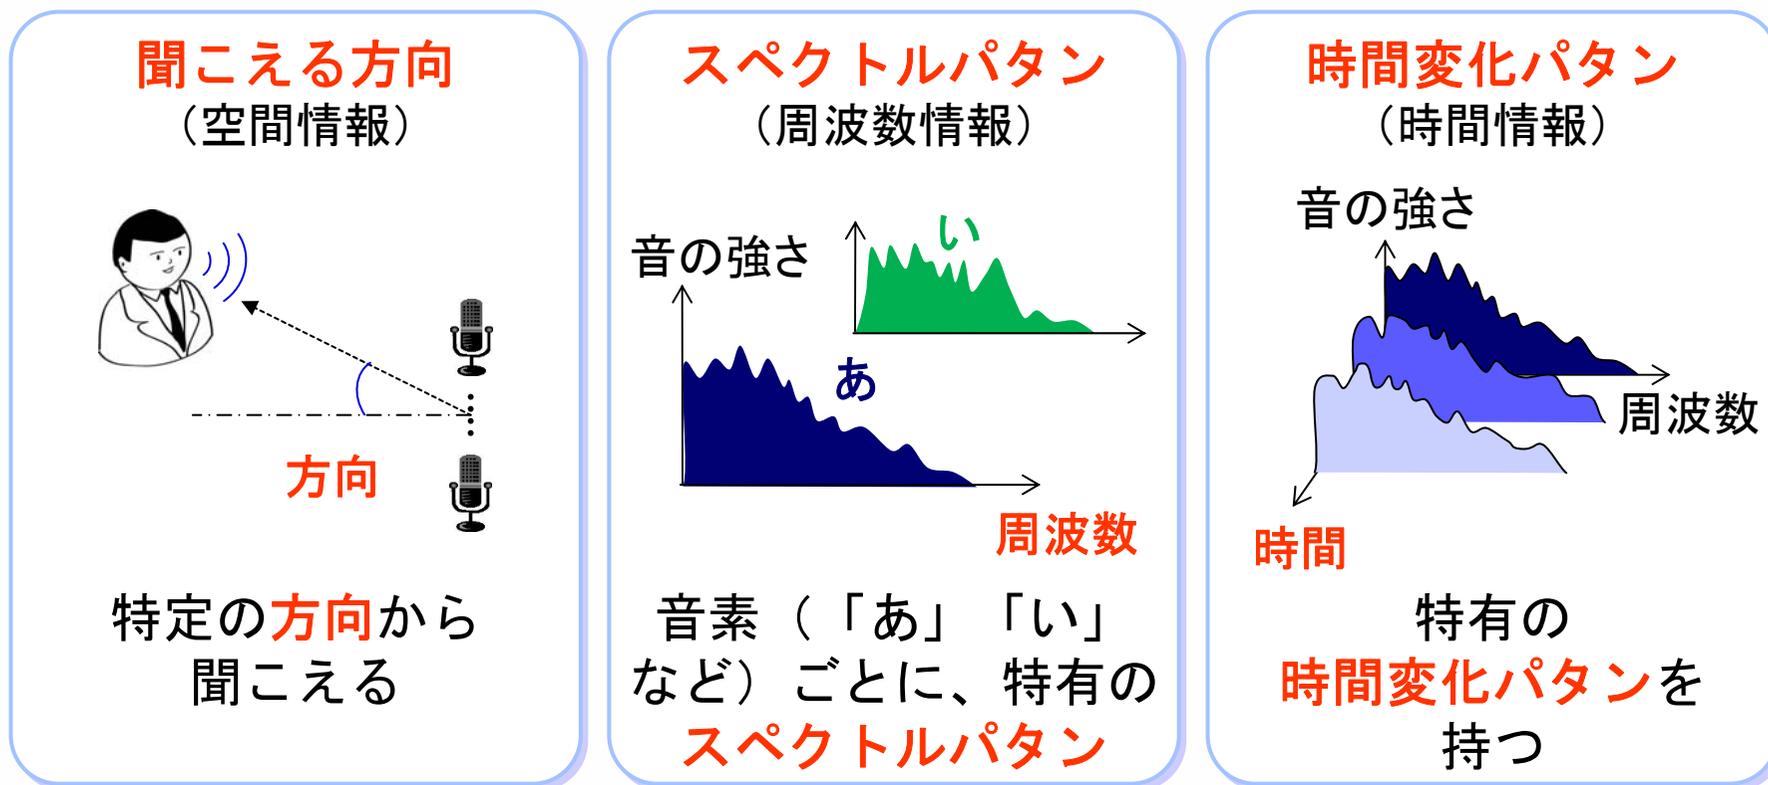
生成モデルの考え方に基づく音声強調＋音声認識



生成モデルの考え方に基づく音声強調＋音声認識



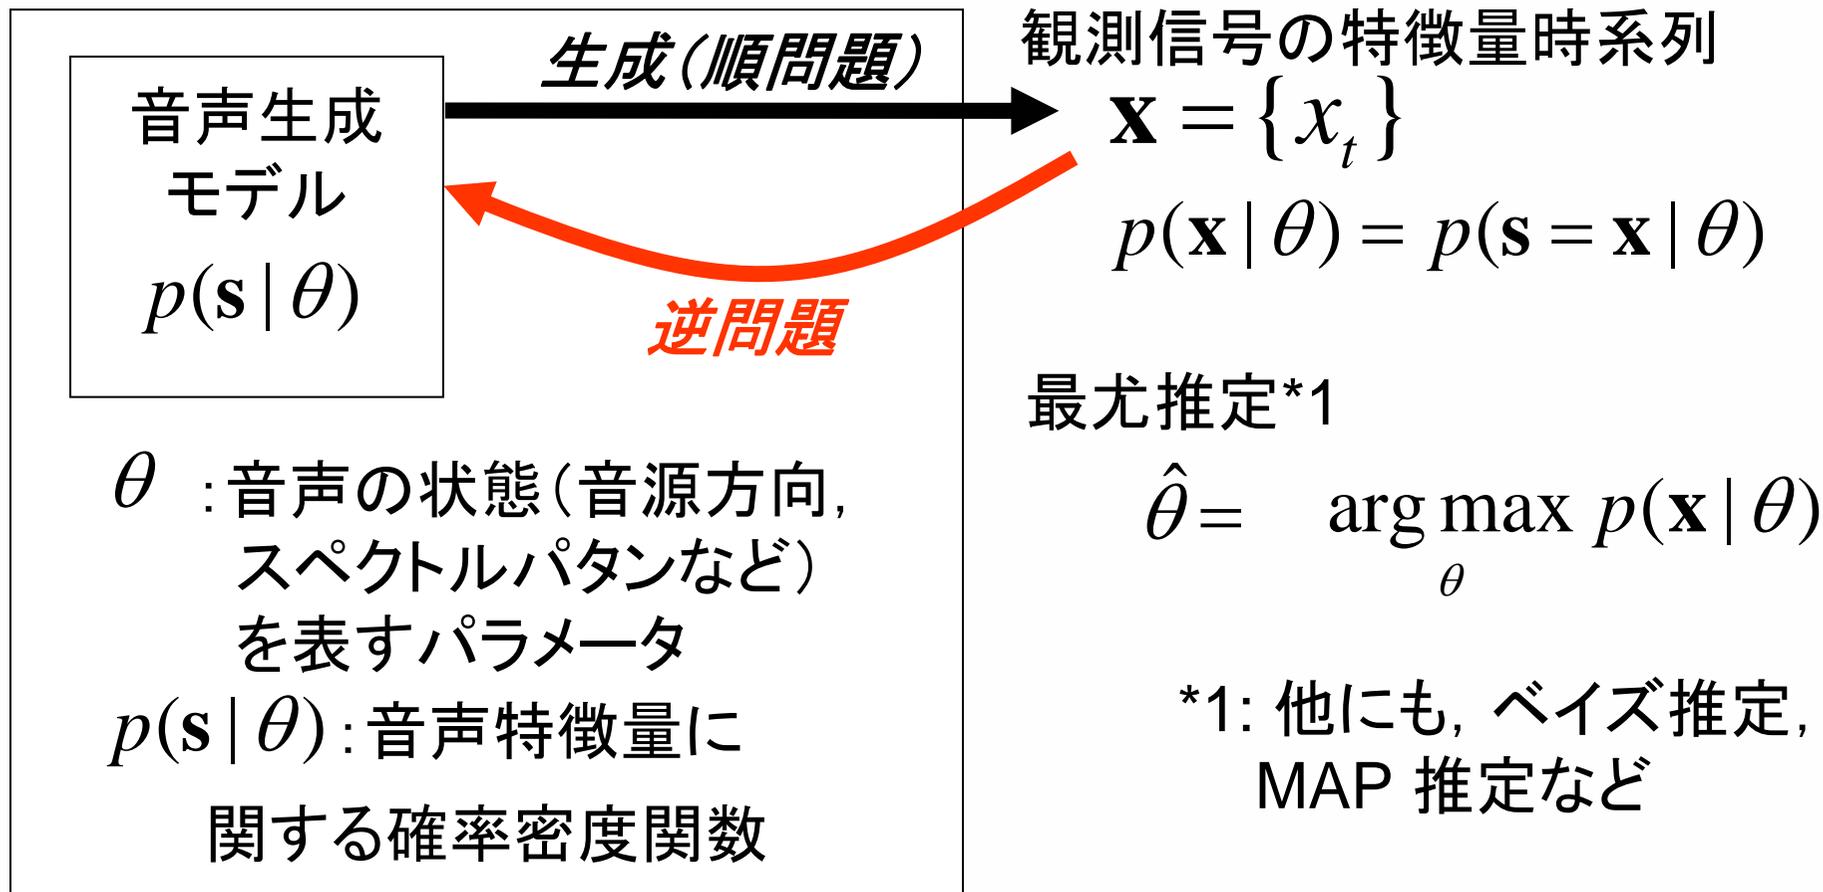
生成モデルで表現する音声・雑音の状態の例



