

2008年5月30日

NTT CS研 未来想論2008

13:00~14:30 at 大会議室

1F 2A会場で展示中

実世界コミュニケーションシーンを 理解する音声映像技術

～会話の流れを分析する

音声技術と映像技術の調和～

日本電信電話株式会社
NTTコミュニケーション科学基礎研究所
メディア情報研究部
大塚和弘

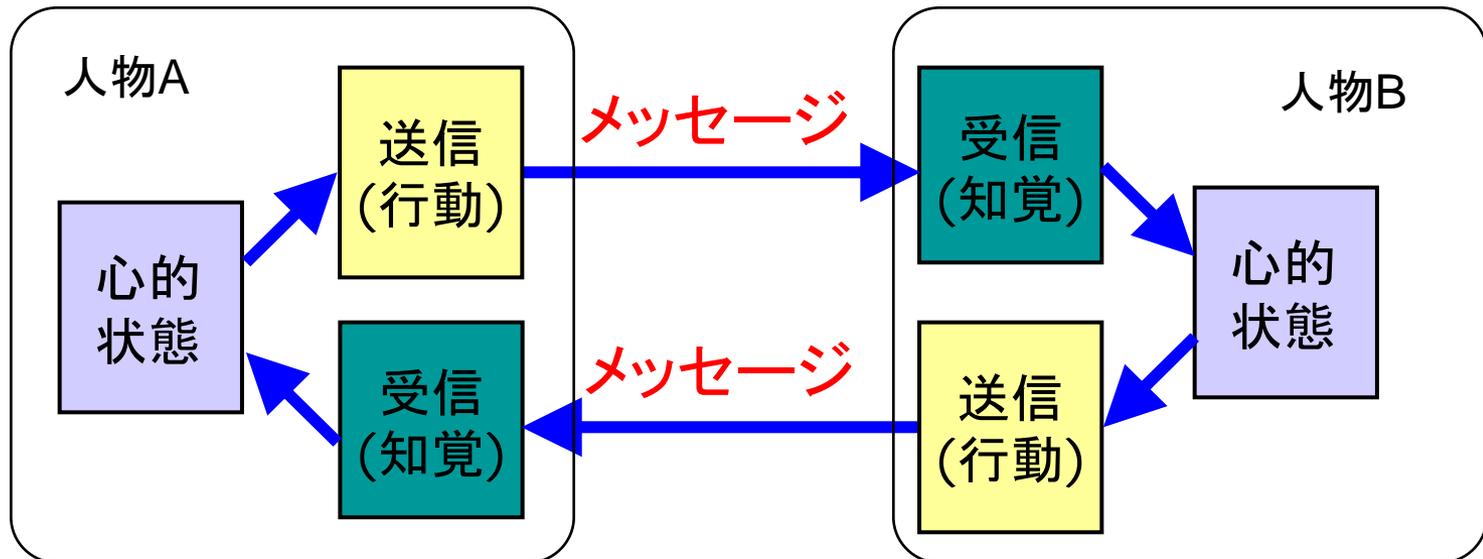
コミュニケーションの情報科学

そもそもコミュニケーションとは？

コミュニケーションの定義

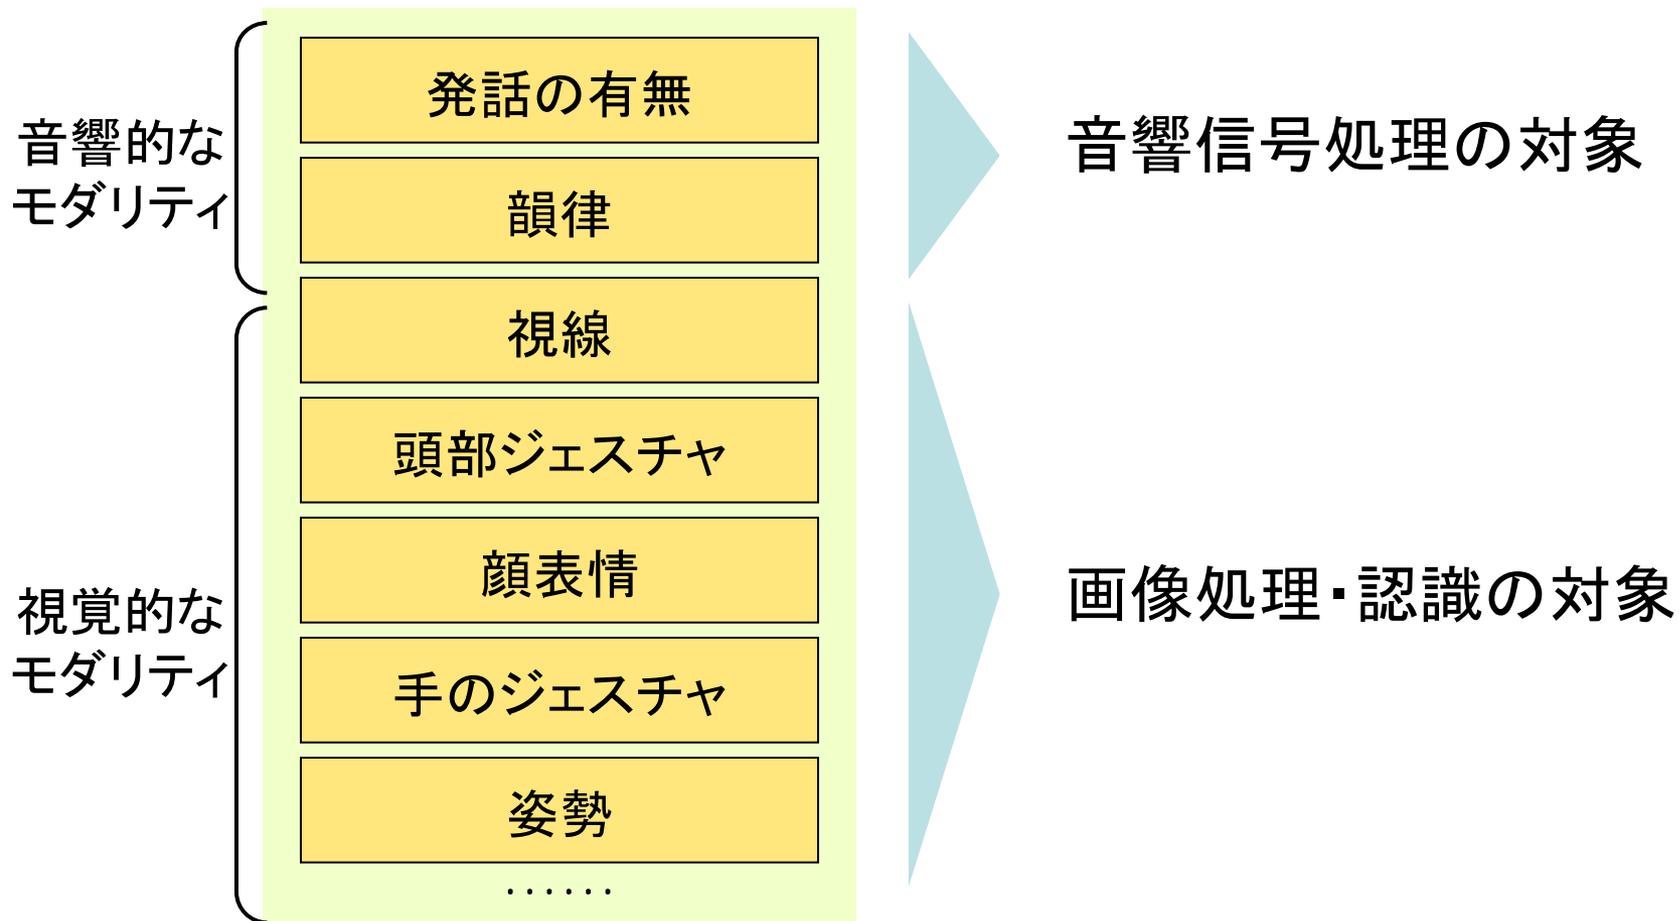
- (1) 人物間におけるメッセージの送信・受信の過程
- (2) メッセージの送受信によって心的状態に変化を生じさせる現象

