

# 画像の学習と応用

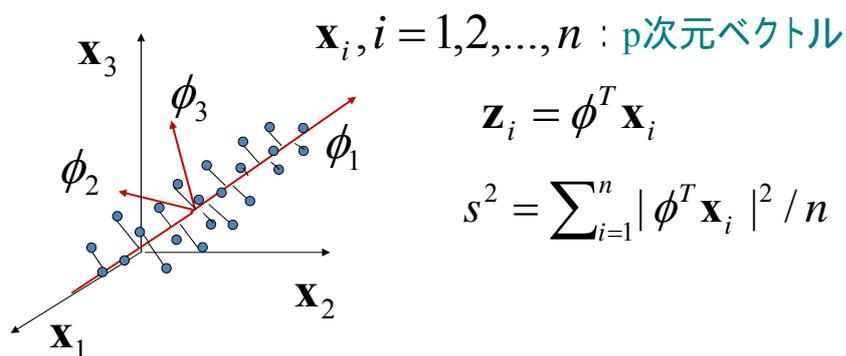
白井 良明

[shirai@ci.ritsumei.ac.jp](mailto:shirai@ci.ritsumei.ac.jp)

[www.i.ci.ritsumei.ac.jp/~shirai/](http://www.i.ci.ritsumei.ac.jp/~shirai/)

## 主成分分析

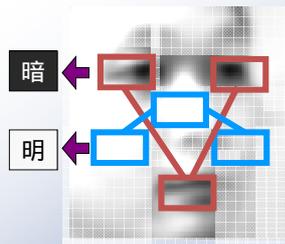
(Principal Component Analysis)



$$s^2 = \sum_{i=1}^n |(\mathbf{x}_i^T \phi)|^2 / n = \sum_{i=1}^n (\phi^T \mathbf{x}_i \mathbf{x}_i^T \phi) / n$$
$$= \phi^T \left( \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T / n \right) \phi$$

# 顔の状態の変化への対応

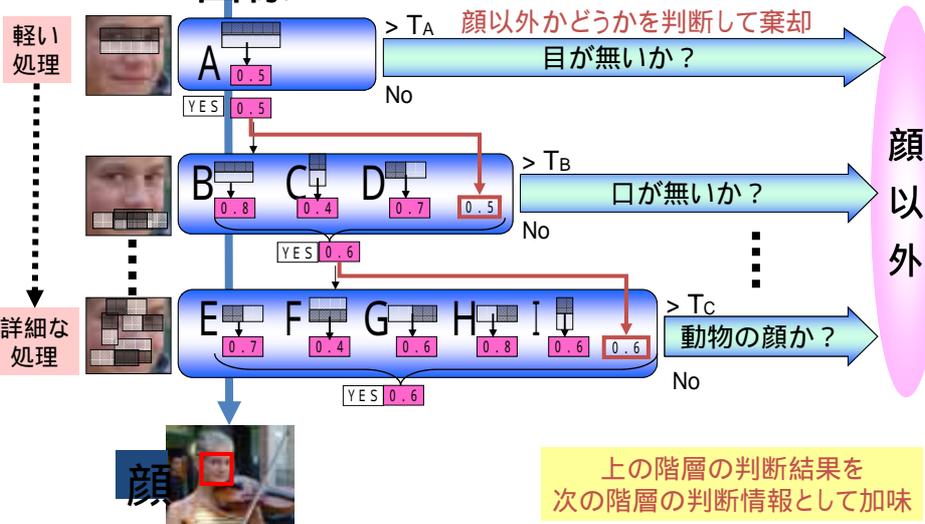
部分的な明暗差で顔をとらえることができる



斜め向きでも

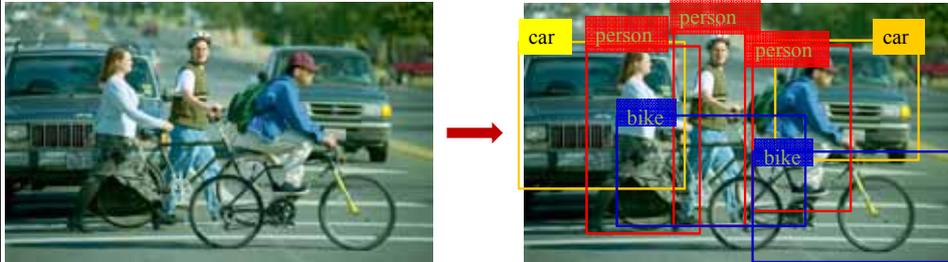
# 階層化棄却技術

画像の大部分は顔でない。顔でない部分をいかに高速に棄却するかが重要。



# Object Extraction from Image Database

PASCALVO  
C 2010



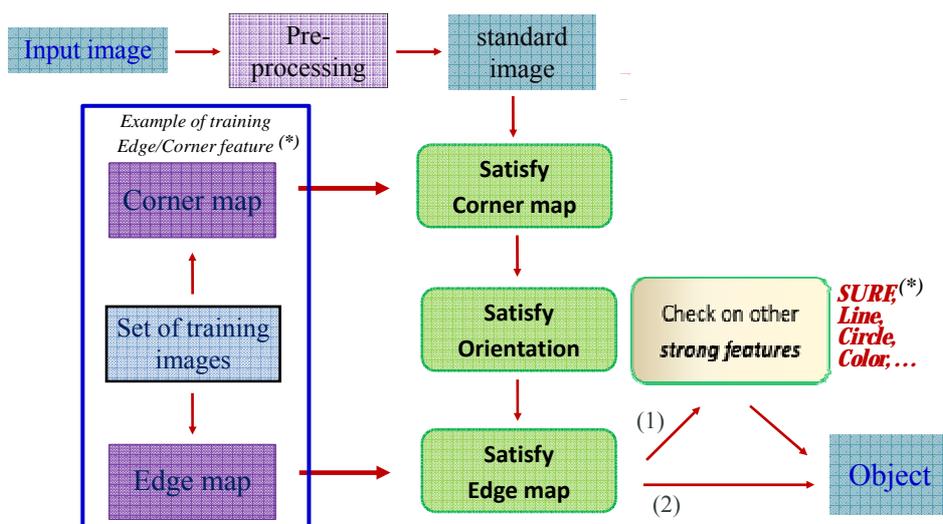
**Semantic**  
not easy to get

**Which objects**  
that an image contain?

**Objectives:**

Combine **multiple features** to detect  
*as many objects as possible*

## Object detection approach



(\*)Other features are also trained

6

## Edge map and corner map (training)

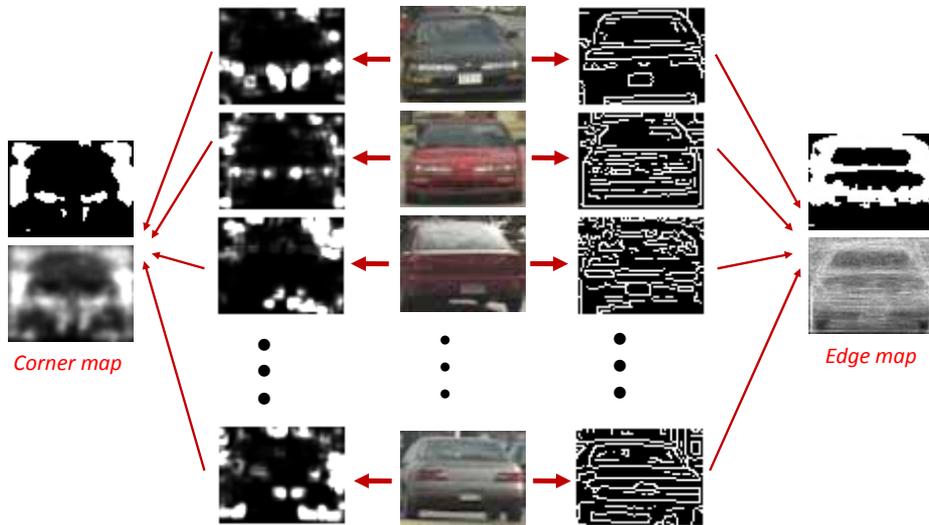
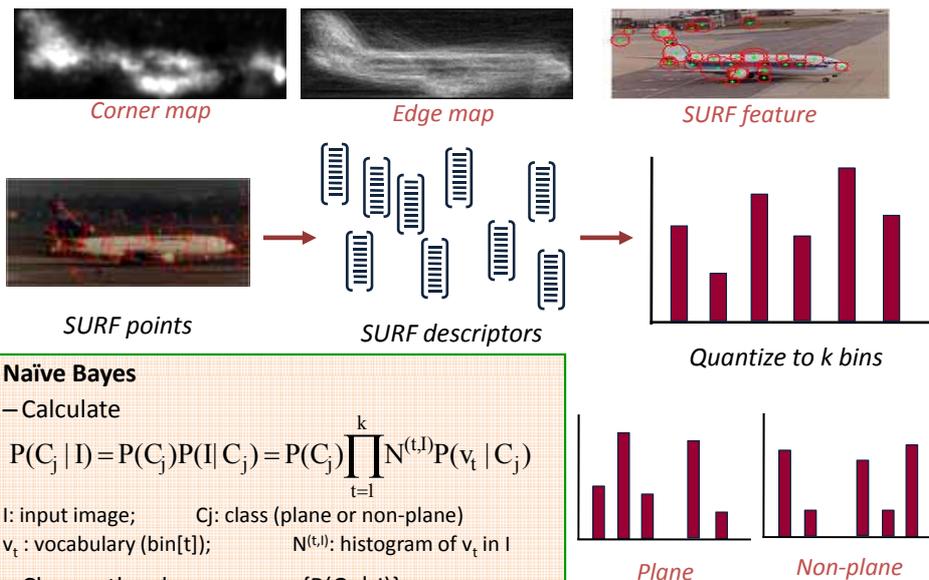