その他: 音声区間 [藤本, 2008], 調波構造 [亀岡, 2007], F0パターン [亀岡, 2010], 発話内容 [Rennie, 2010] など

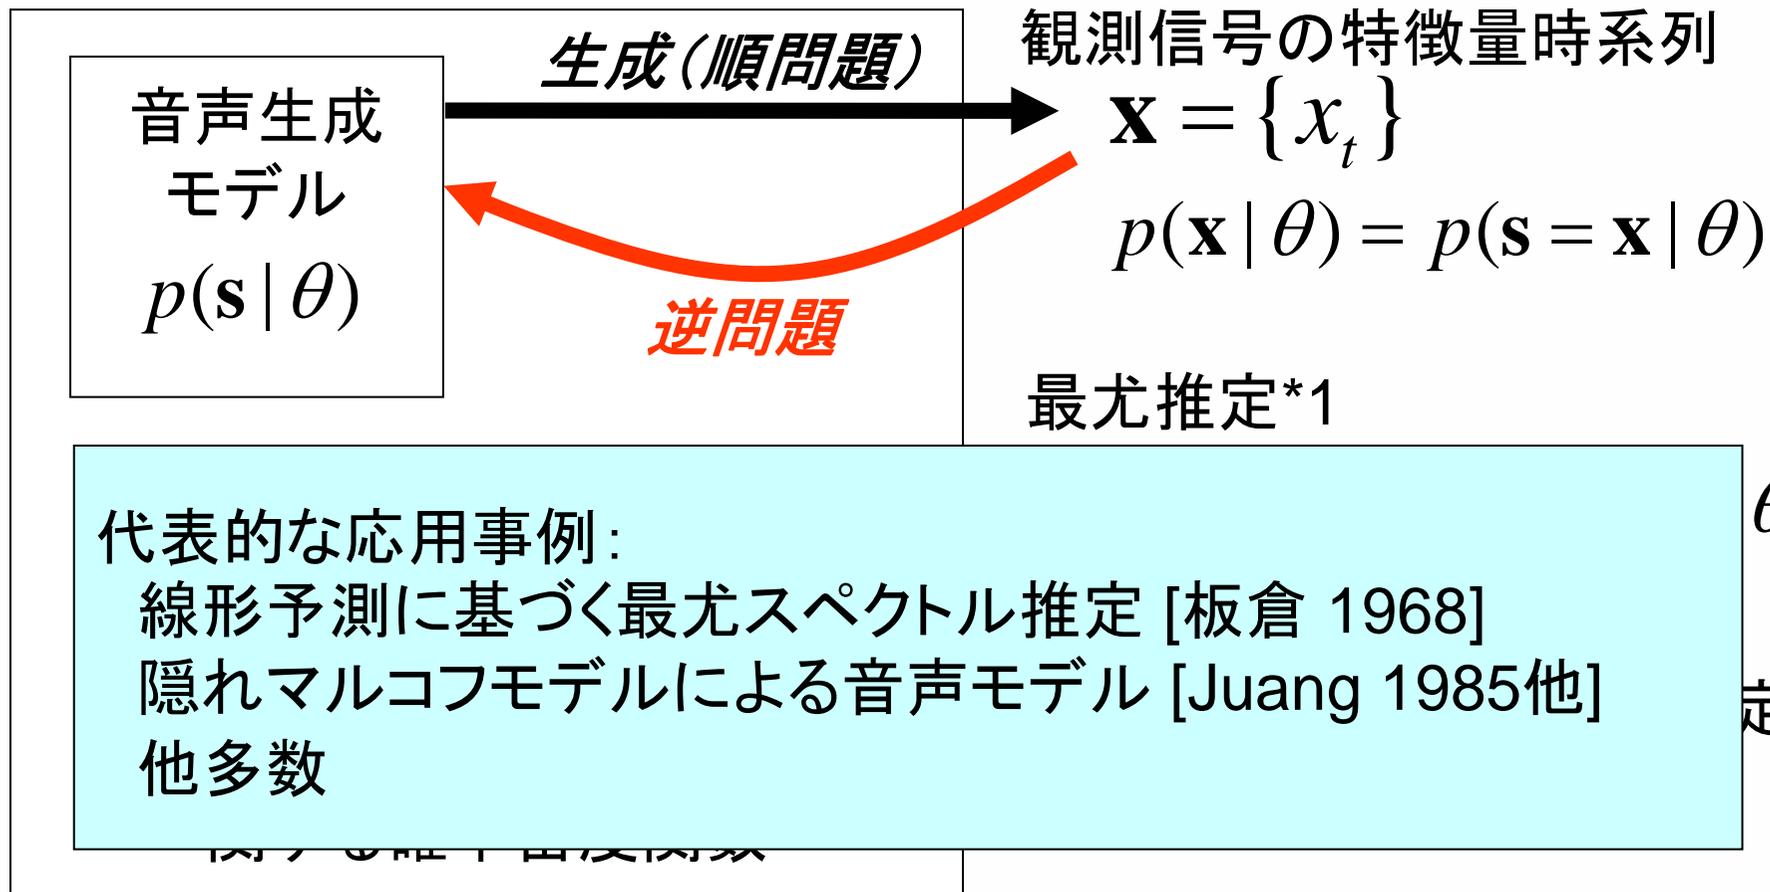
生成モデルに基づく音響信号分析の考え方 (1/2)