コミュニケーションの過程



非言語行動・非言語メッセージ

対面コミュニケーションにおいて、
非言語行動・非言語メッセージは重要な役割を持つ



コミュニケーション・シーンの理解

コミュニケーションシーン理解のタスク

:=観測した画像・音響信号等から6W1Hを**自動的に**明らかにすること

when	where	who	whom	what	how	why
いつ？	どこで？	誰が？	誰と？	何を？	どのように？	何故？

様々なレベルのタスク

行動レベル

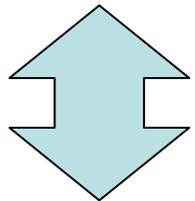
例)いま, 話しているのは誰か? 話者推定の問題

例)彼は誰と話しているのか? 話者+受け手の推定

例)誰のどの発言が彼を怒らせたのか?

例)何故, 彼女は泣いているのか?

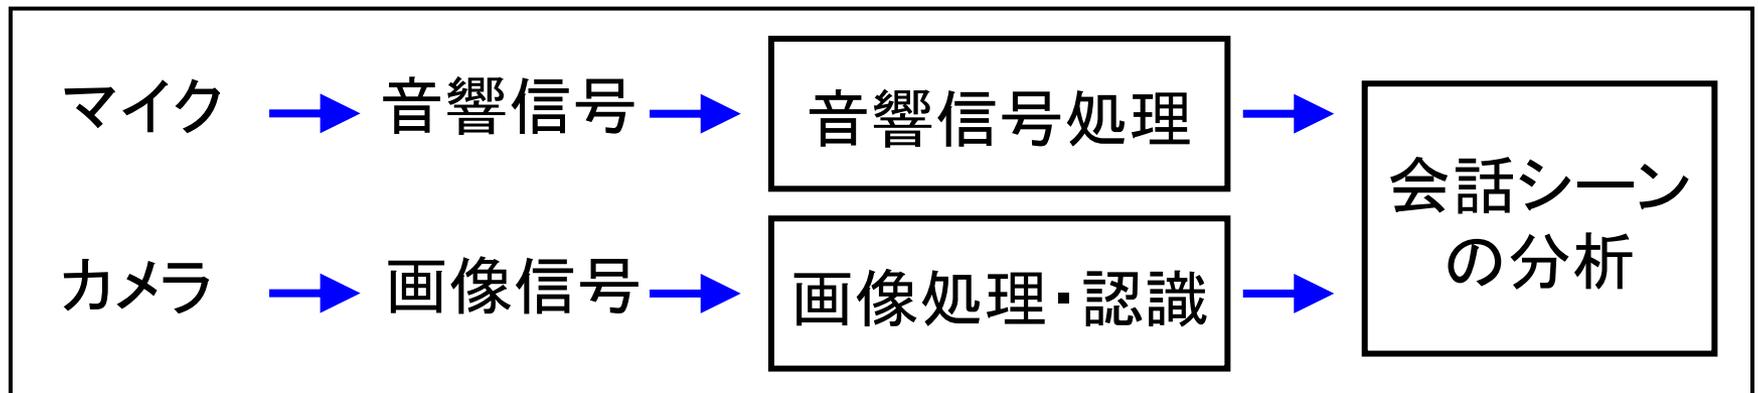
例)誰の意見がグループの結論に貢献したのか?



文脈・意味 のレベル

今回展示のデモシステムの概要

- 1) マルチモーダル・シーン分析
 - 「誰がいつ話しているか」を推定
 - 「誰が誰の方を向いているか」を推定
 - 「誰が注目を集めているか」を推定
- 2) コンパクトなカメラ・マイク統合システム
- 3) **リアルタイム**に動作する
- 4) いくつか会話シーンの可視化方法も提案