Fig. 2. Making Edge map & Corner map from training set

7

## SURF feature (aero plane, train)



### Naïve Bayes

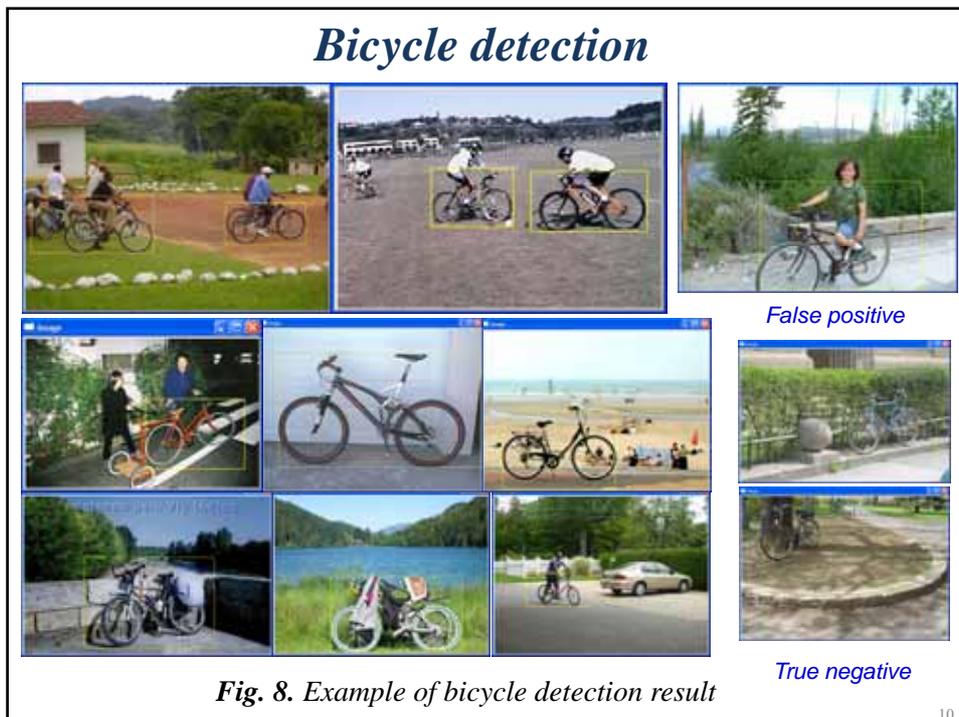
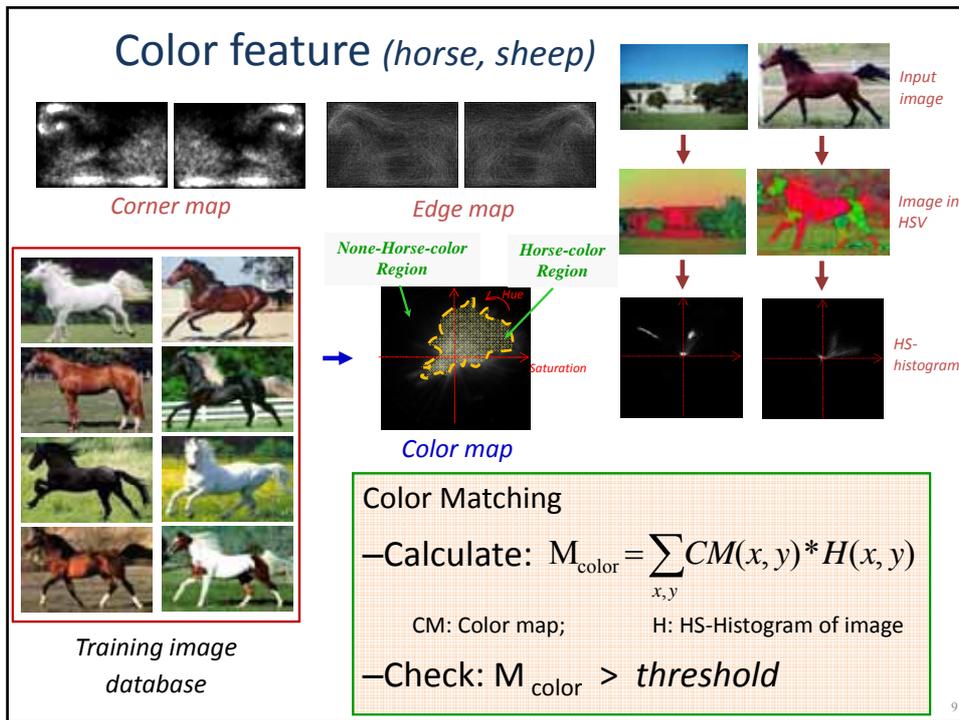
– Calculate

$$P(C_j | I) = P(C_j)P(I | C_j) = P(C_j) \prod_{t=1}^k N^{(t,I)} P(v_t | C_j)$$

I: input image;  $C_j$ : class (plane or non-plane)  
 $v_t$ : vocabulary (bin[t]);  $N^{(t,I)}$ : histogram of  $v_t$  in I

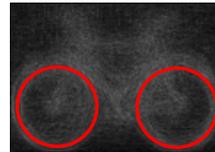
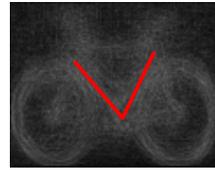
– Choose the class :  $\text{argmax}\{P(C_j | I)\}$

8



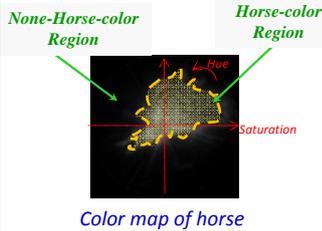
**Fig. 8.** Example of bicycle detection result

# Automatically choose features

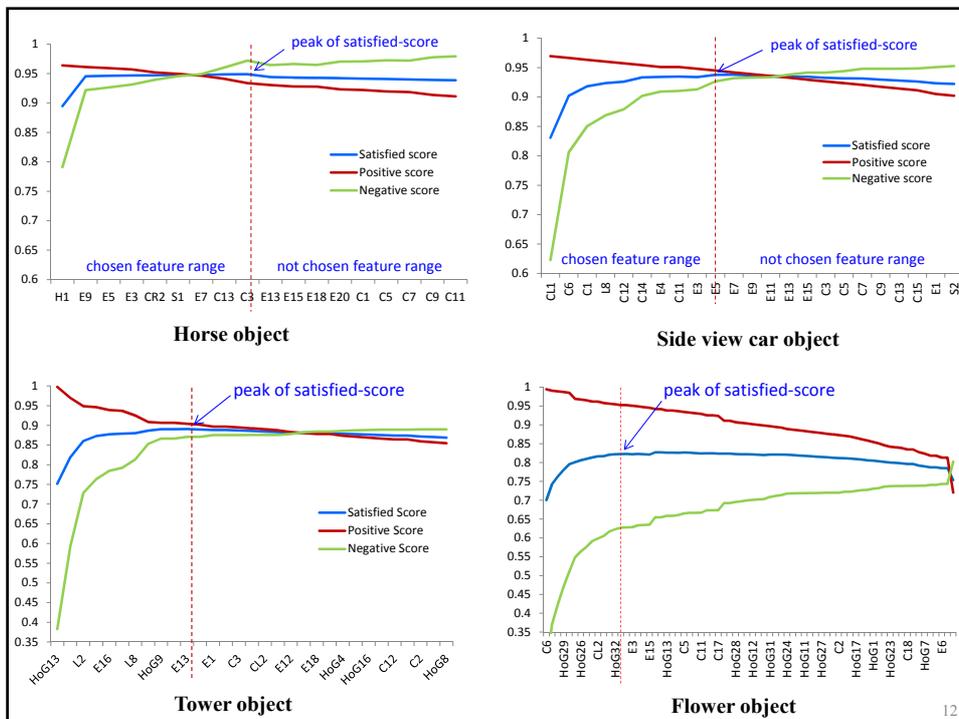


Two strongest lines of train

Line and Circle of bicycle



– Which features are “good” for a specific object?  
 – Can system *automatically* choose “good” features or not?



### Object with automatically chosen features

Object	Edge	Corner	Line	Circle	HoG	SURF	Color
F/r car	1	1	0	0	1	1	0
Side car	1	1	0	1	1	1	0
Bike	1	1	1	1	0	0	0
Train	1	1	0	0	1	1	0
Aero plane	1	1	1	0	0	1	0
Motorbike	1	1	0	0	0	1	1
Horse	1	1	1	0	0	1	1
Sheep	1	1	0	0	0	1	1
Tower	1	1	1	0	1	0	0
Flower	1	1	0	0	1	1	0

Table 2. Features are good for recognizing object

13

Object	TRAINING STAGE		TESTING STAGE	
	Average Precision	Average Recall	Average Precision	Average Recall
F/r car	96.48%	90.21%	95.12%	90.14%
Side car	97.20%	94.92%	94.21%	91.73%
Bike	85.80%	81.32%	84.02%	79.14%
Train	87.24%	77.16%	83.65%	75.31%
Aero plane	86.65%	84.55%	85.75%	84.51%
Motorbike	90.23%	87.32%	89.38%	85.47%
Horse	88.93%	82.09%	87.81%	75.40%
Sheep	87.32%	75.91%	86.25%	73.24%
Tower	89.07%	90.39%	84.33%	82.64%
Flower	82.71%	75.15%	81.57%	74.42%

Table 3. AP & AR at training/testing stage of automatically choosing features

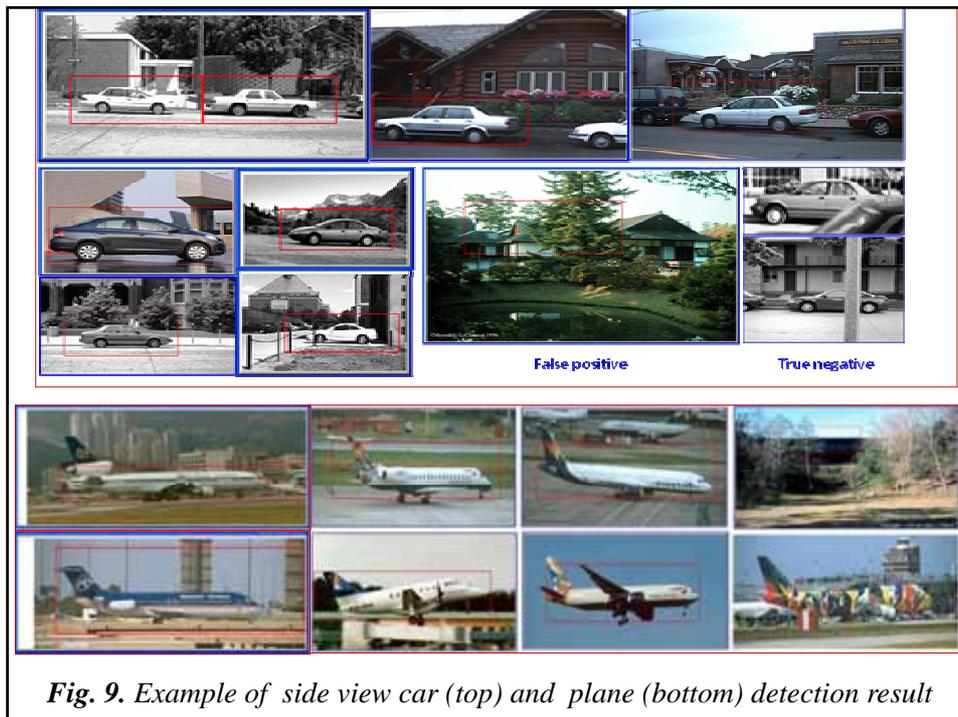


Fig. 9. Example of side view car (top) and plane (bottom) detection result

Evaluation			
Object	Our system	PASCAL VOC 2010 <sup>(1)</sup>	
	Average Precision	Average Precision	Authors
Front/rear car	95.12%	49.10%	<a href="#">UOCTI_LSVM_MDPM</a>
Side car	94.21%		
Bicycle	84.02%	55.30%	<a href="#">NLPR_HOGLBP_MC_LCEGCHLC</a>
Train	83.65%	50.30%	<a href="#">MITUCLA_HIERARCHY</a>
Aero plane	85.75%	58.40%	<a href="#">UVA_GROUPLOC</a>
Motorbike	89.38%	56.30%	<a href="#">NUS_HOGLBP_CTX_CLS_RESCO_RE_V2</a>
Horse	87.81%	51.90%	<a href="#">NUS_HOGLBP_CTX_CLS_RESCO_RE_V2</a>
Sheep	86.25%	37.80%	<a href="#">UVA_DETMONKEY</a>
Tower	84.33%	84.00%	<a href="#">HENA_LU_DU</a> <sup>(2)</sup>
Flower	81.57%	80.00%	<a href="#">JZU_HONG_CHEN_LI</a> <sup>(3)</sup>

Table 5. Comparison between our system with PASCAL 10

<sup>1</sup> PASCAL 10 <http://pascallin.ecs.soton.ac.uk/challenges/VOC/voc2010/results/> (about 20 categories)

<sup>2</sup> Lu Yang, Du Xiao-wei, 2<sup>nd</sup> Intl Asia Conference on Informatics in Control, Automation and Robotics 2010, p.p 349-352

<sup>3</sup> Hong et al. / J Zhejiang Univ SCI 2004 5(7):764-772 <http://www.zju.edu.cn/jzus>

## Conclusion

- Combine various features for object detection.
- Automatically choose suitable features.