分析すべき音シーン : 単一音源(雑音なし)の場合



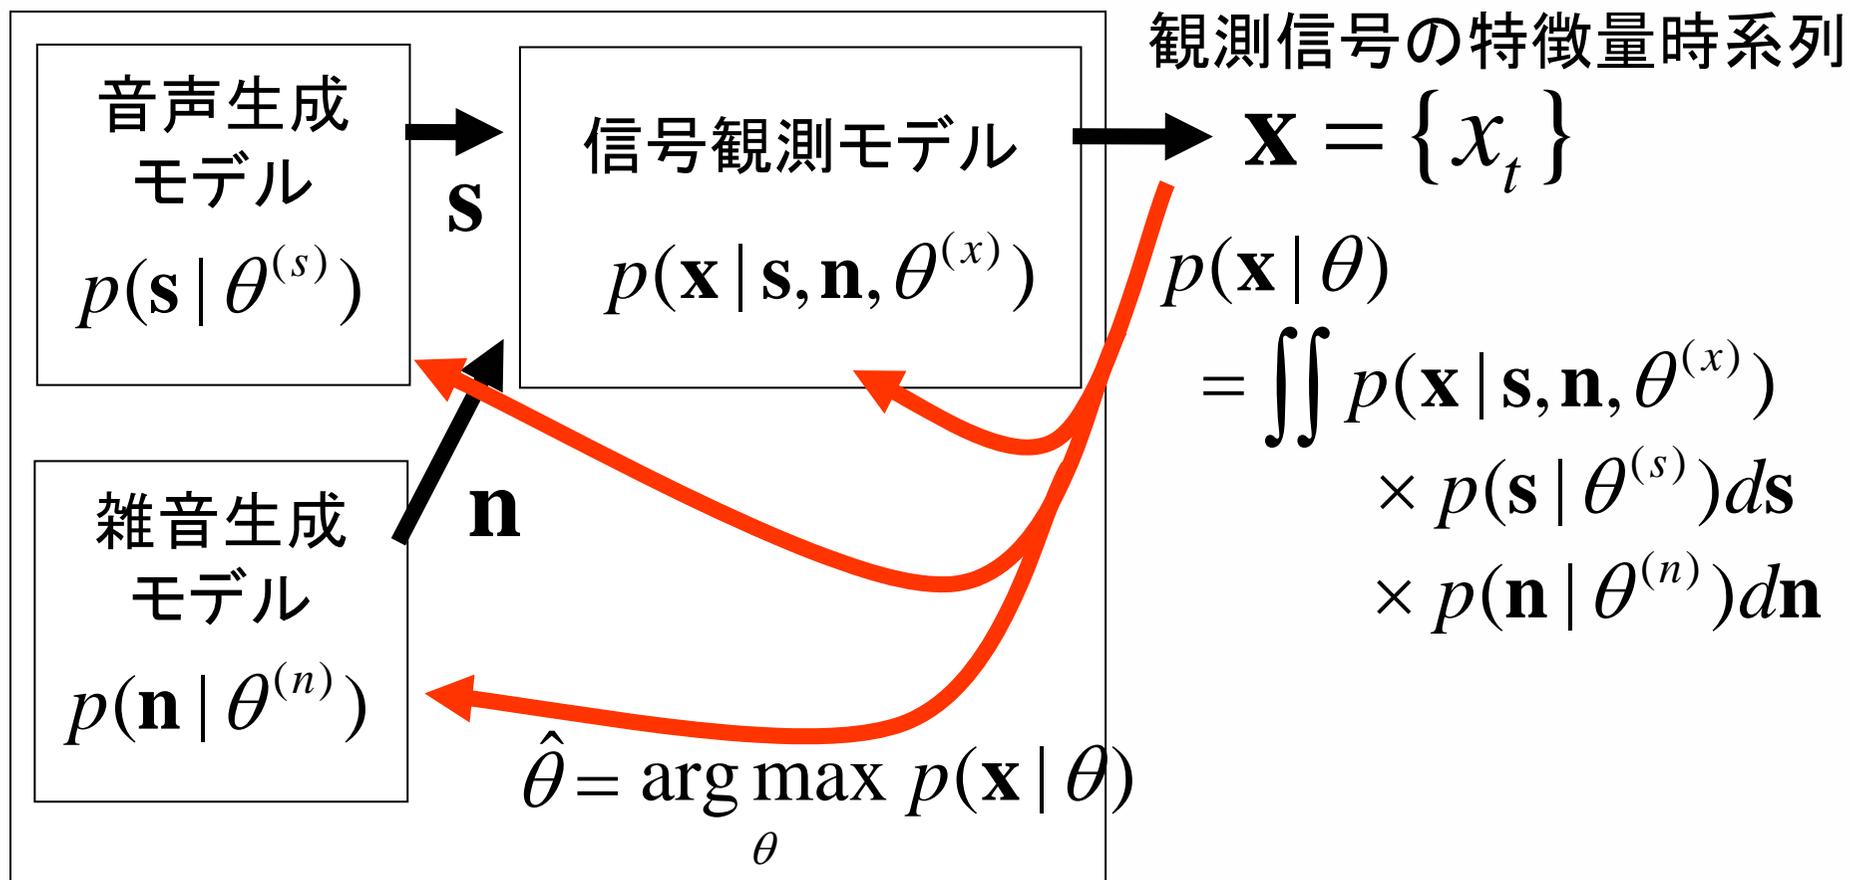
生成モデルに基づく音響信号分析の考え方 (1/2)

分析すべき音シーン : 単一音源(雑音なし)の場合



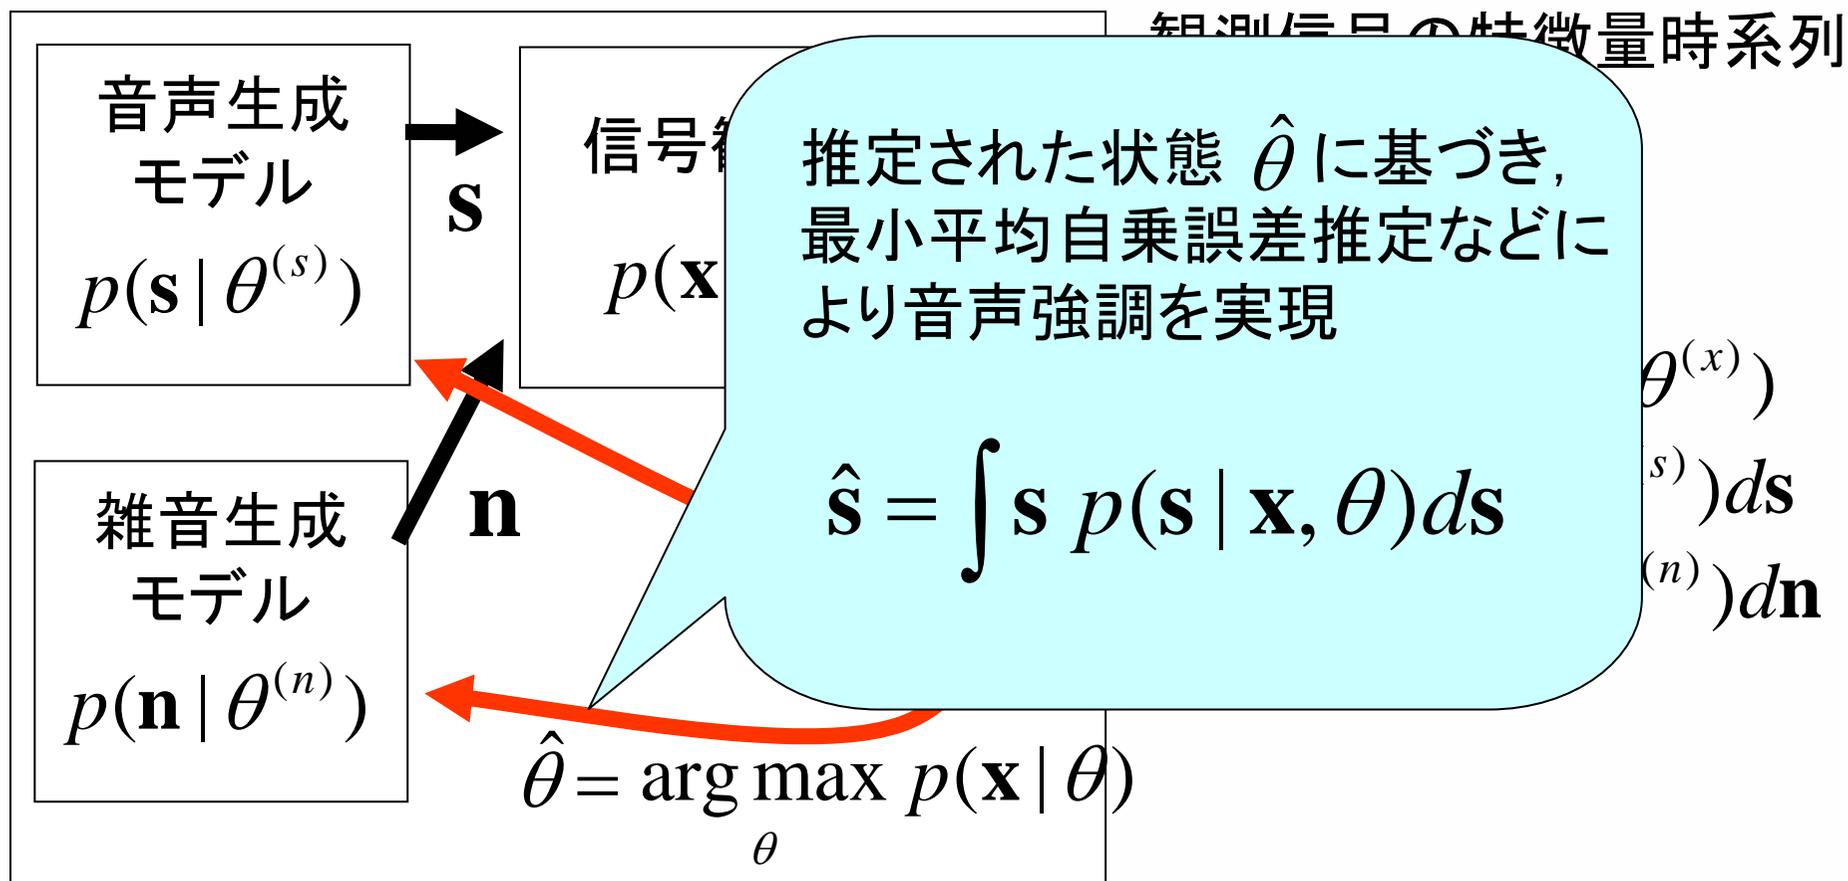
生成モデルに基づく音響信号分析の考え方 (2/2)