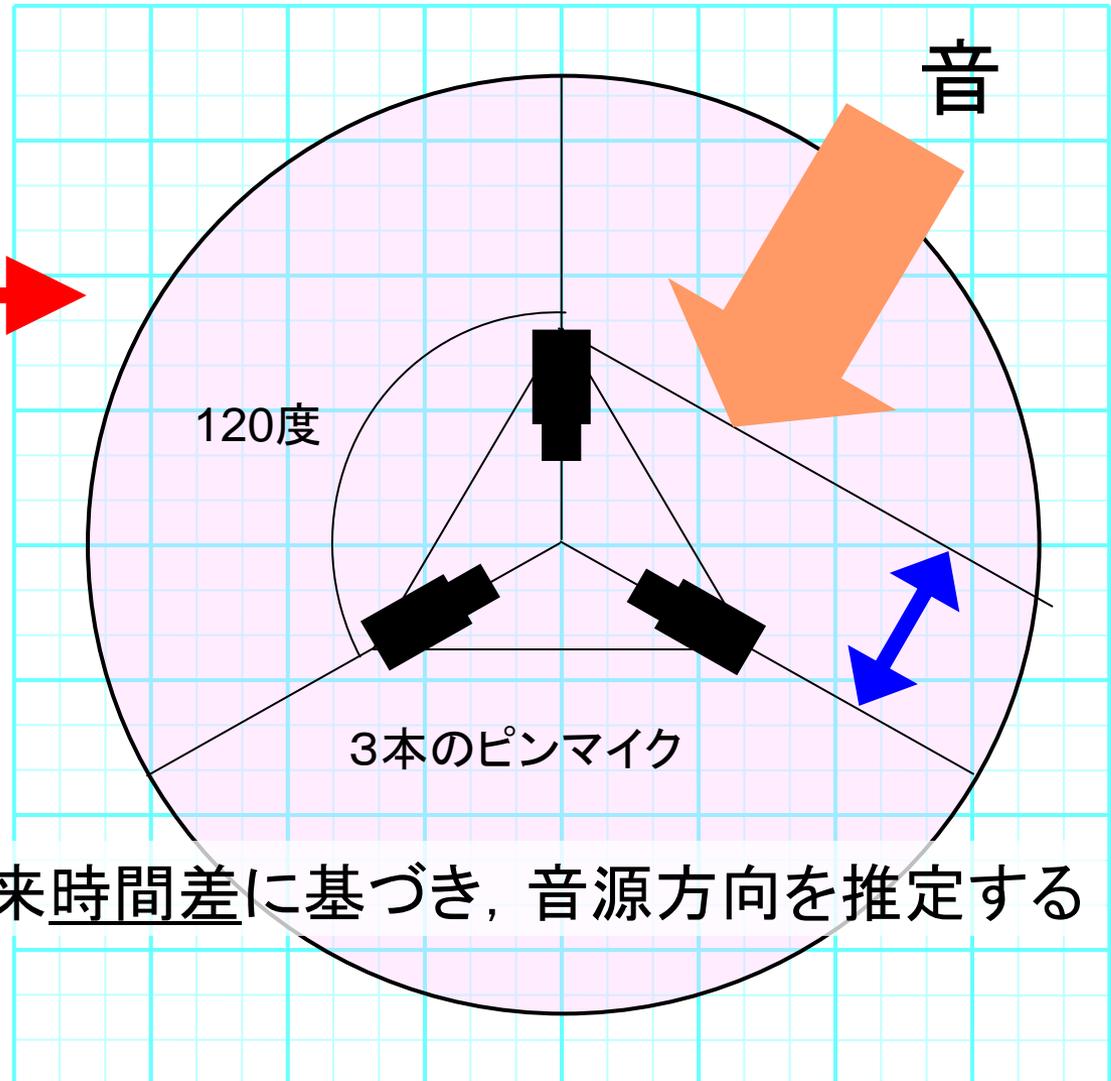
デモシステムの様子



全方位カメラ・マイクシステム

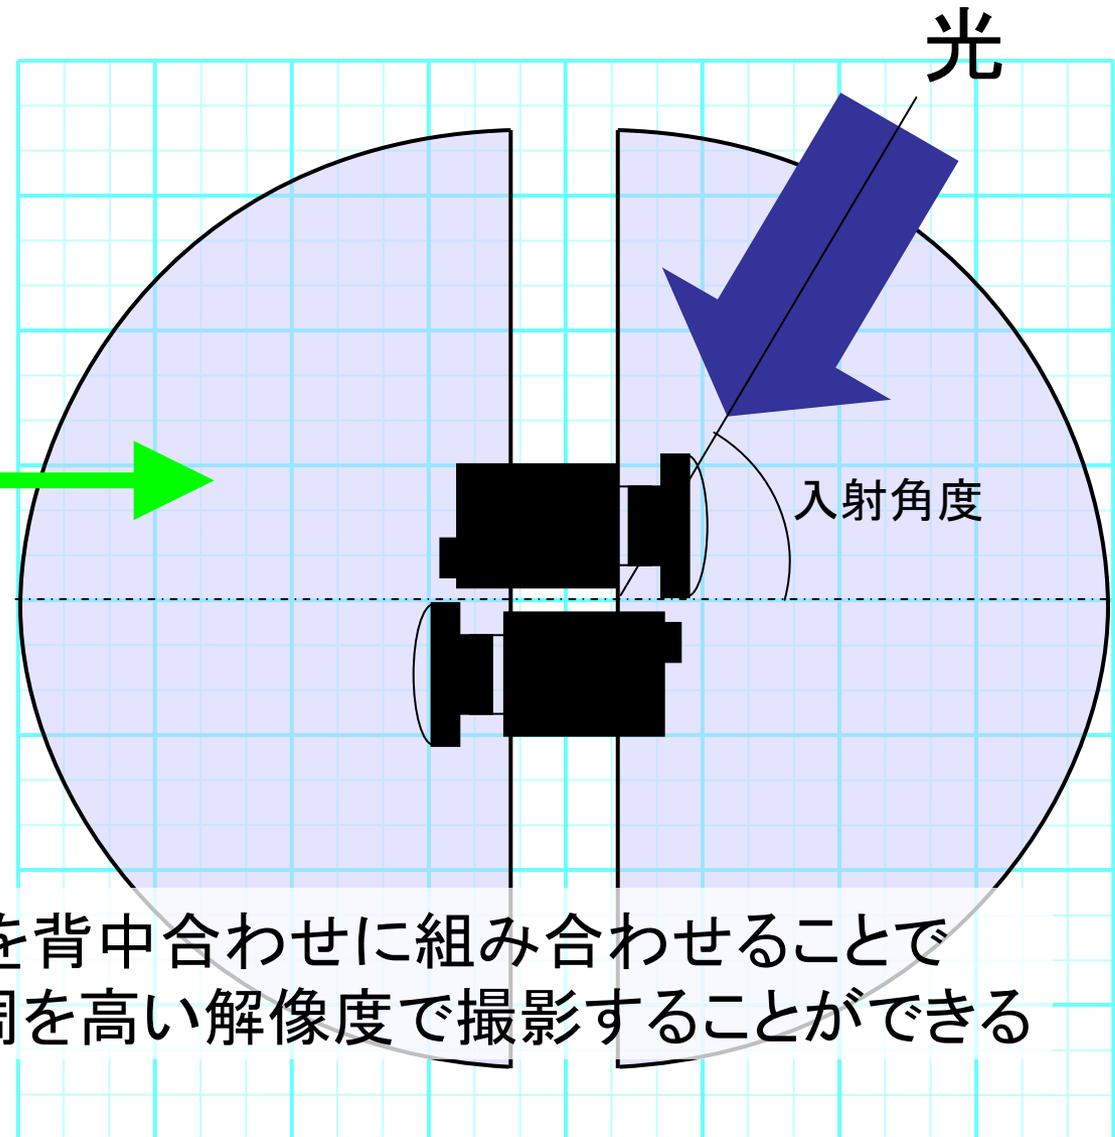


マイクロフォンアレー



マイク間での音の到来時間差に基づき、音源方向を推定する

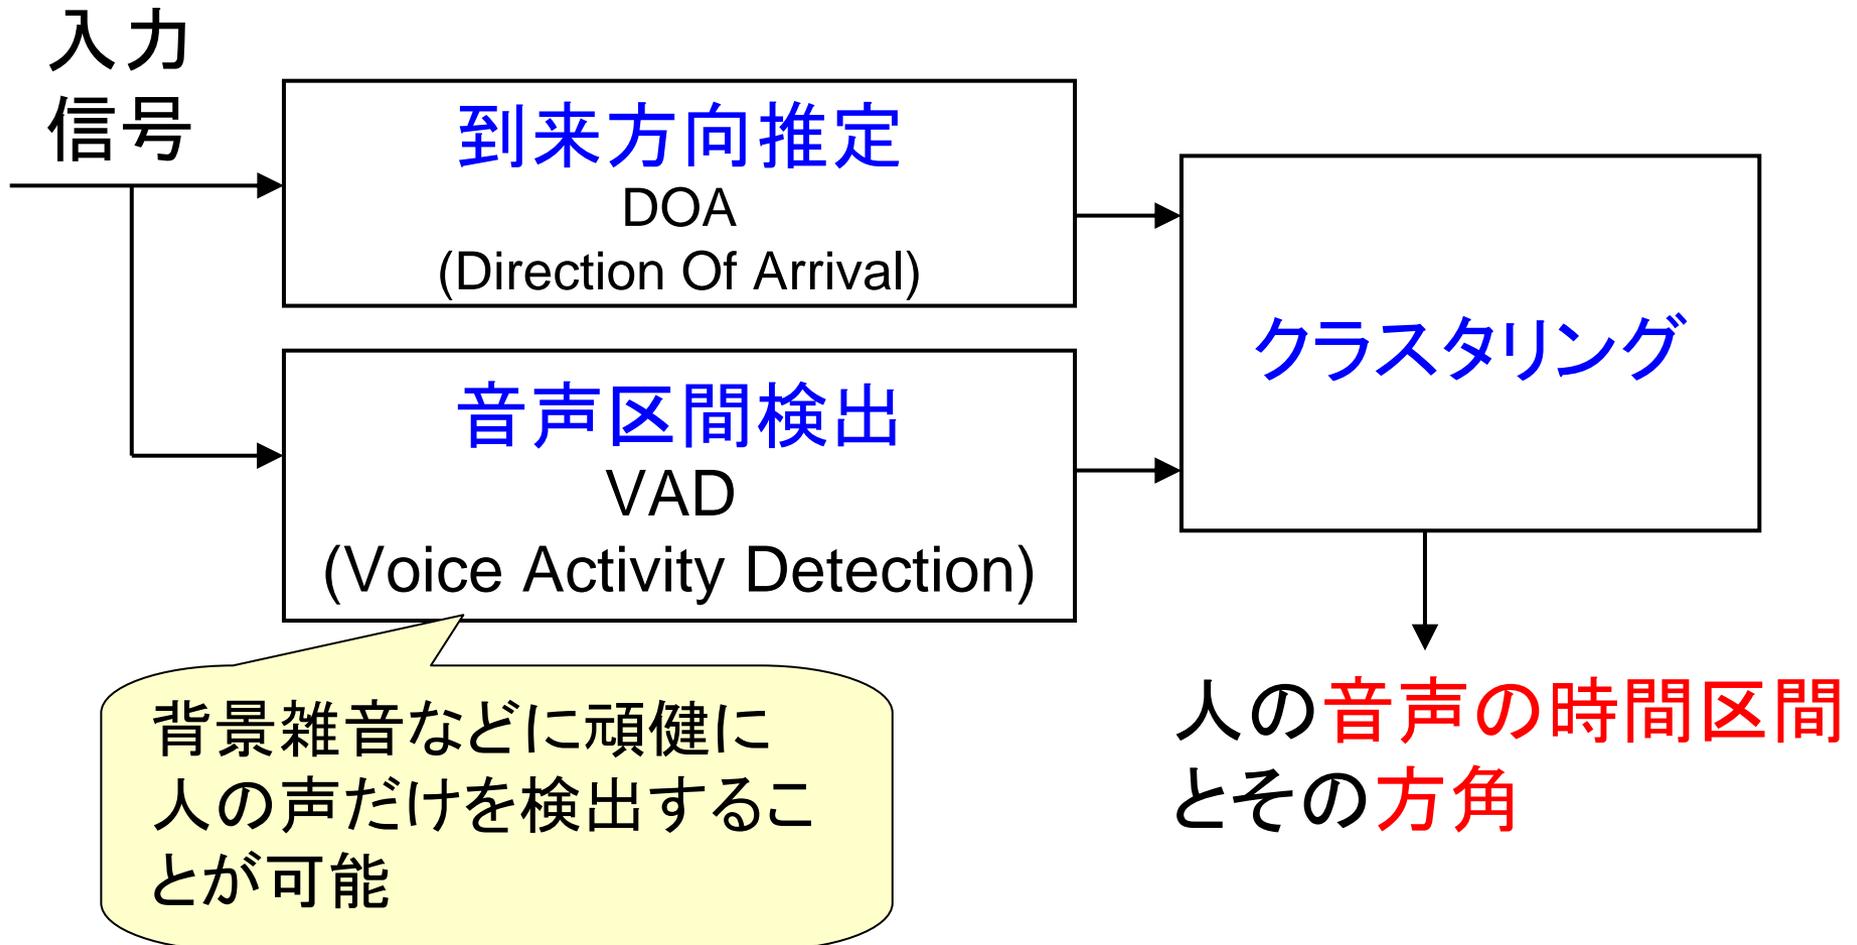