## Future works

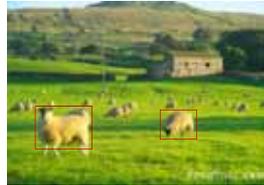
- $f_i \wedge f_{i+1} \wedge f_{i+2} \rightarrow f_i \wedge (f_{i+1} \vee f_{i+2})$

- very small object



Select

“suitable” scale

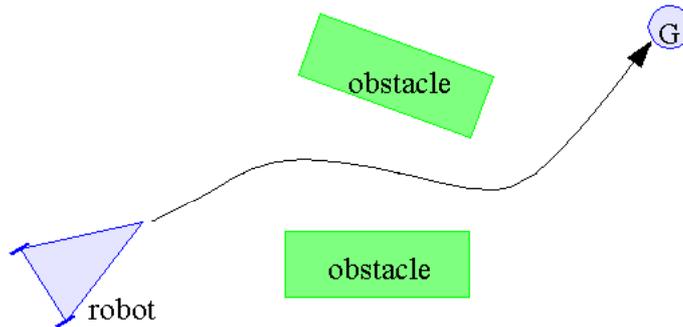


## Dynamic Motion Planning for Efficient Visual Navigation under Uncertainty



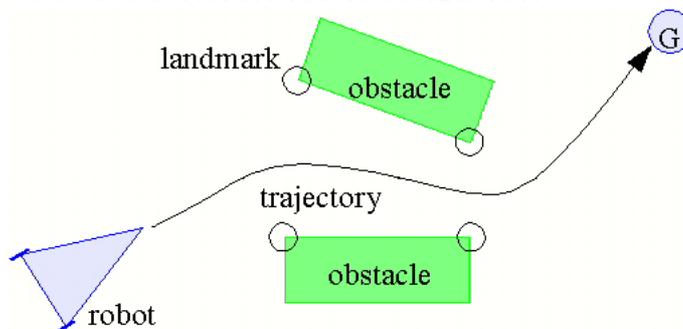
## Objective

- Safely and quickly reaching a goal position



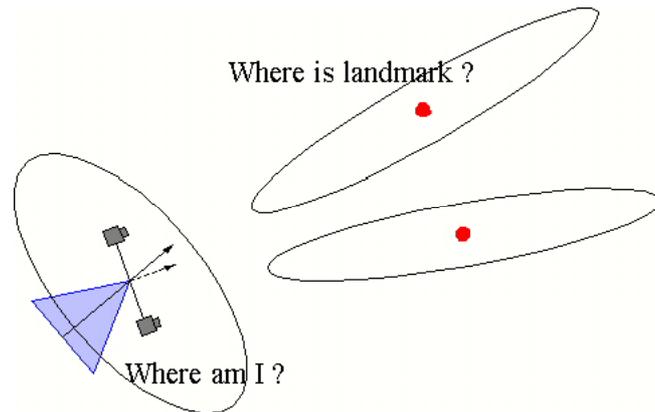
## Basic assumption for the first case

- Indoor environment is known
- Landmarks are given
- Use stereo vision for localization



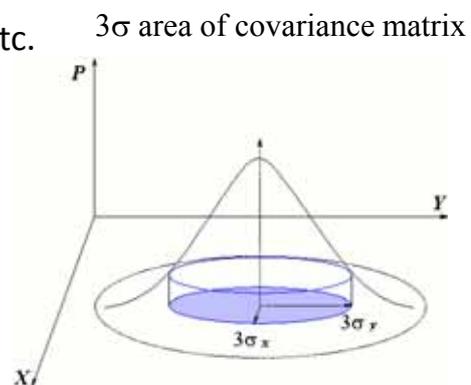
## Problem

- Motion and vision include **uncertainty**.
- Vision requires **high computational cost**.

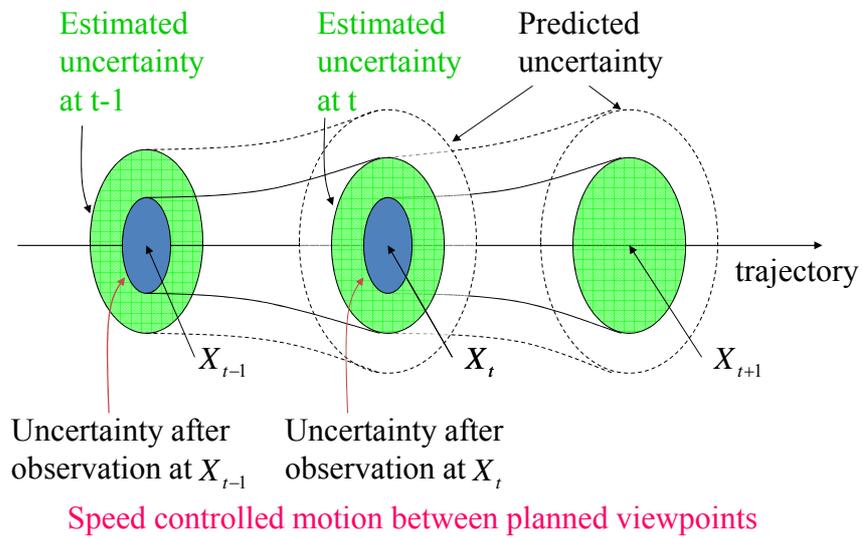


## Uncertainty

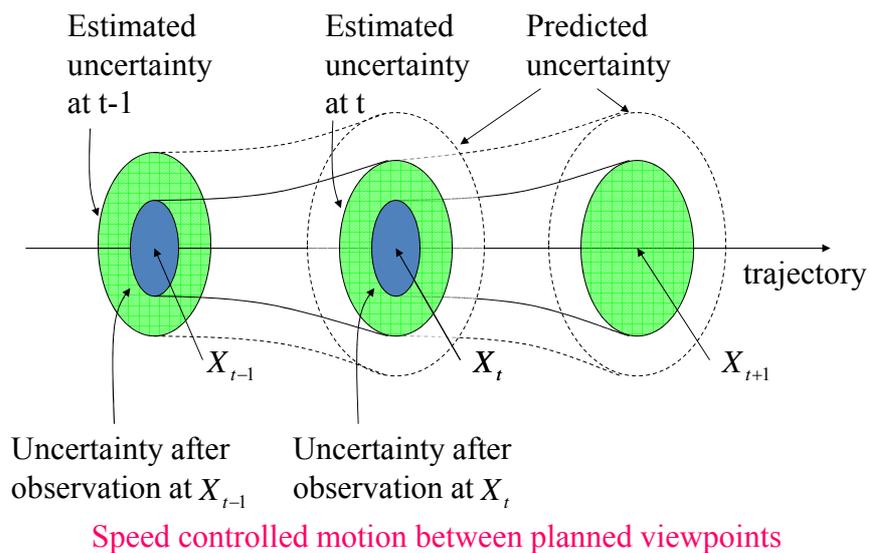
- Motion uncertainty
  - control error
  - rolling, slippage and etc.
- Vision uncertainty
  - quantization error
  - calibration error



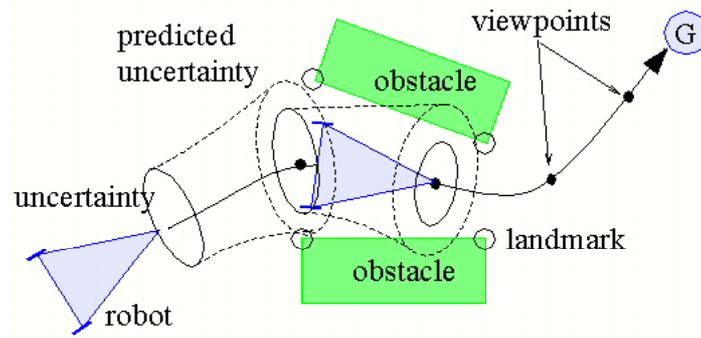
## Non-stop and speed controlled navigation strategy



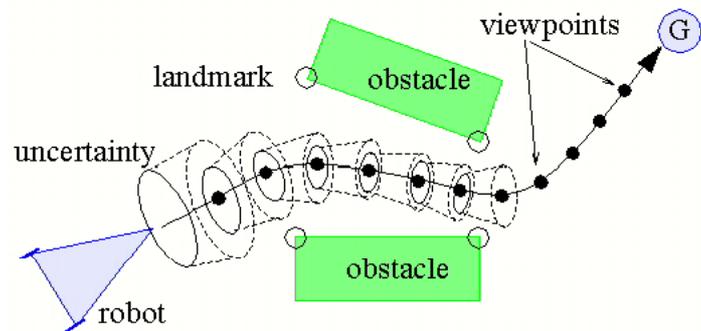
## Non-stop navigation strategy



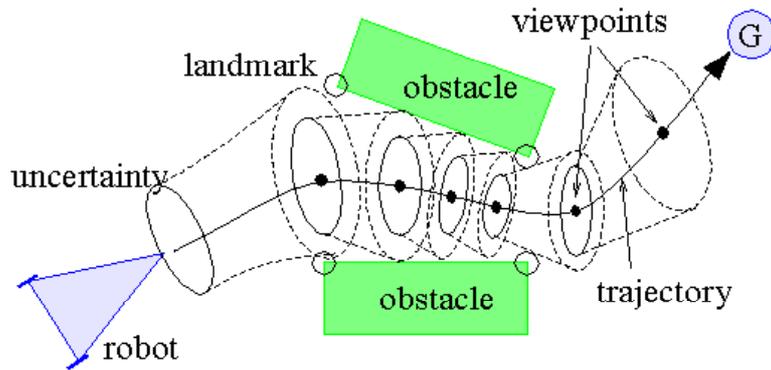
## Case 1: fast but dangerous



## Case 2: safe but slow



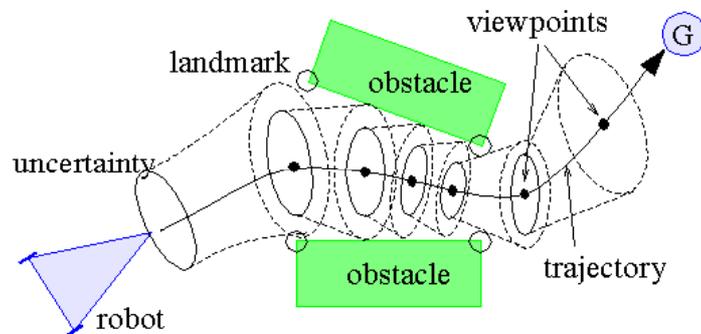
## Case 3: adaptive observation



Adaptive viewpoint planning method considering uncertainty

## Adaptive viewpoint

1. Observation position to **guarantee the safety**
2. Observation position to reach the goal position **quickly**



## Idea

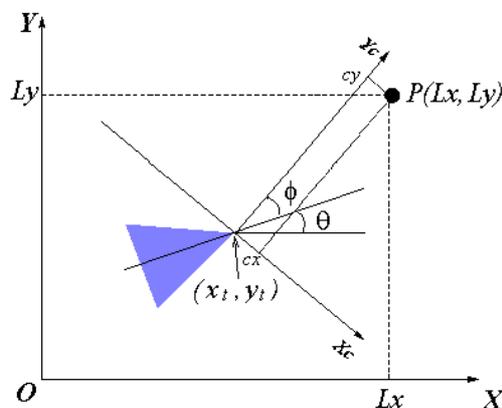
- Safety
  - considering **uncertainty**
- Quickly
  - navigation with **minimum observation**
  - **non-stop and speed controlled** navigation



Adaptive viewpoint planning under uncertainty

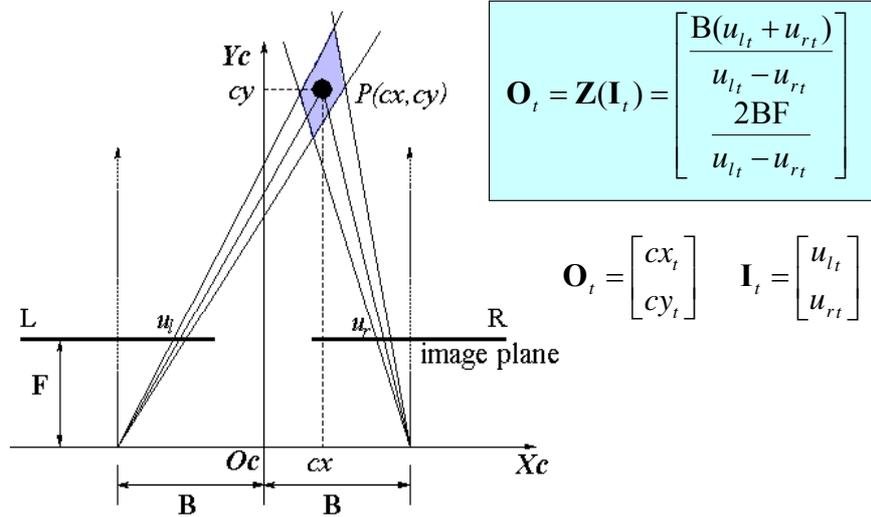
## Observation model

$$\mathbf{G}(\mathbf{X}_t, \mathbf{O}_t) = \begin{bmatrix} x_t \\ y_t \end{bmatrix} + \begin{bmatrix} \sin(\theta_t + \phi_t) & \cos(\theta_t + \phi_t) \\ -\cos(\theta_t + \phi_t) & \sin(\theta_t + \phi_t) \end{bmatrix} \begin{bmatrix} cx_t \\ cy_t \end{bmatrix} - \begin{bmatrix} L_x \\ L_y \end{bmatrix} = \mathbf{0}$$