分析すべき音シーン : 複数音源の場合



生成モデルに基づく音響信号分析の考え方 (2/2)

分析すべき音シーン : 複数音源の場合



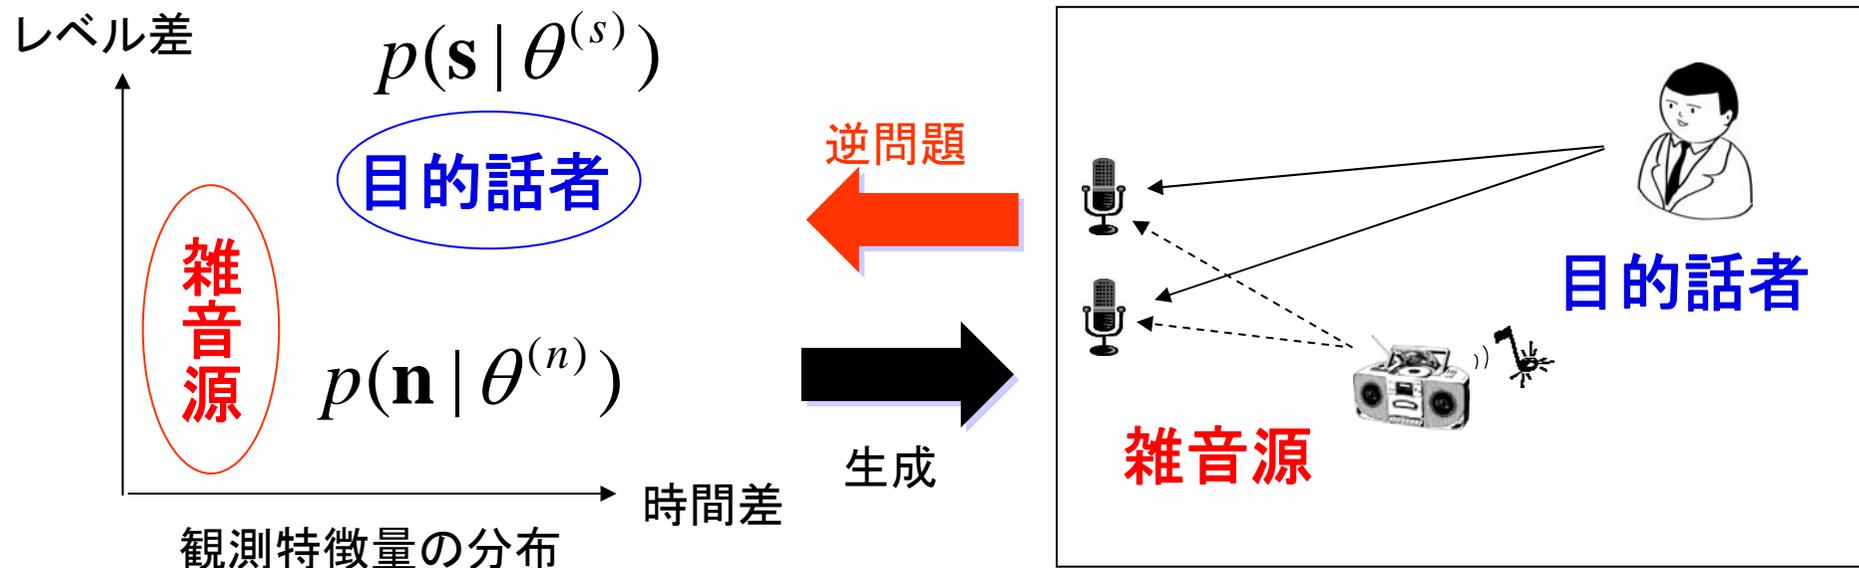
生成モデルによる音響信号分析：特徴・課題

- 音源の状態から観測信号を予測する観測信号生成モデルの構築は、比較的容易（**順問題**）
 - **様々な手がかり**を導入できる
- 音響信号分析は、観測信号生成モデルのパラメータ推定問題として定式化できる（**逆問題**）
 - ただし、多くの場合、非線形最適化問題となり、**効率的に解けるとは限らない**

生成モデルに基づく代表的な音声強調の手法

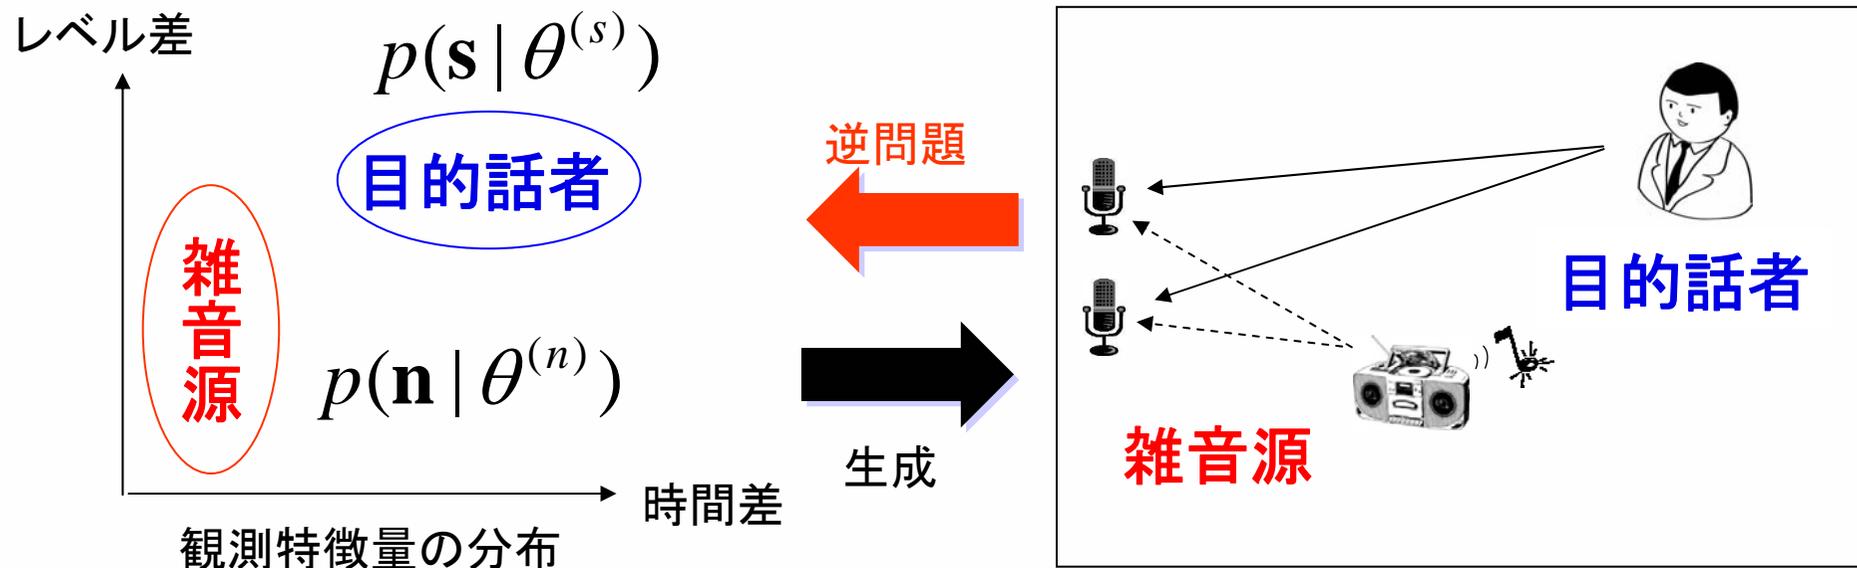
手がかり	音源の方向	スペクトルパタン	時間変化パタン
代表的な手法	<ul style="list-style-type: none"> ・独立成分分析 (ICA) ・音源方向クラスタリング 	<ul style="list-style-type: none"> ・非負値行列分解 (NMF) ・Factorial モデル 	<ul style="list-style-type: none"> ・隠れマルコフモデル (HMM) ベース ・事例ベース
特長	生成モデルの事前学習が不用 → ブラインド処理が可能	生成モデルの事前学習が必要 → 音声・雑音のパタンの分布をあらかじめ制限できる	

音源方向クラスタリングに基づく音声強調 [Yilmaz, 2004]