全方位カメラ



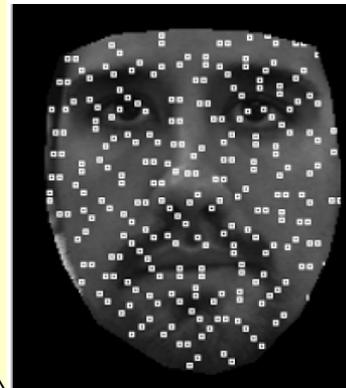
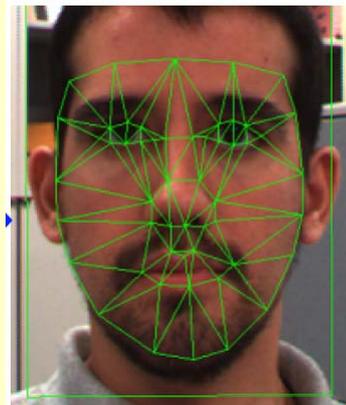
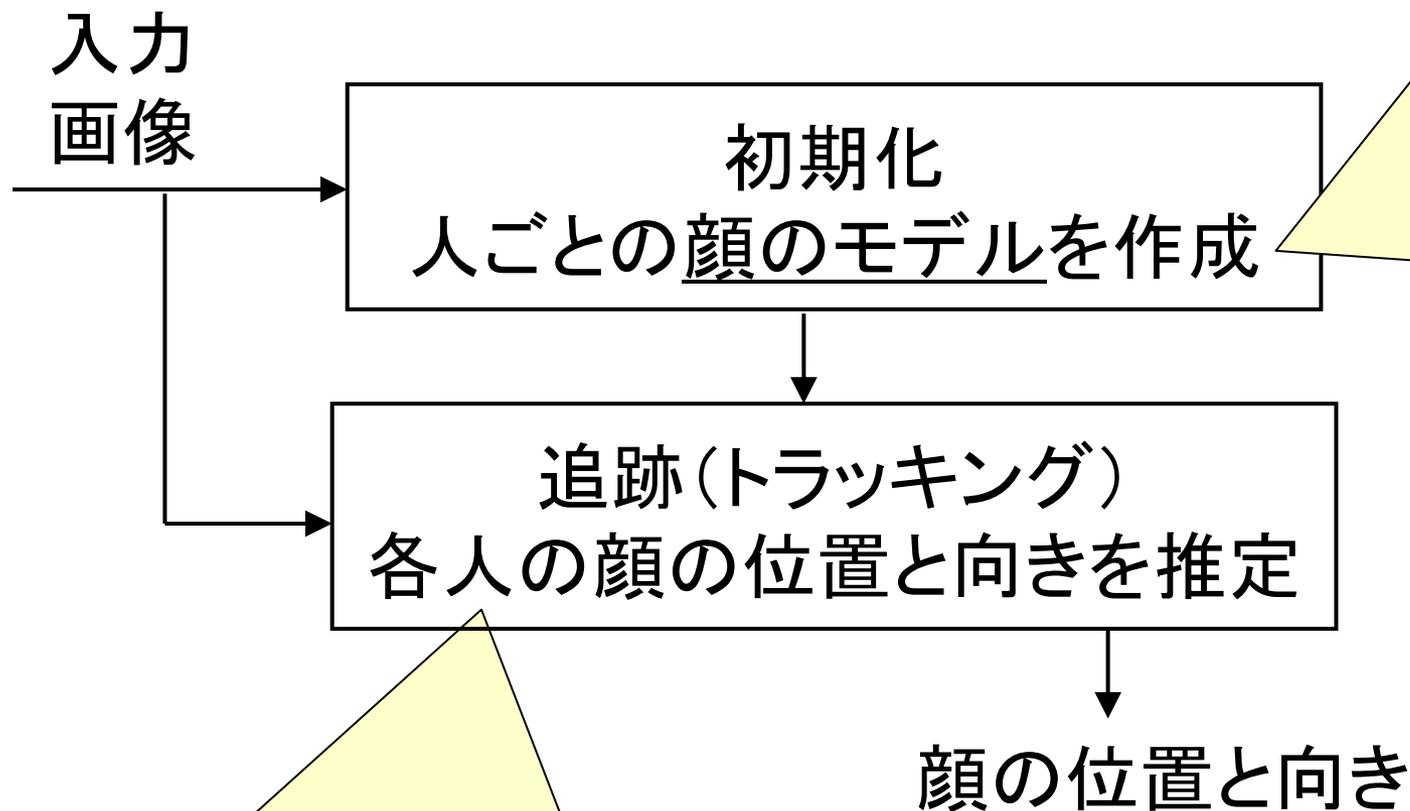
2つの魚眼レンズを背中合わせに組み合わせることで
ほぼ360度の全周を高い解像度で撮影することができる