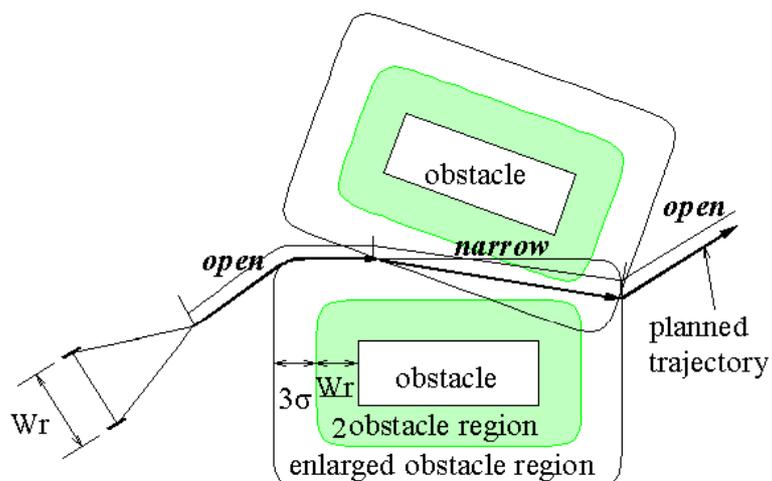


$$\mathbf{X}_t = \begin{bmatrix} x_t \\ y_t \\ \theta_t \end{bmatrix} \quad \mathbf{O}_t = \begin{bmatrix} cx_t \\ cy_t \end{bmatrix}$$

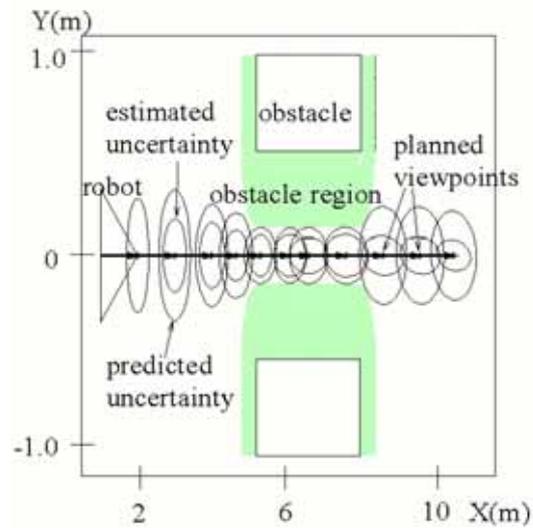
## Stereo observation model



## Trajectory planning

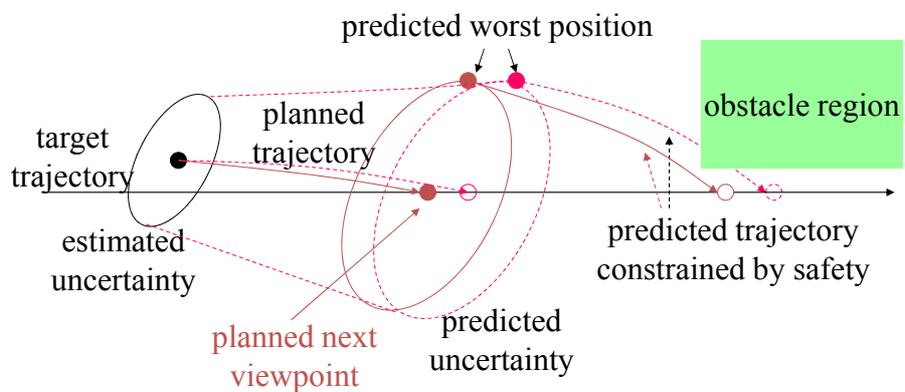


## Offline planned viewpoints



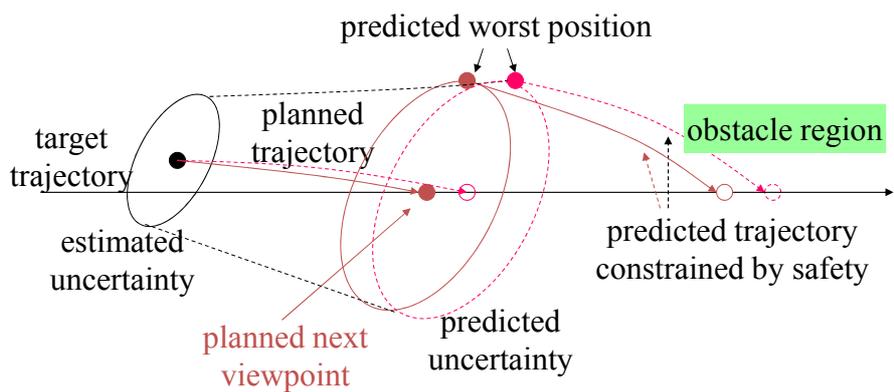
## Dynamic planning method

Move to the farthest safe position on the target trajectory

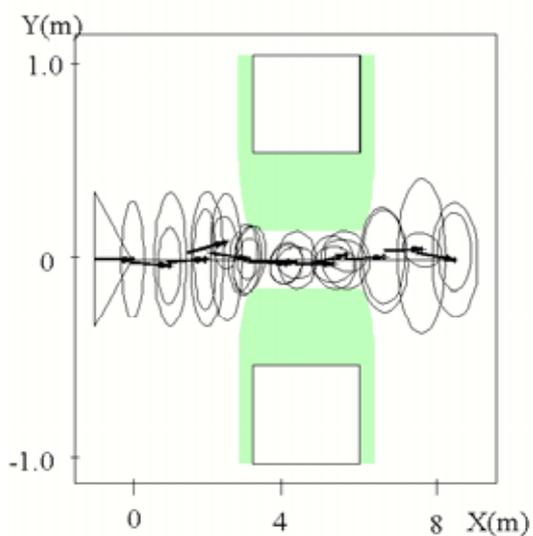


## Dynamic viewpoint planning

Move to a position to guarantee safety



## Motion result using online planning

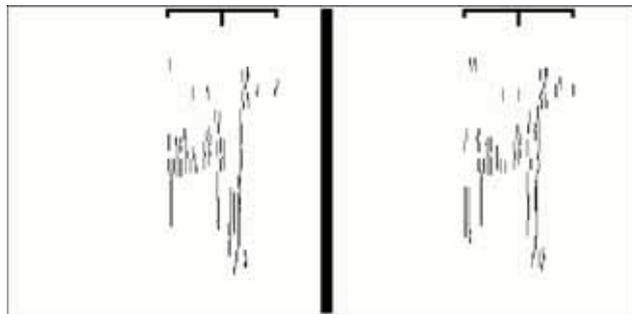


## Landmark observation

- **Vertical segment** as landmark
- Selection candidates by **position and similarity** constraints



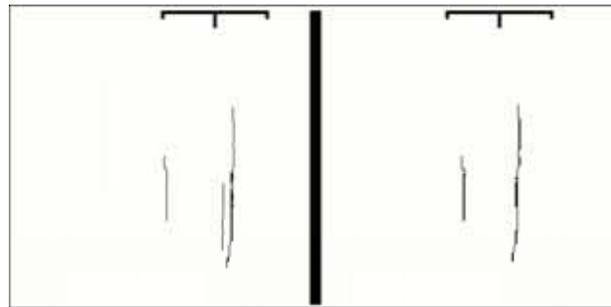
## Position constraint



Left image

Right image

## Similarity constraint



Left image

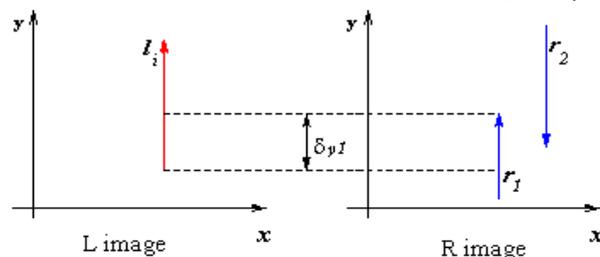
Right image

## Similarity of stereo segment pair

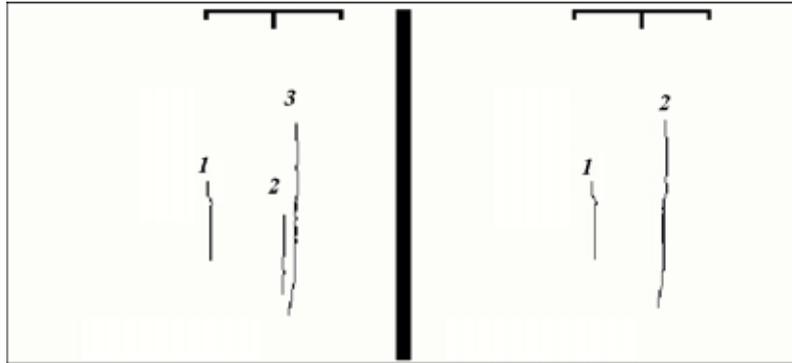
1. Orientation similarity 
$$OS(l_i, r_j) = \begin{cases} 1 & (\text{if } dir(l_i) = dir(r_j)) \\ 0 & (\text{else}) \end{cases}$$

2. Overlap length 
$$OL(l_i, r_j) = \frac{1}{2} \left[ \frac{\delta y}{len(l_i)} + \frac{\delta y}{len(r_j)} \right]$$

3. Length similarity 
$$LS(l_i, r_j) = \frac{\min[len(l_i), len(r_j)]}{\max[len(l_i), len(r_j)]}$$



## Example of matching

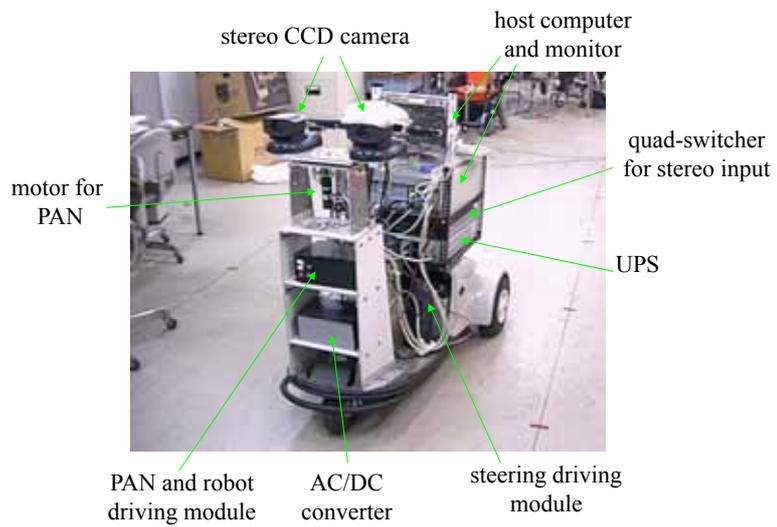


## Result of landmark detection



-  Predicted landmark position on image
-  Detected landmark position on image

## Mobile robot



## 実験 (部分的に早送り)



## Range sensors

– Omnidirectional Stereo

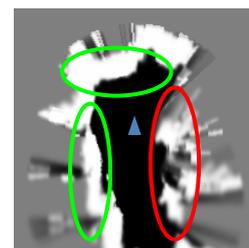
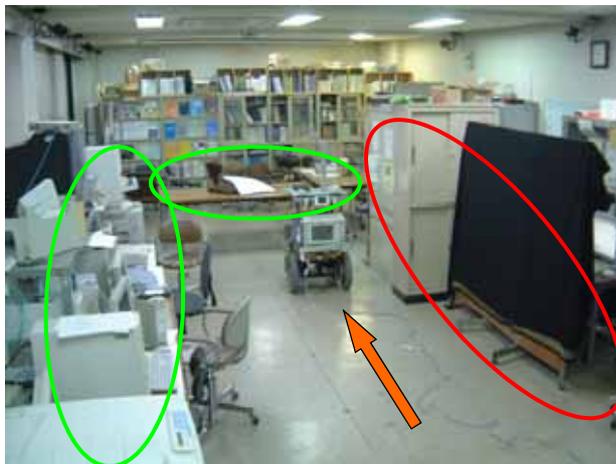


– Laser Range Finder (LRF)

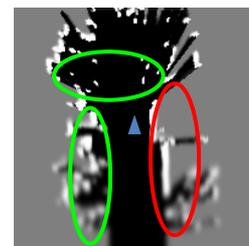


## Generating probabilistic occupancy maps

- Representing probabilities of obstacle existence in each grid.