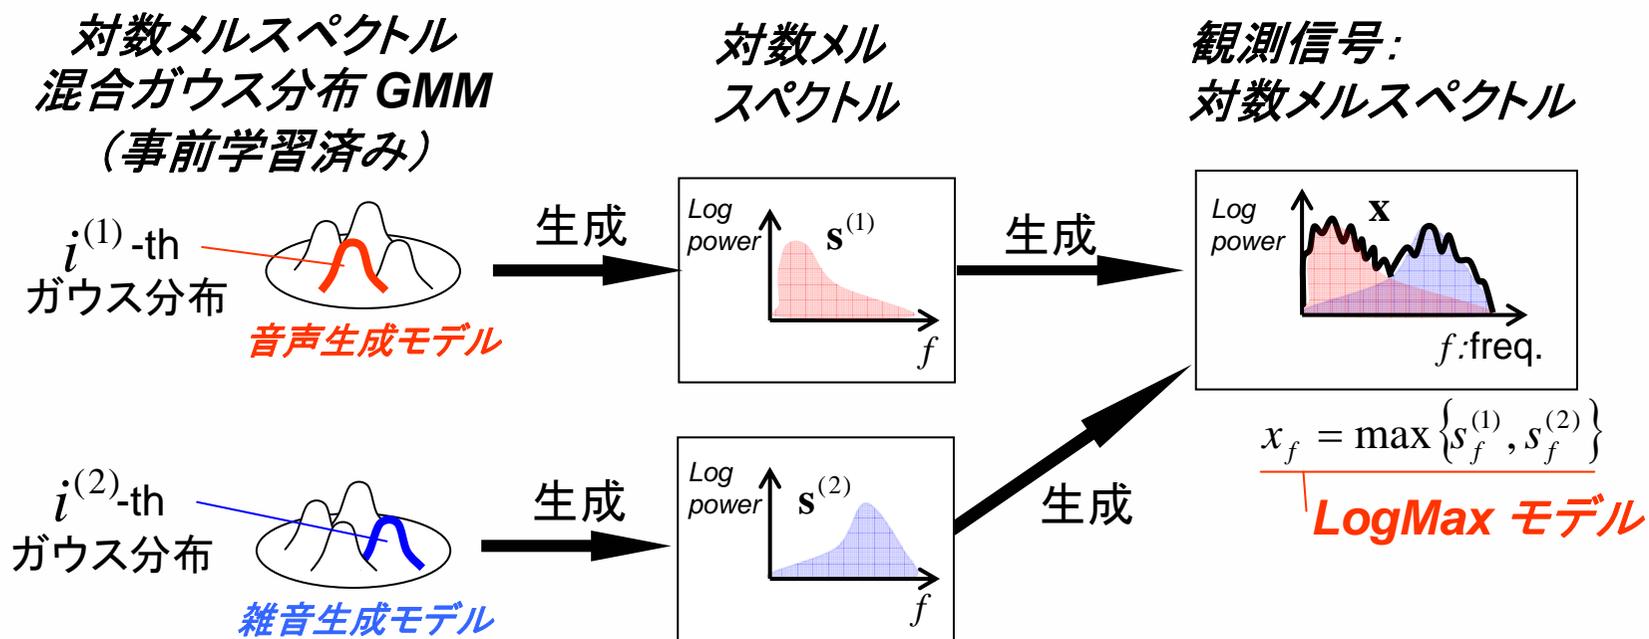
事前に音源方向等が不明でも、観測信号のみから生成モデルを推定できる(ブラインド推定可能)

音源方向クラスタリングに基づく音声強調 [Yilmaz, 2004]



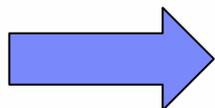
音源分離技術評価キャンペーンSiSEC 等において、
世界トップレベルの性能(信号対歪み比 SDR 等)
を達成 ([澤田 2012] 他)

Factorial モデルに基づく音声強調 [Roweis 2003]



音響信号分析(逆問題) $\mathbf{i} = \arg \max_{\mathbf{i}} p(\mathbf{x}, \mathbf{i})$

観測信号を生成する確率値の高いガウス分布の組 $\mathbf{i} = \{i^{(1)}, i^{(2)}\}$ を推定

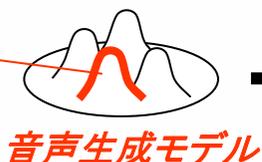


EMアルゴリズムにより効率的な推定が可能

Factorial モデルに基づく音声強調 [Roweis 2003]

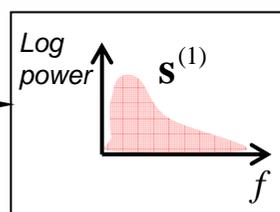
対数メルスペクトル
混合ガウス分布 GMM
(事前学習済み)

$i^{(1)}$ -th
ガウス分布



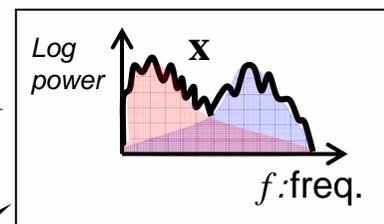
生成

対数メル
スペクトル



生成

観測信号:
対数メルスペクトル



$$x_c = \max \{s_c^{(1)}, s_c^{(2)}\}$$

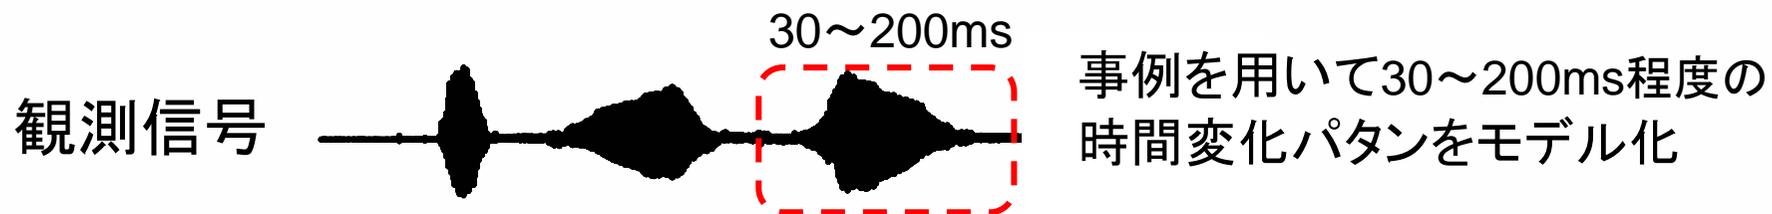
モノラル混合音声の分離・音声認識評価キャンペーン
[Cooke 2010]においてトップスコアを達成 [Rennie 2010]

観測信号を生成する確率値の高いガウス分布の組 $\mathbf{i} = \{i^{(1)}, i^{(2)}\}$ を推定



EMアルゴリズムにより効率的な推定が可能

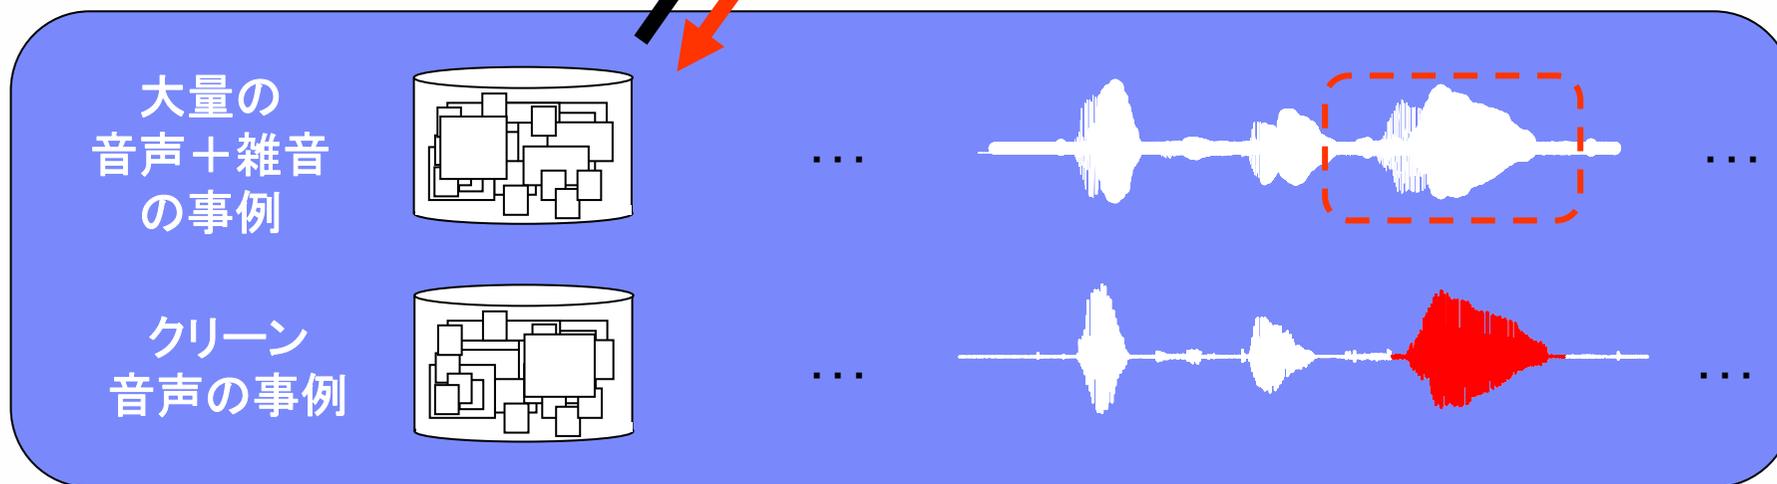
事例ベース音声強調 [Ming, 2011, Kinoshita, 2011]