音声系技術

音声到来方向推定と音声区間検出を組み合わせた技術



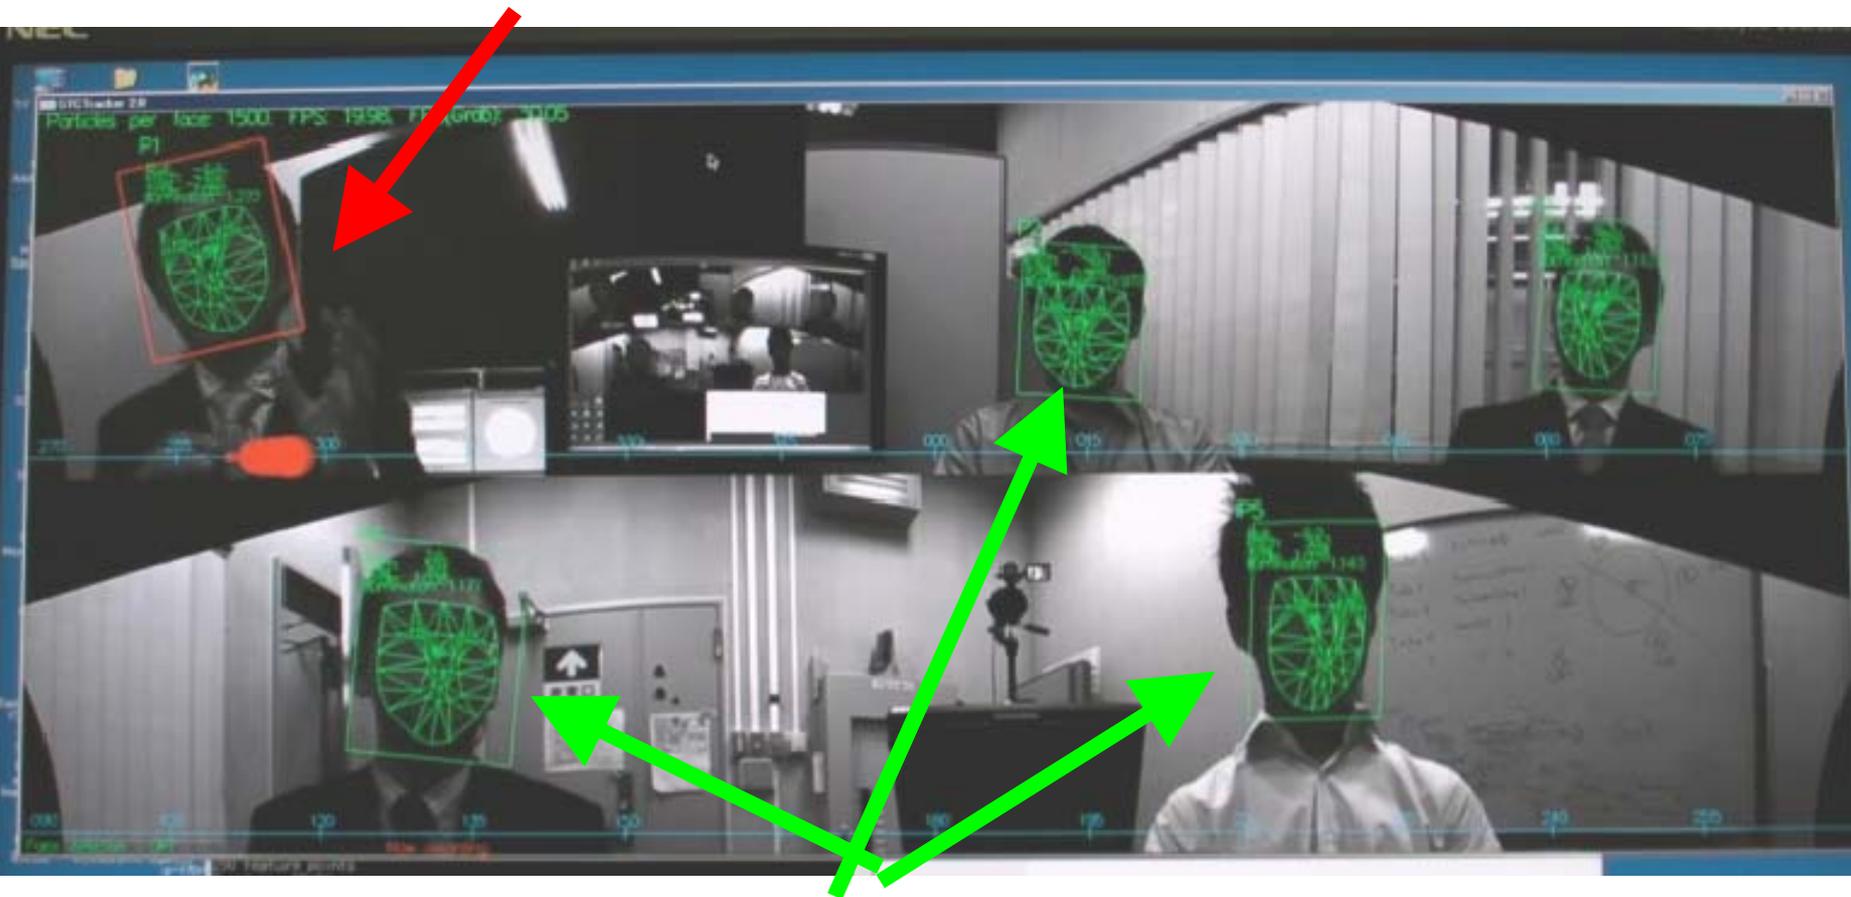
画像系技術



並列アルゴリズム(パーティクルフィルタ)を
並列ハードウェア(GPU=Graphics Processing Unit)