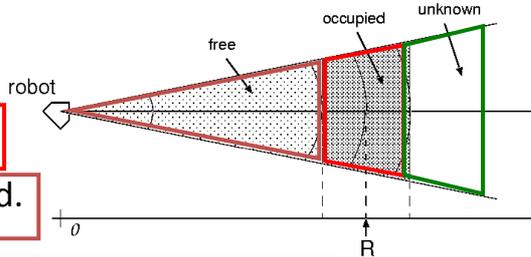
Omnidirectional stereo



LRF

## Interpretation of current sensor data

- $E$ : obstacle exists.
- $O$ : obstacle is observed.
- $\bar{O}$ : free space is observed.



$$P(E | O) = \frac{P(O | E)P(E)}{P(O | E)P(E) + P(O | \bar{E})P(\bar{E})}$$

$$P(E | \bar{O}) = \frac{P(\bar{O} | E)P(E)}{P(\bar{O} | E)P(E) + P(\bar{O} | \bar{E})P(\bar{E})}$$

$P(E)$ : prior probability (initialized to 0.5)

$P(O | E), P(\bar{O} | \bar{E})$ : observation models

## Map generation -integration of two sensors-

- Integration by a logical rule.

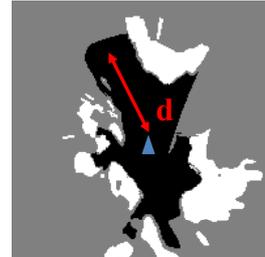
		Omnidirectional stereo			
		obstacle	undecidedwo	undecidedwt	free
L R F	obstacle	obstacle	obstacle	obstacle	obstacle
	undecidedwo	obstacle	obstacle	obstacle	obstacle
	undecidedwt	obstacle	obstacle	obstacle	free
	free	obstacle	obstacle	free	free

undecidedwo : not observed yet

## Formulation

**The robot moves at a speed to sufficiently observe an undecided region.**

- N : the number of observations recognizing a free space
- d : Distance to undecided region
- T : Observation cycle (constant)
- v : Robot speed

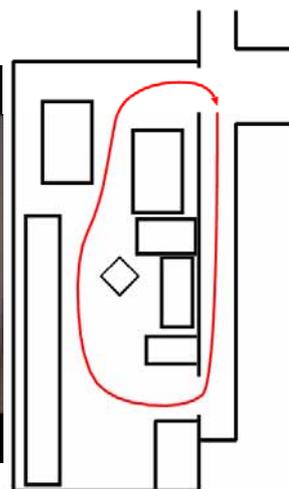


$$\frac{d}{vT} \geq N$$

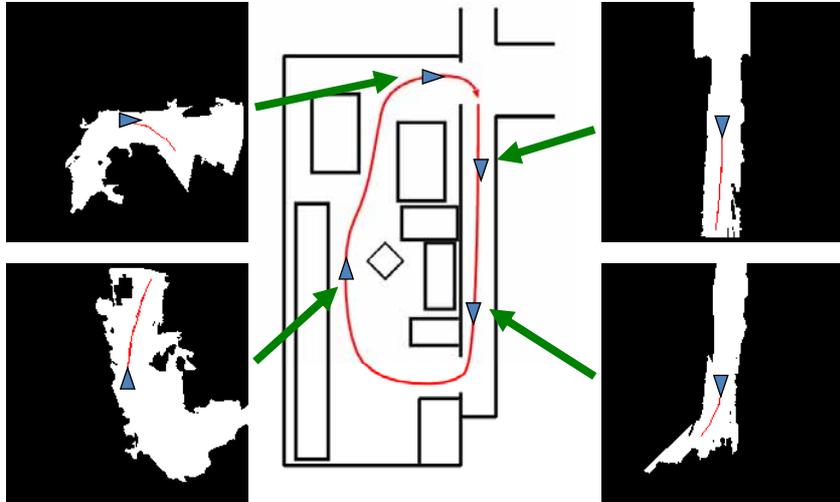
**Maximum speed**

$$v_{\max} = \frac{d}{NT}$$

## Experiment (real-time movie)



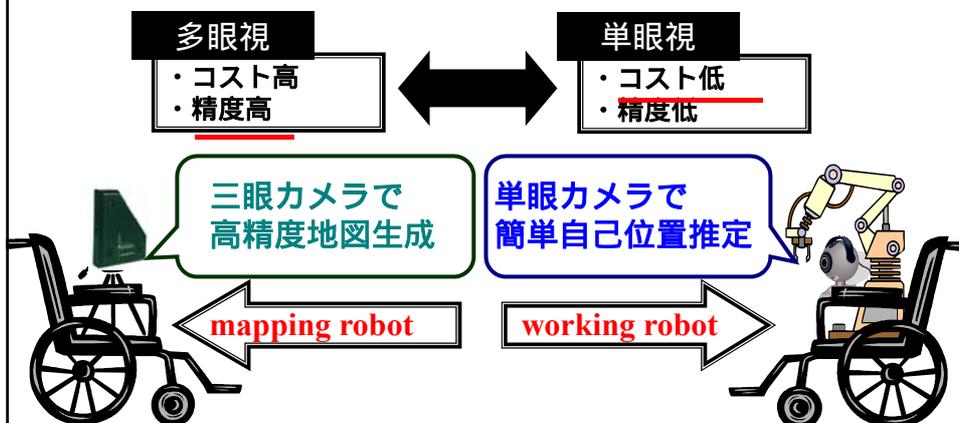
## Free space maps and planned paths



Moving distance: 30[m] in 45[sec] (maximum speed: 1[m/s])  
(without speed control, 150[sec])

## 環境地図生成とナビゲーション

三眼視によるロボットのナビゲーション + 単眼視によるロボットのナビゲーション



## 特徴点抽出

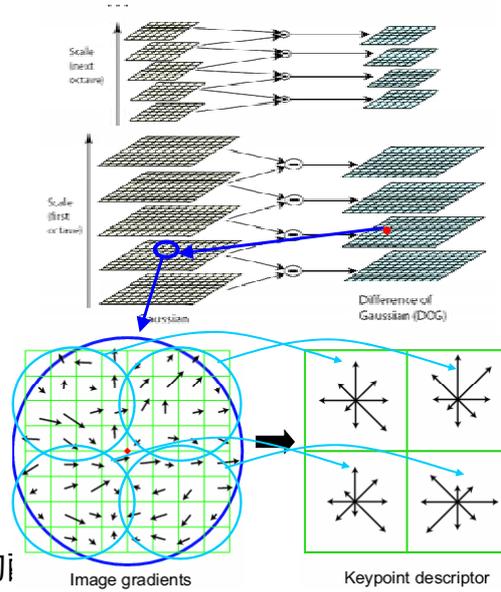
SIFT特徴

Scale  
Invariant  
Feature  
Transform

特徴点のパラメータ

- ・ 画像座標
- ・ スケール
- ・ コントラスト
- ・ SIFT特徴ベクトル

特徴ベクトルは周囲の輝度勾配



example : n=2

## ステレオ対応付け

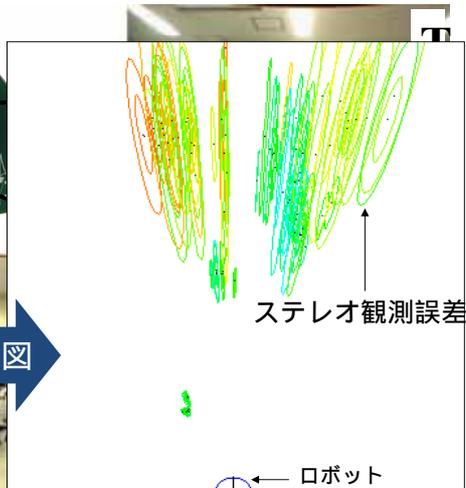
2枚の画像間でユニークな対応を見つける  
(T-R間 と R-L間)

水平・垂直共に対応が付いた点  
**stable keypoint**

地図に登録

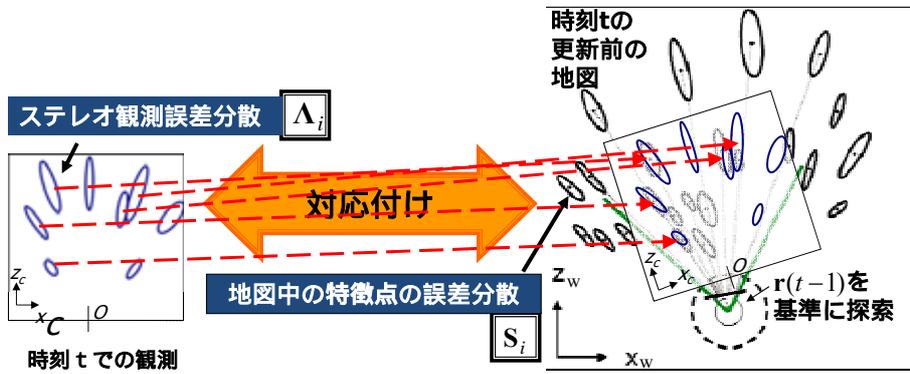


俯瞰図

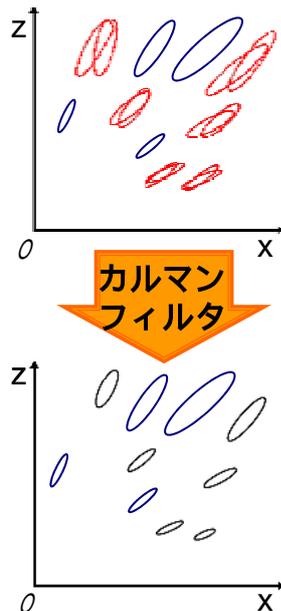


# 状態推定

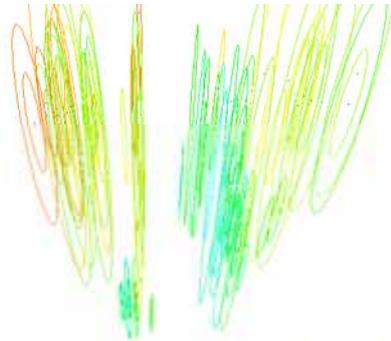
時刻 $t$ における状態  $r(t) = [X(t) Z(t) \sigma(t)]^T$  を推定する