事例ベース
生成モデル

生成

逆問題: 最長・最類似事例探索

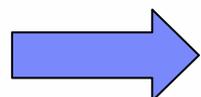


クリーン事例に基づきウィナフィルタを設計し音声強調を実現

生成モデルに基づく音声強調法のまとめ

- 音源の方向, スペクトルパタン, 時間変化パタンなどに基づき, 様々な効果的な方法が提案されている

	音源方向クラスタリング	Factorial モデル／事例ベース
長所	<ul style="list-style-type: none"> ・ブラインド処理が可能 →ボトムアップ的処理に有利 	<ul style="list-style-type: none"> ・スペクトルパタン, 時間変化パタンの分布をあらかじめ規定できる →音声認識との相性○
短所	<ul style="list-style-type: none"> ・同じ方向の音を区別できない ・音声認識との相性？ 	<ul style="list-style-type: none"> ・雑音と音声のパタンが近いと区別が困難 ・事前学習→収録環境への依存性大



各生成モデルの長所を活かすことで, より信頼性の高い音声強調が実現できる期待

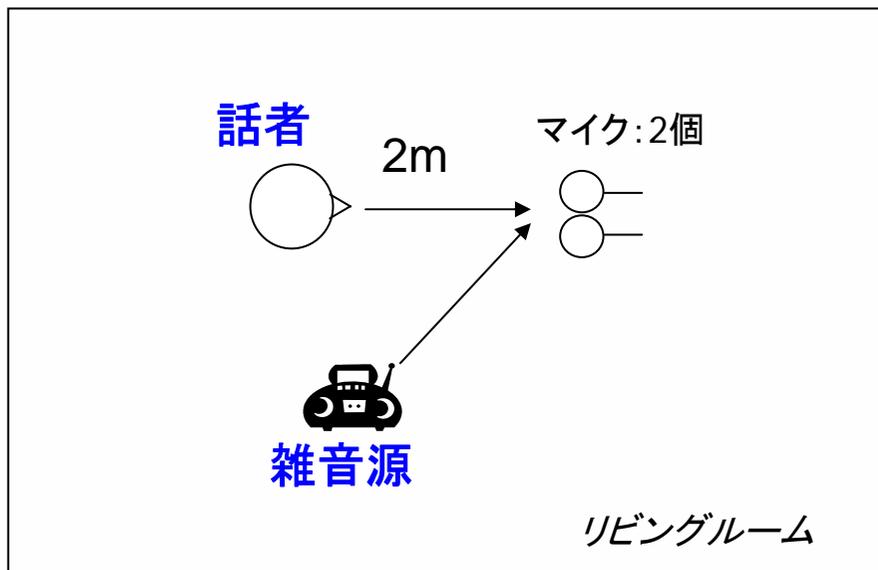
目次

- **研究のモチベーション**
 - 実世界で目的音声を聞き分け理解する技術: 音声強調+音声認識

- **目的音声を聞き分ける技術(=音声強調)**
 - 『生成モデル』の考え方に基づく音声強調
 - 代表的な音声強調手法

- **音声強調+音声認識の応用例**
 - 生活雑音環境下における遠隔発話音声認識
 - 複数人会話の音声認識

生活雑音環境下での遠隔発話音声認識 CHiME タスク



- コマンド文※の音声認識
 - 生活環境で録音された雑音を含む
 - 特定話者音声認識
 - オフライン処理
- マルチマイク(2マイク)録音
 - 話者位置は固定
 - 事前学習データ有(音声・雑音)

※ コマンド文の例(赤字で示した部分のみの認識率を評価)