にて実行することで、約10倍の高速化を実現

デモシステムの動作の様子

- 各参加者の発話を検出



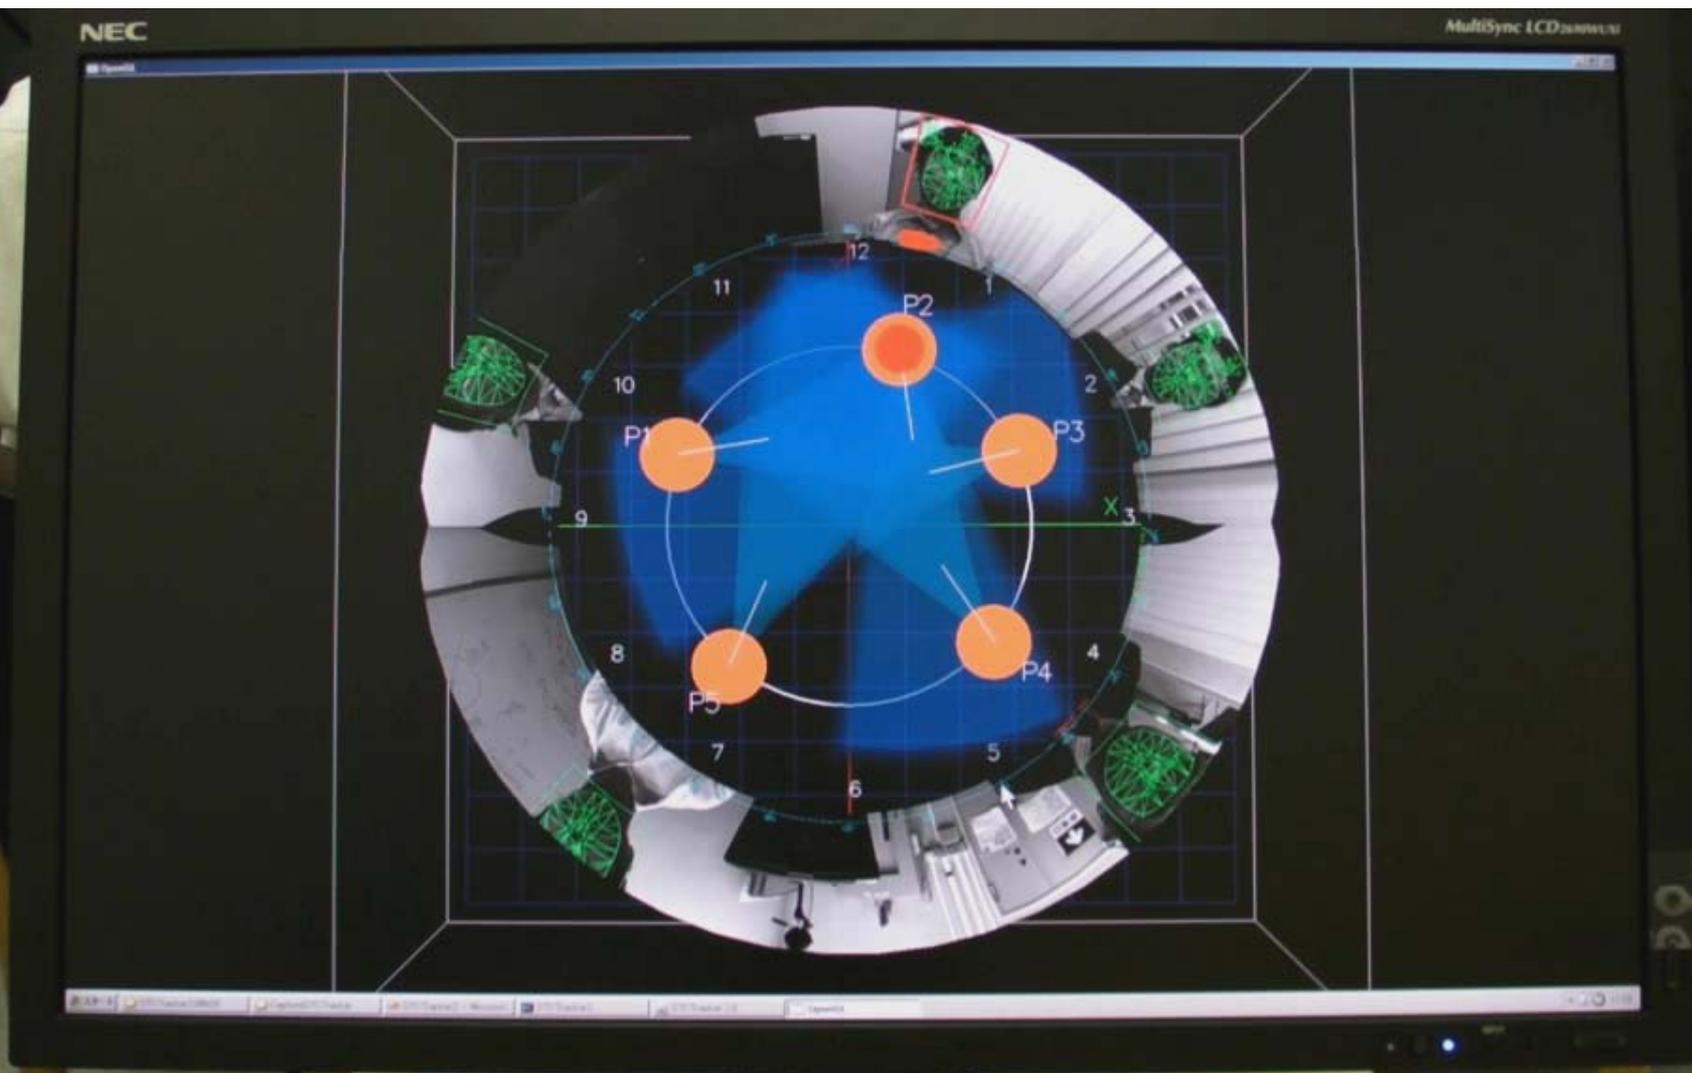
- 会話参加者の顔の位置と向きを追跡(トラッキング)