# 地図の更新



## 地図生成結果



← 地図生成過程

High  
特徴点の高さ  
Low

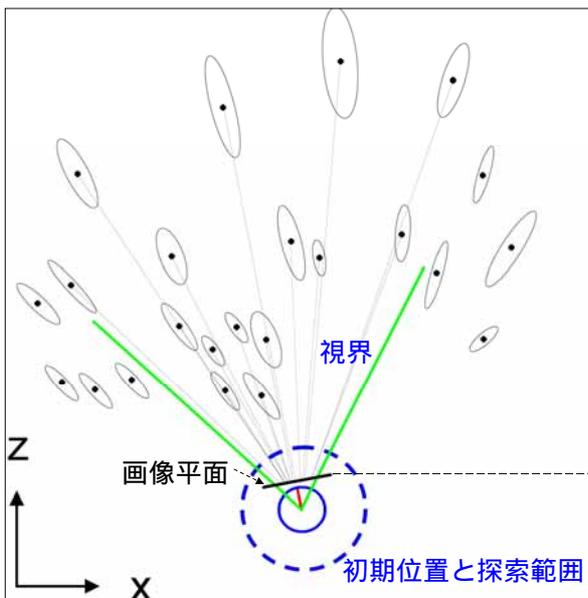


← 入力画像系列

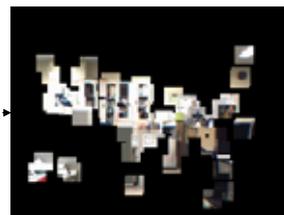
•: 地図と対応した点

+ : 新しく登録された点

## 自己位置推定では、特徴点の位置を予測



入力画像



再構成画像

## マッチングと状態推定



入力画像



再構成画像

- : 地図中のkeypointとマッチした点

画像平面上での誤差の2乗和を最小化



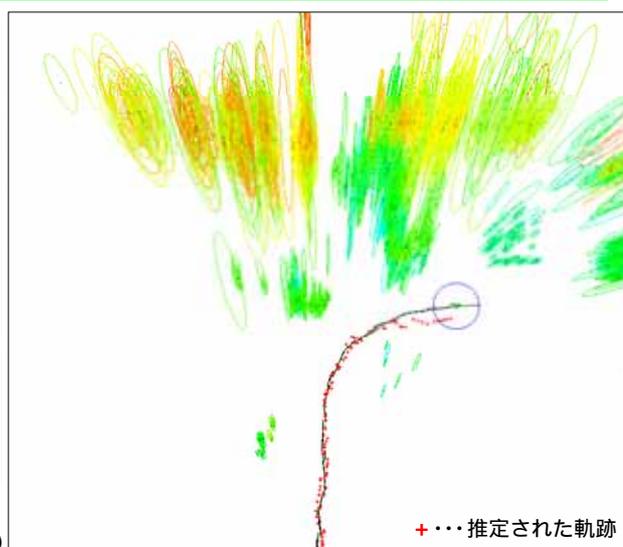
状態推定結果

## 状態推定シミュレーション

mapping時と別の画像シーケンスを入力



状態推定に要した時間  
**0.75** [sec/frame] (平均)



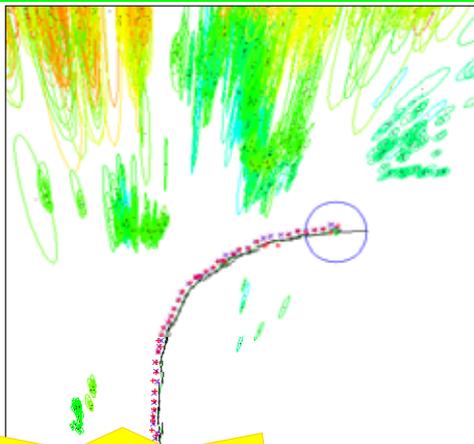
## 自己位置推定結果

mapping robotの左カメラのシーケンスを入力

	x[mm]	z[mm]	$\theta$ [deg]
誤差平均	-0.20	2.07	0.03
分散	157.63	795.04	0.13
標準偏差	<b>12.55</b>	<b>28.20</b>	<b>0.36</b>

### 探索範囲

-100 mm x +100 mm  
 -100 mm z +100 mm  
 - 10 deg  $\theta$  + 10 deg  
 (量子化幅...x:10mm, z:10mm,  $\theta$ :1deg)



状態推定に要した時間

**0.86** [sec/frame] (実時間実行には特徴点数が多すぎる)

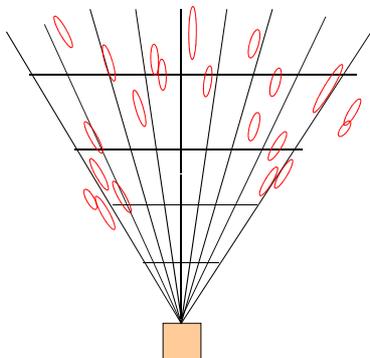
投影する特徴点数を減らす

## 投影する特徴点削減

視野空間をセグメンテーション

&それぞれの区画で代表点を選ぶ

**近い点** } は, ロボットの { **位置**  
**遠い点** } { **向き** を求めるのに有利



### 代表点の基準

観測回数が多い  
 コントラストが高い

画像平面に投影し,  
 入力画像とマッチング

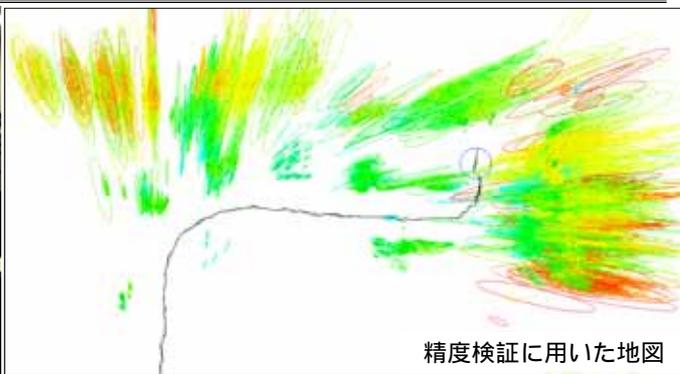
## 投影点削減効果



投影点を減らした場合

	x[mm]	z[mm]	$\phi$ [deg]
誤差平均	-1.90	-1.38	0.16
分散	863.41	713.43	1.38
標準偏差	<b>29.38</b>	<b>26.71</b>	<b>1.18</b>

処理時間 **0.37** [sec/frame]



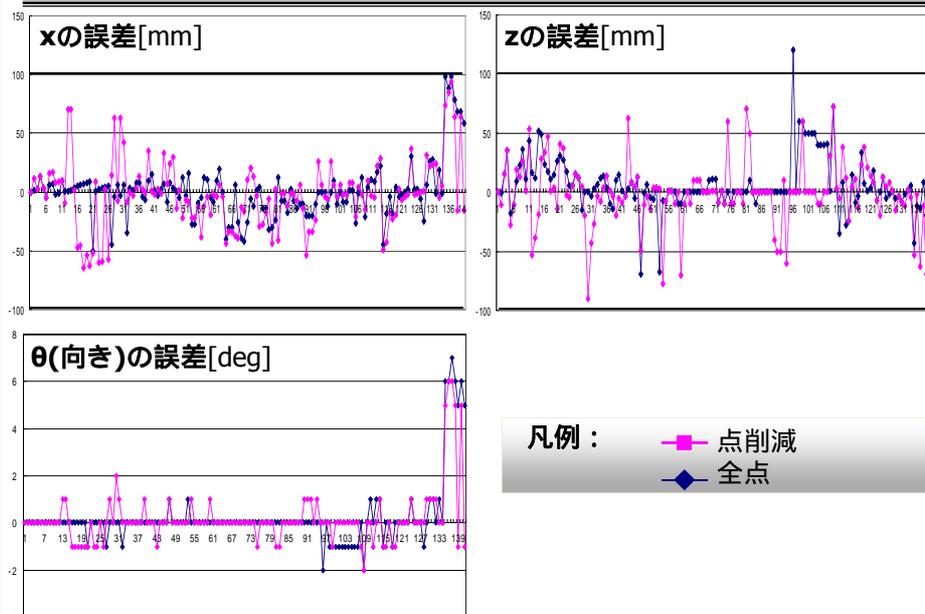
精度検証に用いた地図

全点を用いた場合

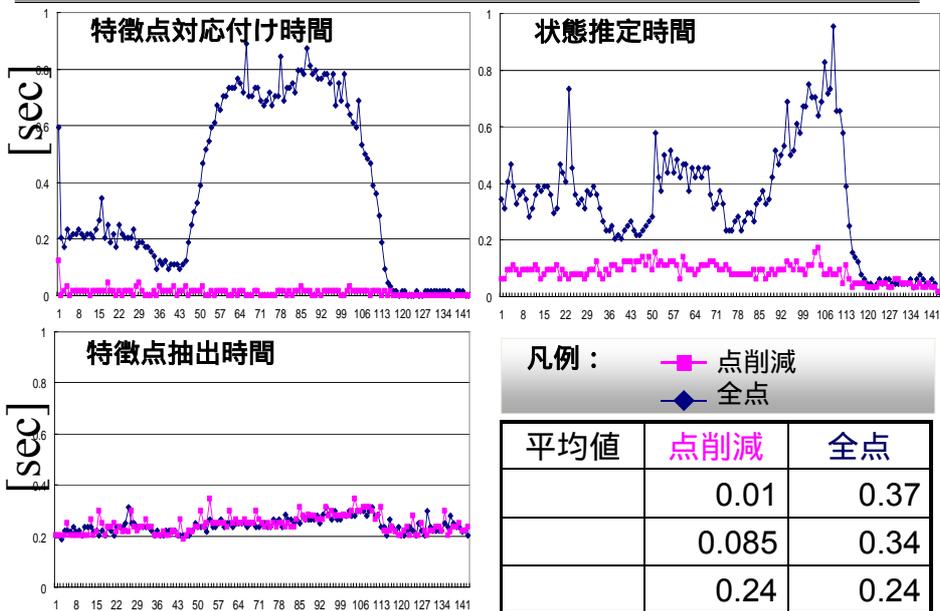
	x[mm]	z[mm]	$\phi$ [deg]
誤差平均	0.45	6.99	0.21
分散	558.06	575.12	1.96
標準偏差	<b>23.62</b>	<b>23.98</b>	<b>1.40</b>

処理時間 **0.98** [sec/frame]