<コマンド 4通り><色 4通り><前置詞 4通り><アルファベット 25通り><数字 10通り><副詞 4通り>

例: “Bin red by F 8 please”
 “Lay green with G 4 again”
 ⋮

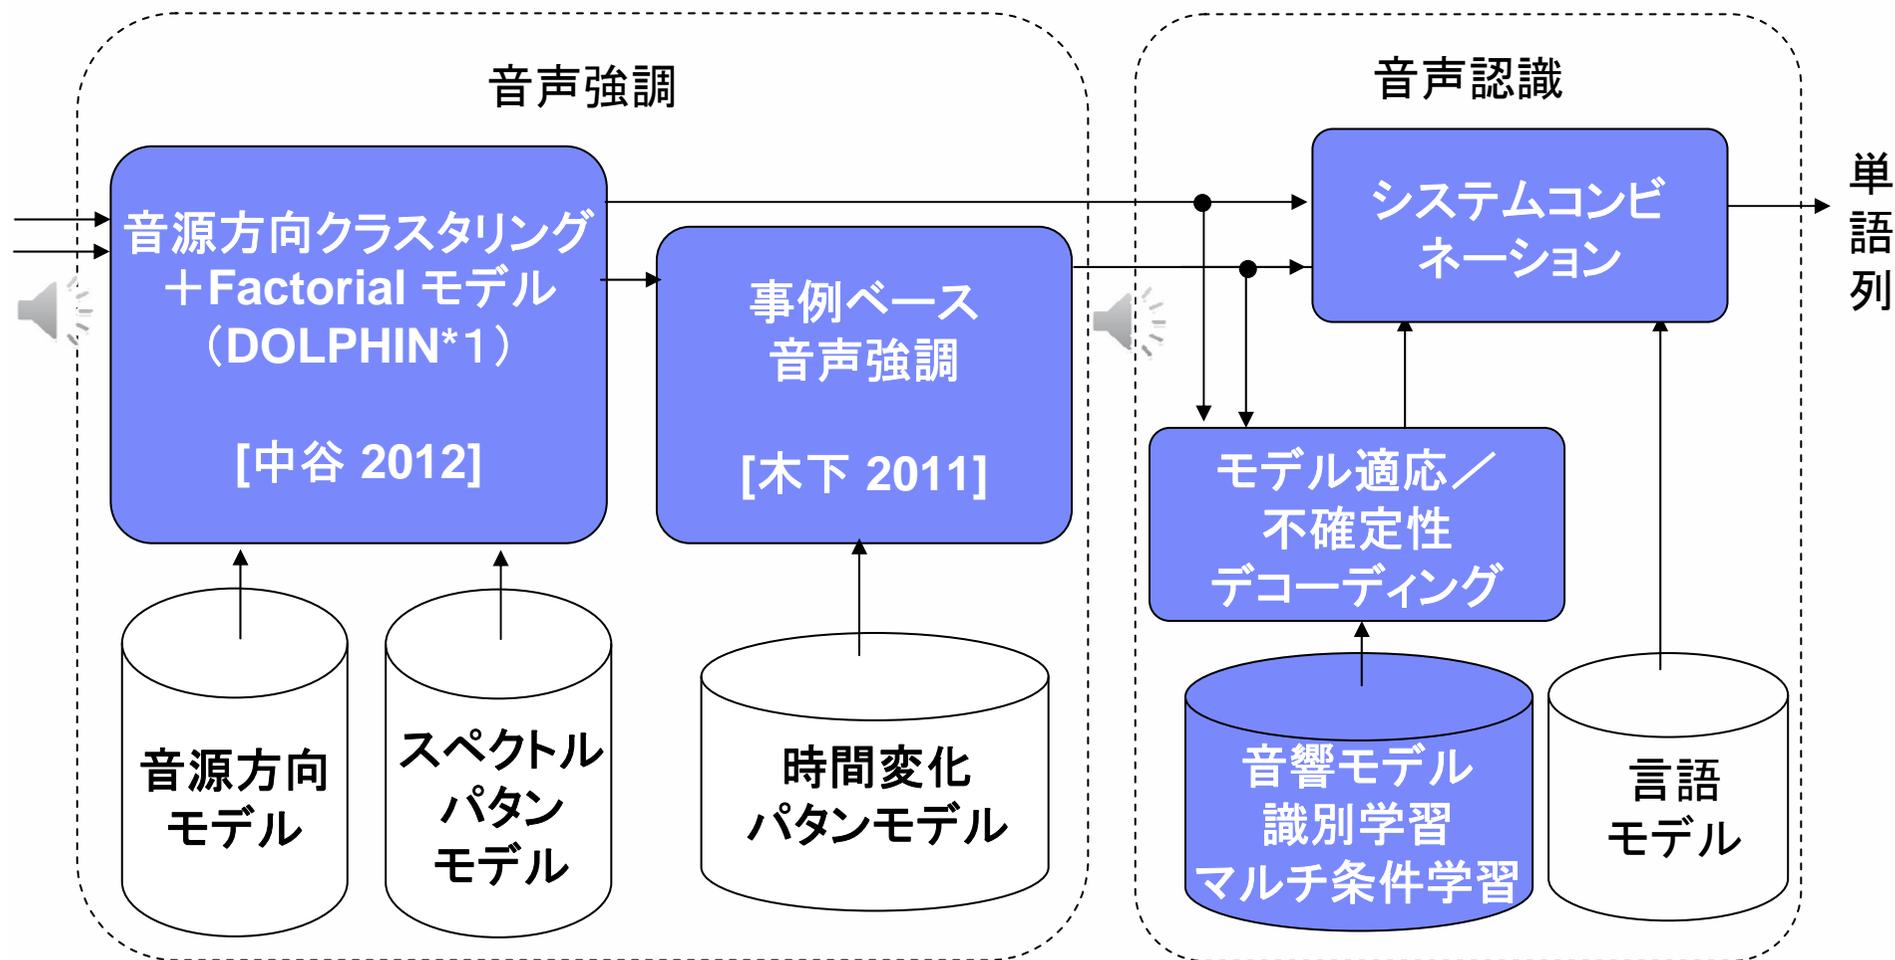


クリーン



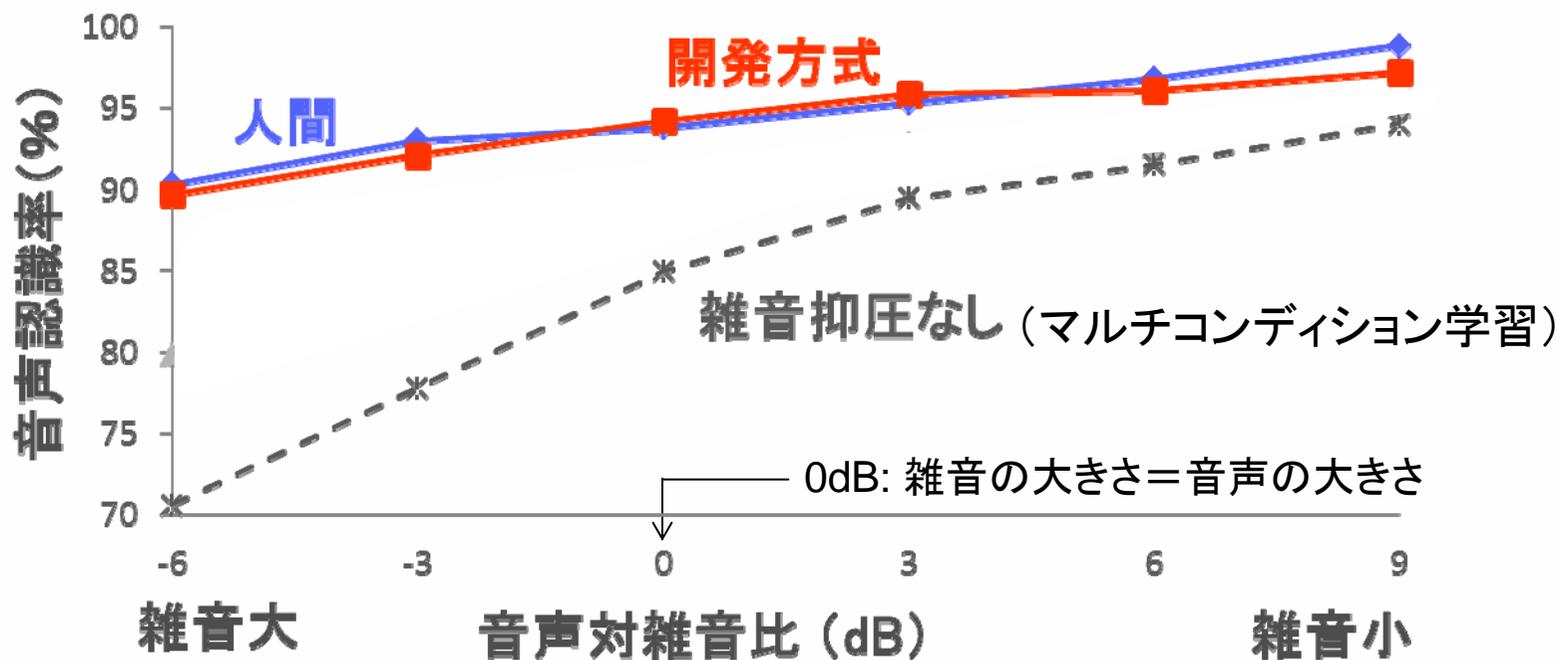
観測信号(含雑音)

NTT開発方式の構成



*1) *DO*minance based *LO*cational and *PO*wer-spectral *CH*aracteristics *IN*tegration

キーワード認識正解率



人間に比肩する性能を達成(現時点で世界トップ性能)

複数人会話の音声認識 (複数人・遠隔・自由会話音声認識)