デモシステムの動作の様子

[ムービー 15秒]



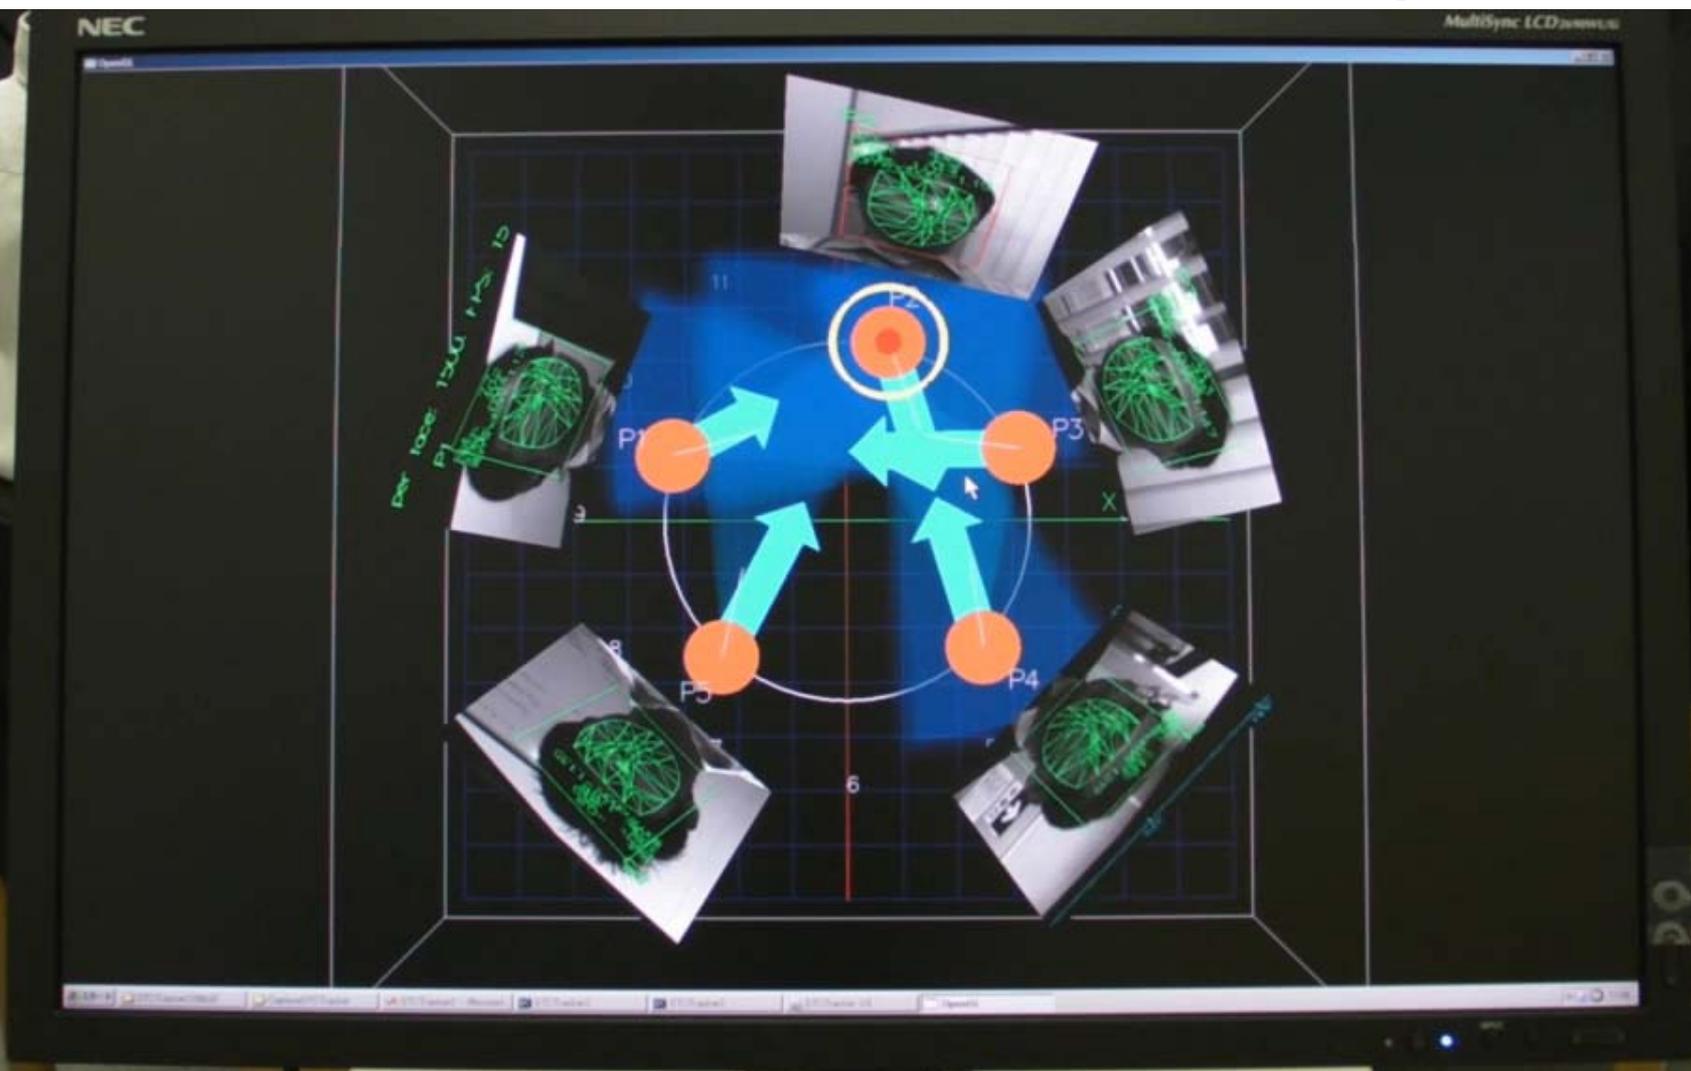
俯瞰的な表現



各人の顔の向いている方向と、(おおまかな)視野範囲を表示。

視線方向推定の例

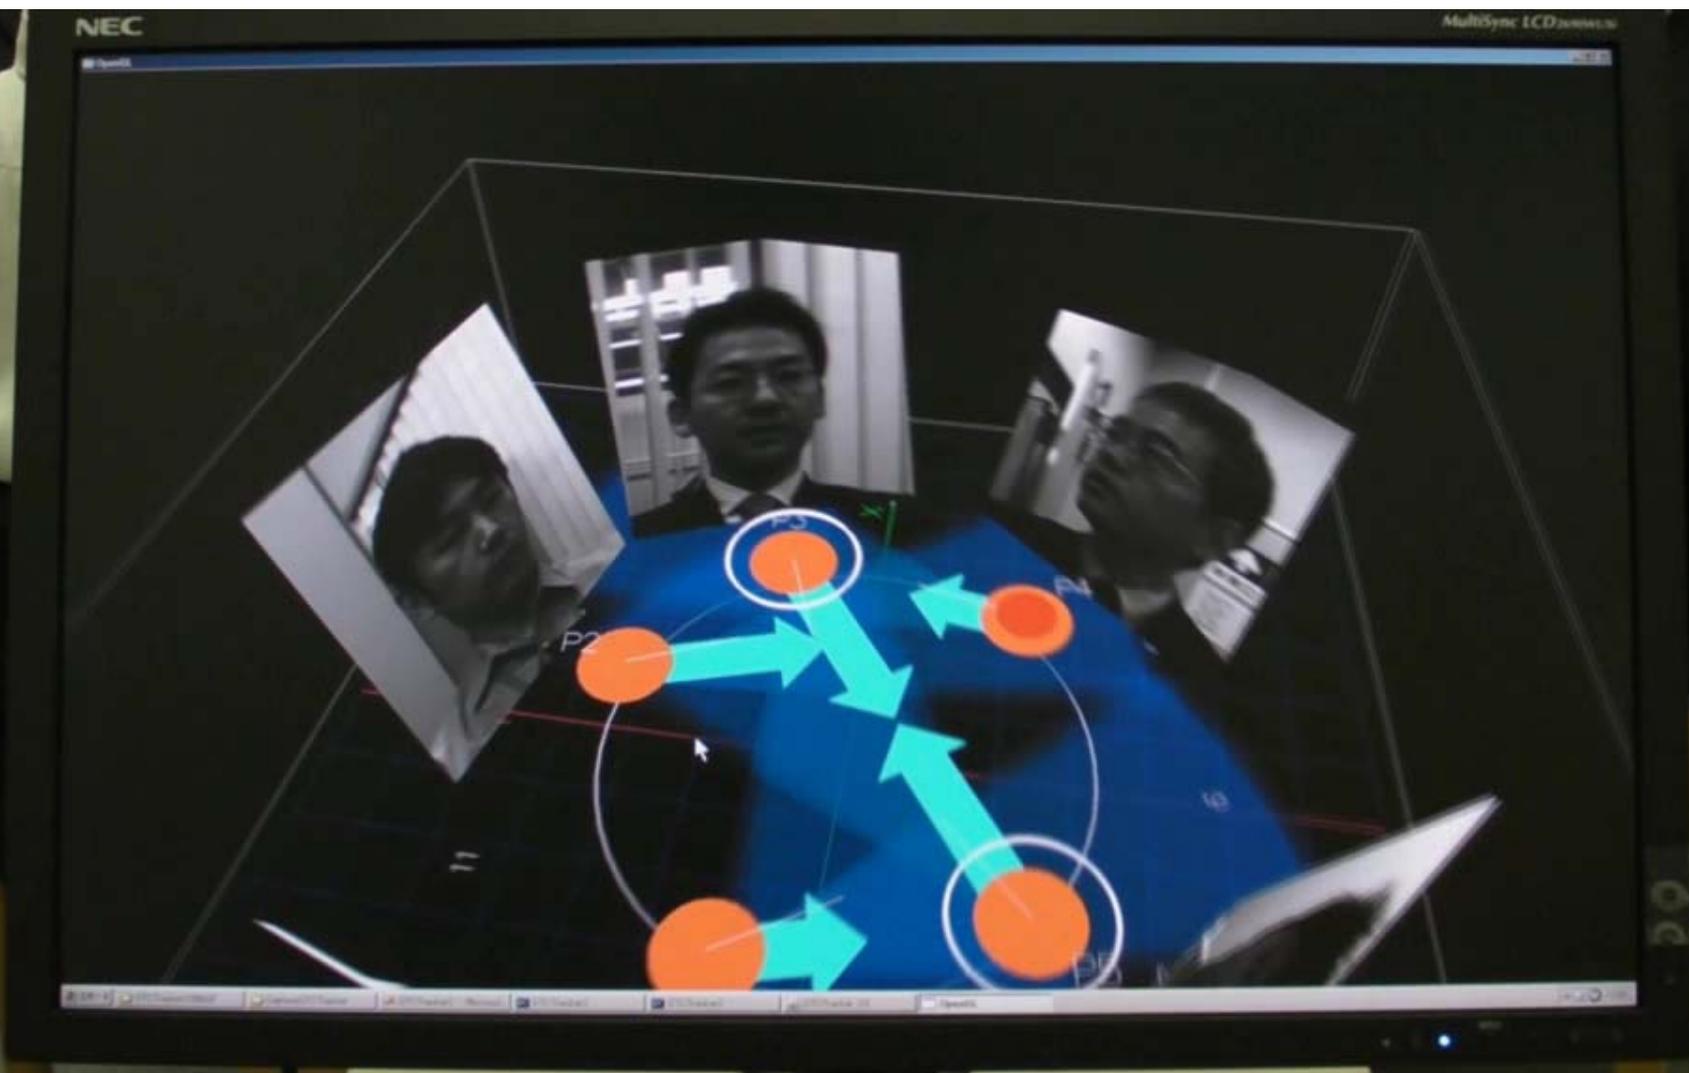
[ムービー 20秒]



矢印で推定視線方向を示す. 円で注目されている人を示す

カメラワークの例

[ムービー 40秒]



会話の様を自由に視点を変えて見ることが出来る

(C)2008 NTT Communication Science Labs.

議 論

- このような技術によって何が可能になるのか？
 - 「人のコミュニケーションをより良く知る」研究への貢献
 - 「人のコミュニケーションをより良くする」アプリケーションへの貢献
- どのような方向に技術開発を進めるのか？
- 複数分野の研究者との連携の必要性
 - 画像, 音声, 言語, 心理, 社会, 認知科学など