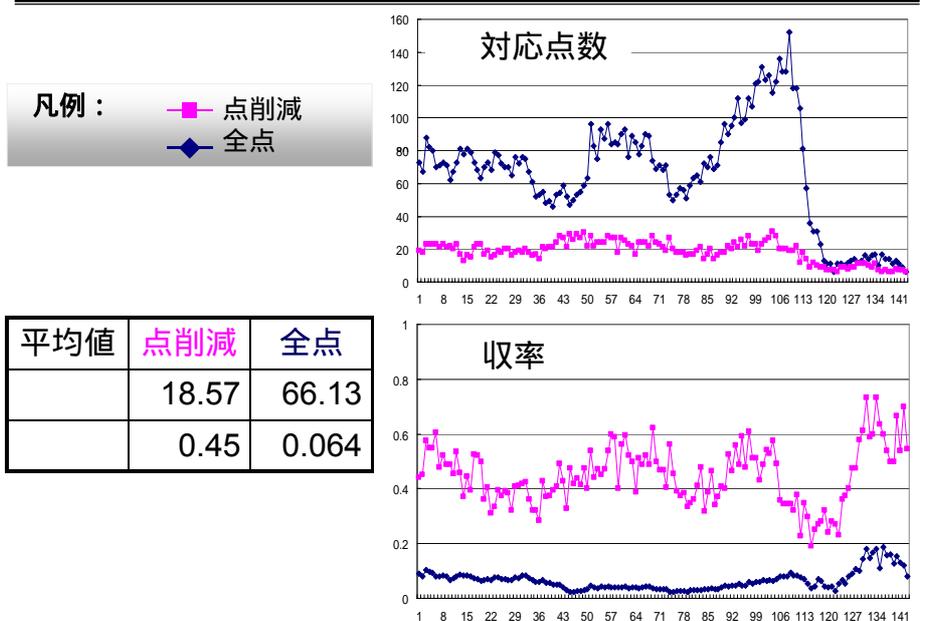
## 推定値と真値の誤差



## 投影点削減効果 ~処理時間~



## 投影点削減効果 ~対応点数と収率~

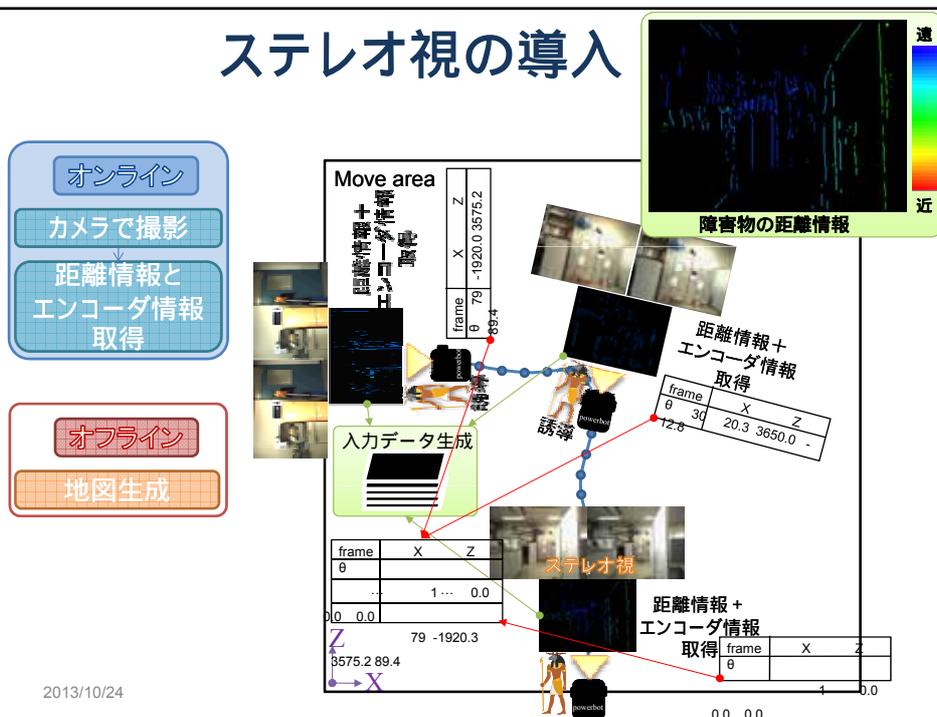


## 実機による走行実験結果



時間の都合上3倍速で再生

## ステレオ視の導入



# 生成される地図

- 障害物点の位置情報とその存在確率で表された地図

**正確な対応付け**

特徴点 理想の障害物点

左 カメラ 右

障害物点の位置情報

中心位置  $X$

誤差分散  $\Sigma$

ステレオ観測で画像間の対応が正しいときに取得した障害物点の位置  $X$  は不確かさ (誤差分散  $\Sigma$ ) が含まれるのでその誤差楕円は正規分布に従うとする

Map 存在確率

高 低

誤った障害物点の可能性あり

高信頼な障害物点

**誤った対応付け**

特徴点 得られた障害物点

左 カメラ 右

稀に対応付けが誤り未存在位置に障害物点を観測

左 右

障害物点が本当に存在するのかわ存在確率  $P$  で表現

$P$  が高いほど高信頼な障害物点となる

$P = 1 - P_s \quad (0 \leq P_s \leq 1)$

$P_s$ : 観測時における画像間の対応の誤り確率

# 自己位置の推定

$r_e(\cdot)$ : エンコーダによる  
ロボットの位置  $(x, z, \theta)$   
 $r(\cdot)$ : 自己位置推定後の  
ロボットの位置  $(x, z, \theta)$   
 $t$ : 時刻

- エンコーダ情報から自己位置を導出
- $\Delta r$  にもとづいて自己位置を修正

$$\Delta r = r_{(t-1)} - r_{e(t-1)}$$

$$r_{(t)} = r_{e(t)} + \Delta r$$

Map

エンコーダ情報により自己位置を導出  $r_e(t)$

ステレオ視により自己位置を推定  $r_{(t)}$

スタート地点  $(x, z, \theta) = (0, 0, 0)$

Map

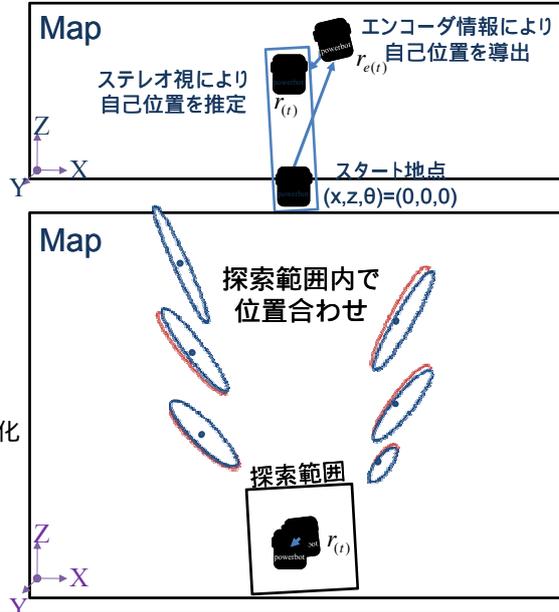
現在観測された障害物点

2013/10/24

## 自己位置の推定

$r_e(\cdot)$ : エンコーダによる  
 ロボットの位置  $(x, z, \theta)$   
 $r(\cdot)$ : 自己位置推定後の  
 ロボットの位置  $(x, z, \theta)$   
 $t$ : 時刻

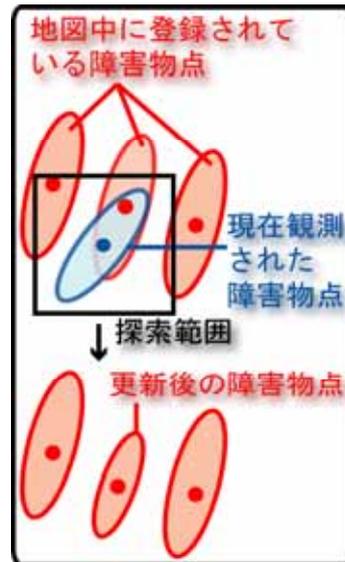
- エンコーダ情報から自己位置を導出
- $\Delta r$  にもとづいて自己位置を修正
- 探索範囲内で自己位置を推定
  - 地図を仮想的にボクセル化



## 地図の更新

現在観測された障害物点が  
 地図中に登録されている障害点と  
 同じ障害物点を表しているなら  
 それらを一つに統合して  
 地図を更新

- 対応点の探索
- 位置情報の更新
- 存在確率の更新



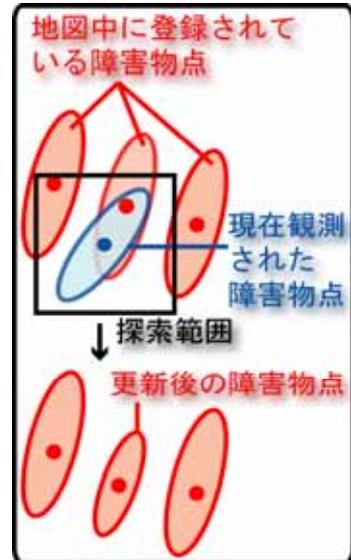
## 位置情報の更新

- 対応点が発見されれば障害物点の位置  $X$  と誤差分散  $\Sigma$  を存在確率  $P$  から最尤推定に基づき統合して更新

$$X = \frac{P_n \Sigma_n^{-1} X_n + P_m \Sigma_m^{-1} X_m}{P_n \Sigma_n^{-1} + P_m \Sigma_m^{-1}}$$

$$\Sigma = P_n \Sigma_n^{-1} + P_m \Sigma_m^{-1}$$

- $n$  : 現在観測された障害物点
- $m$  : 地図中に登録されている障害物点



2013/10/24

73

## 存在確率の更新

- 統合された障害物点
  - 障害物点の位置情報が統合されればその存在確率も更新

$$P = 1 - (1 - P_n)(1 - P_m)$$

- $n$  : 現在観測された障害物点
- $m$  : 地図中に登録されている障害物点

- 空き領域
  - 現在観測された障害物点における空き領域内に地図中に登録されている障害物点があればその存在確率を更新

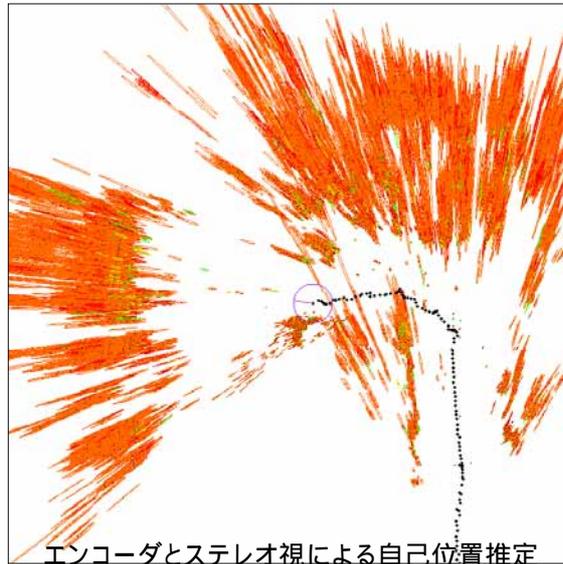
$$P = (1 - P_n)P_m$$



2013/10/24

74

## 生成された地図



2013/10/24

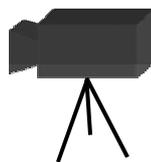
エンコーダとステレオ視による自己位置推定

## Real-time 3-D hand posture estimation from 2-D appearance

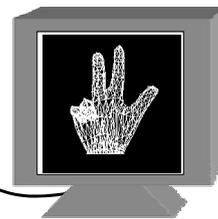
→ Gesture recognition for human interface



Input image

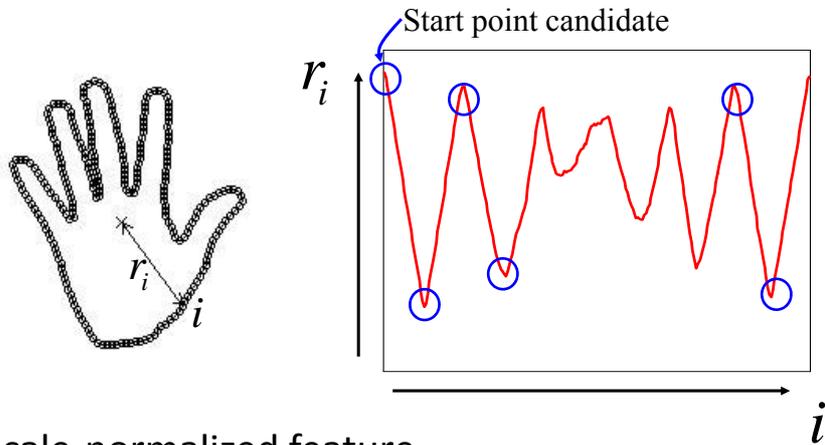


Camera



Estimation result

## Contour Feature Extraction



- Scale-normalized feature
- Multiple start points are tried

## Previous Approaches of Gesture Estimation

	3-D Model Fitting	Direct Image Matching
Single Image	Arbitrary postures High computation cost	Limited postures Low computation cost
Sequential Image	Motion constraints can be derived from the model	Motion constraint needs to be learned