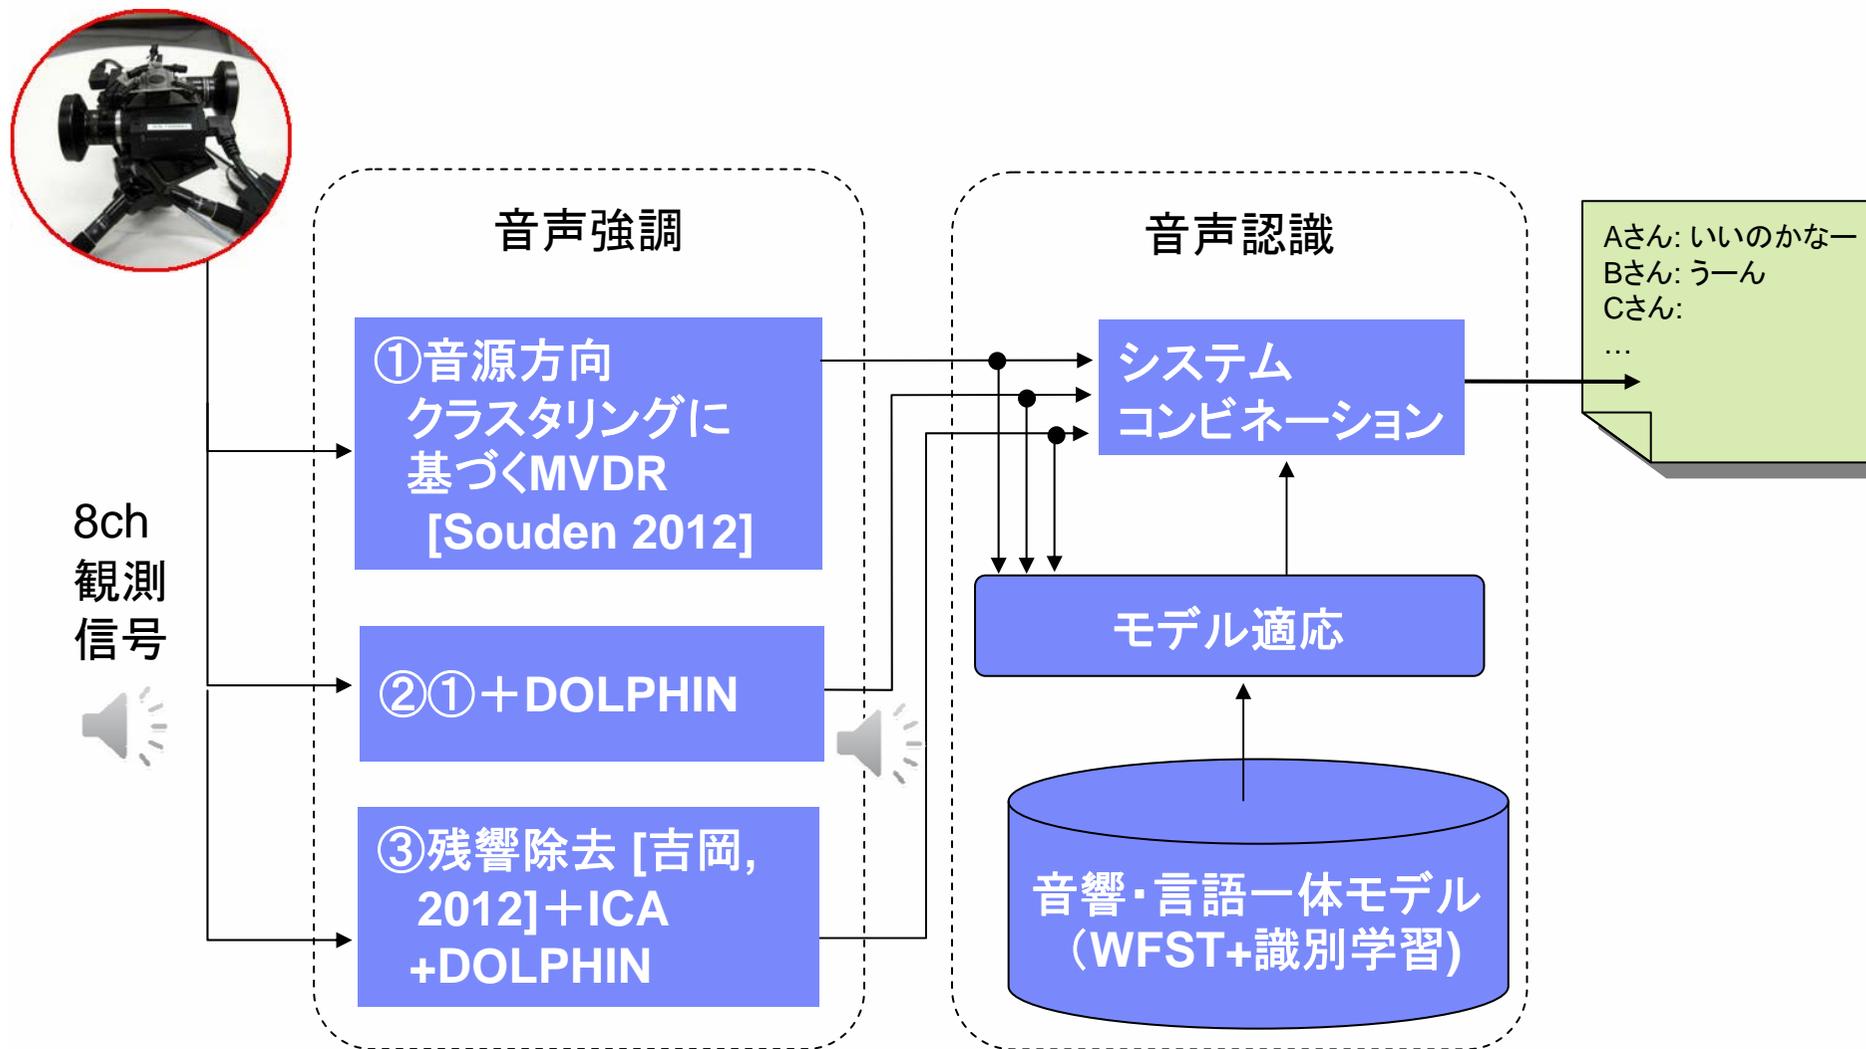
■ 会話音声認識

- 比較的フォーマルな自由会話
例:「仕事でのストレスについて」
- オフィスルーム／防音室
- 不特定話者音声認識
- オフライン処理

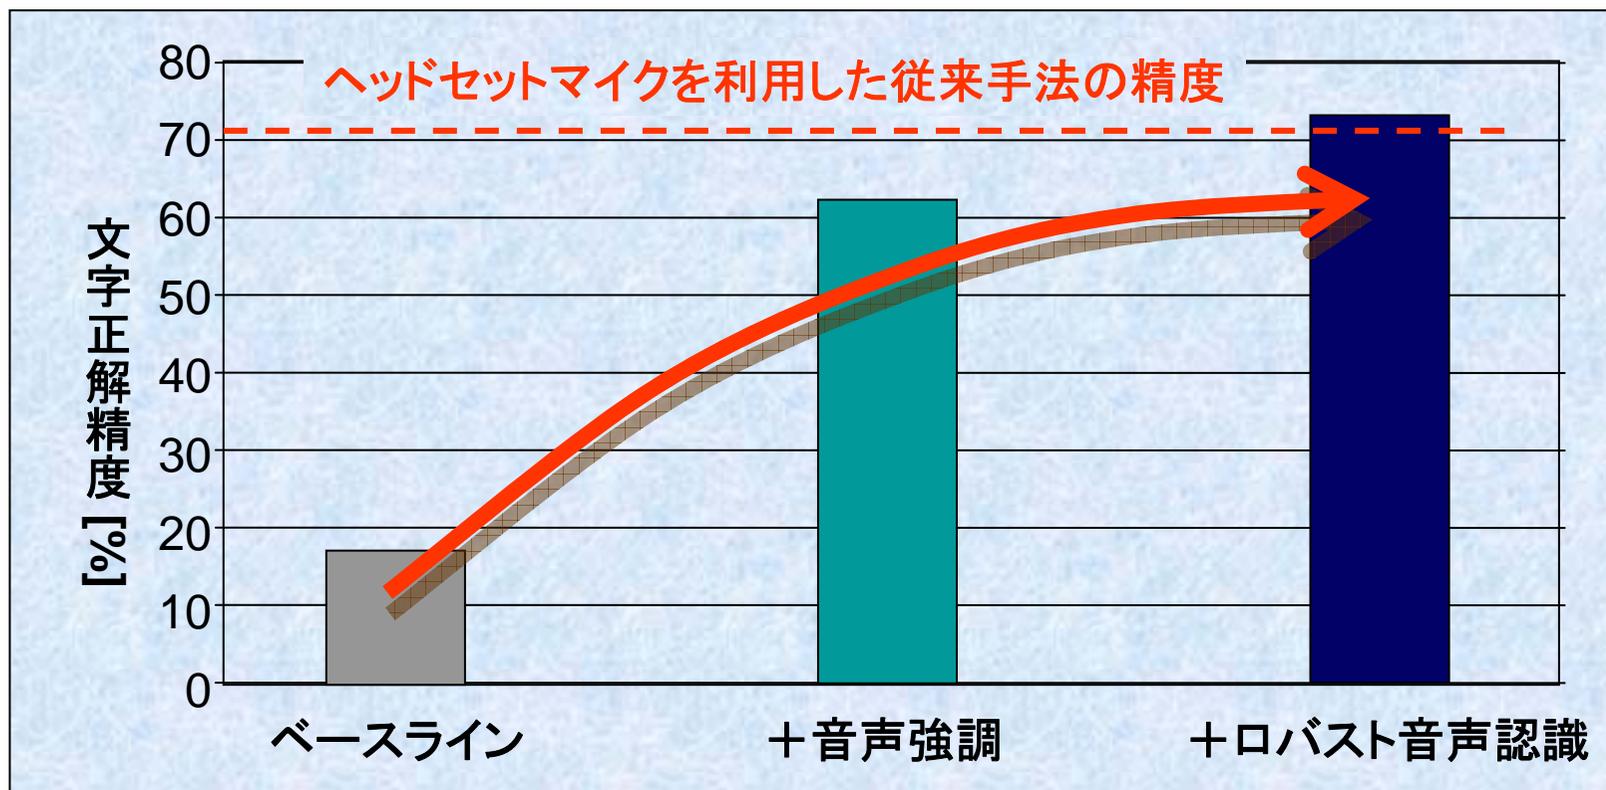
■ マルチマイク(8マイク)録音

- 話者数は4(固定)
- テーブル周囲に着席
(方向は不明)

NTT開発方式の構成



音声認識性能



ヘッドセットマイクを利用した従来手法を凌ぐ認識精度

まとめ

- 生成モデルに基づき、観測信号中の各構成音の状態を推定し、目的音声を強調するアプローチを紹介
- 音源方向・スペクトルパターン・時間変化パターンに基づく音声強調＋最先端音声認識技術により、実世界音声認識に応用
- 今後の課題
 - 大量の収録データからの教師なし学習
 - モデル構造(音源数・音源の種類など)の自動獲得