## Real time processing

experimental  
environment



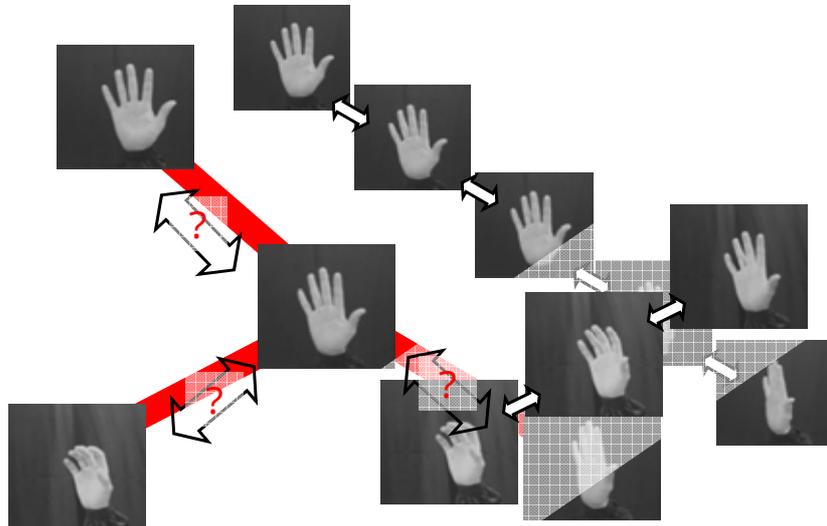
input image

result

## Previous Approaches of Gesture Estimation

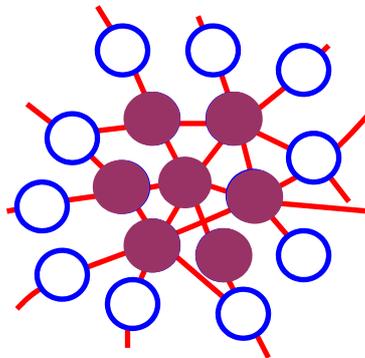
	3-D Model Fitting	Direct Image Matching
Single Image	Arbitrary postures High computation cost	Limited postures Low computation cost
Sequential Image	Motion constraints can be derived from the model	Motion constraint needs to be learned

## Learning of Shape Transition



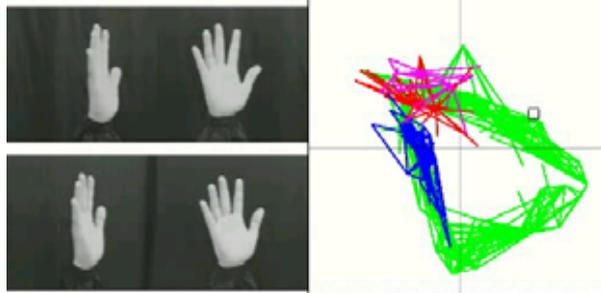
## Efficient Matching Using Transition Network

- Try only possible postures which are reached from the current posture

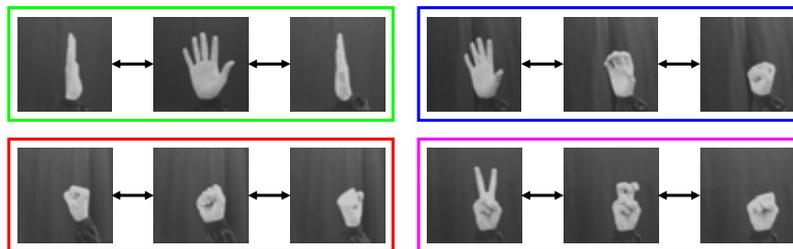


## Shape Estimation Result

Input image



Matched model

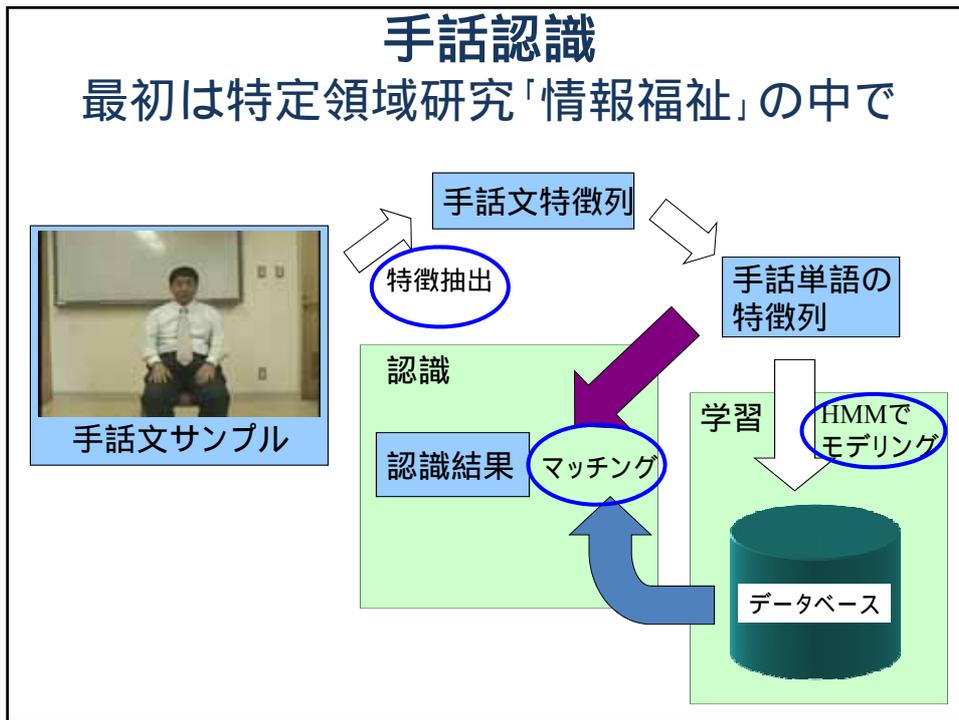


## Hand Shape Estimation under Complex Backgrounds for Sign Language Recognition

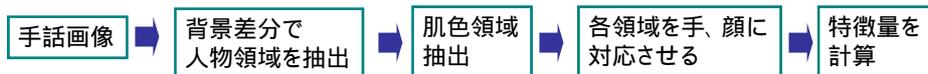


# 手話認識

最初は特定領域研究「情報福祉」の中で



# 特徴量抽出



隠蔽がある場合は、隠蔽前後の手・顔のテンプレートから各領域を決定



手話画像



人物領域

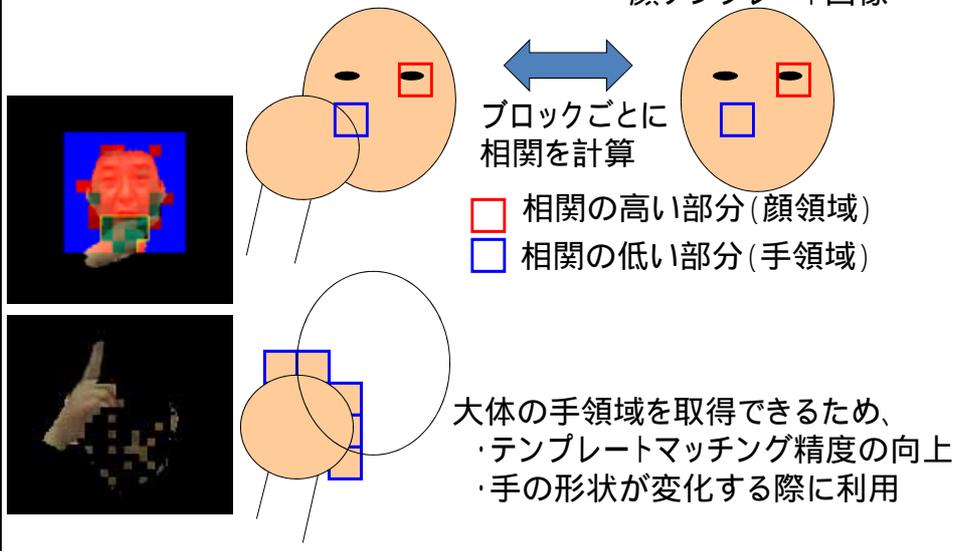


肌色領域

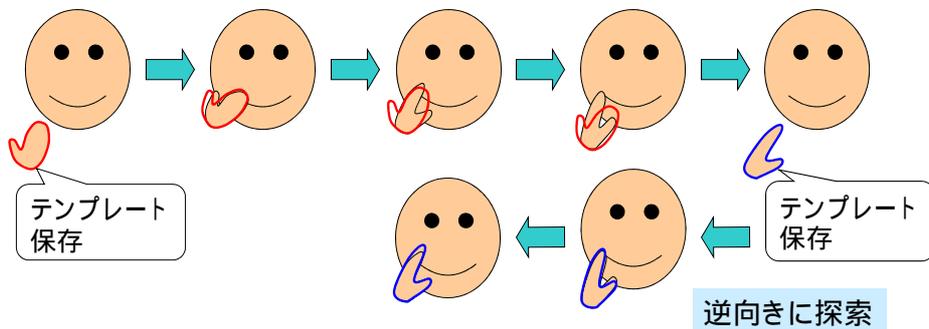
## 隠蔽時の処理

隠蔽状態の肌色領域

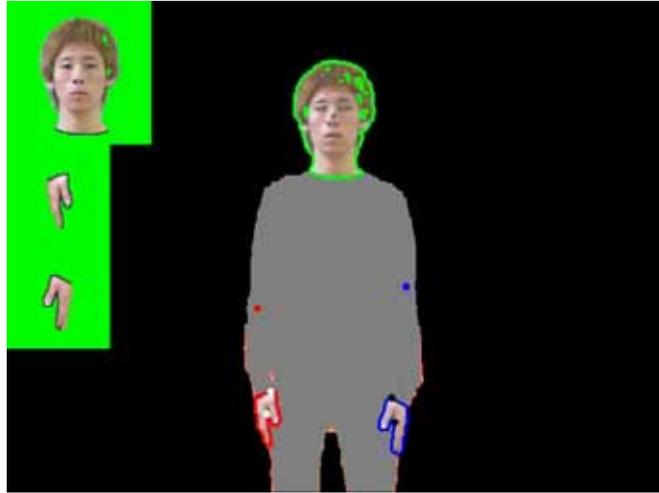
保存してある  
顔テンプレート画像



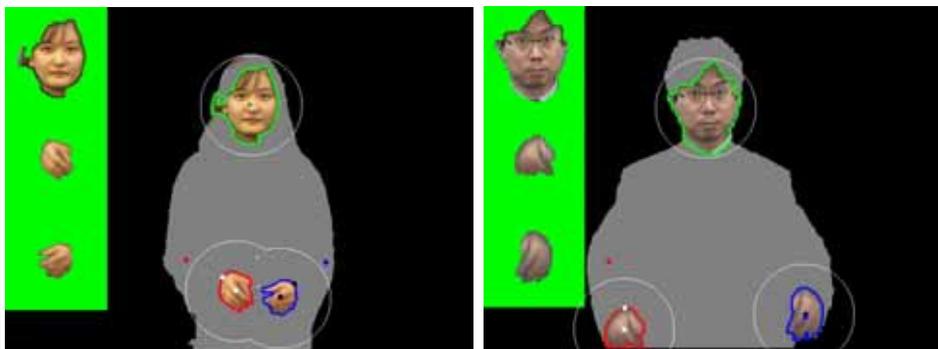
## テンプレートマッチングによる分離



## 画像処理の結果

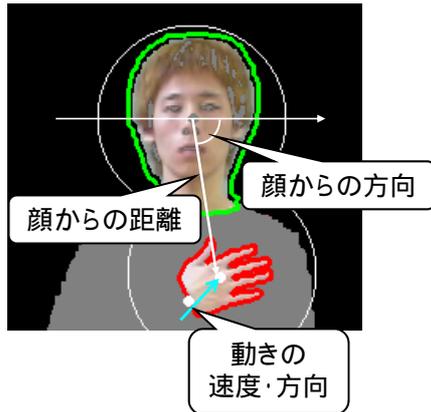


## 特徴抽出成功例

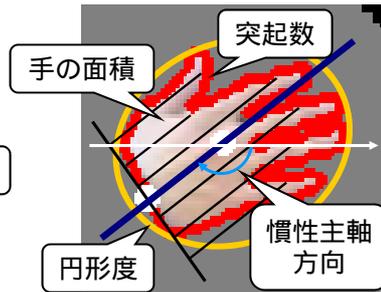


# 手話特徴量

## 位置に関する特徴量



## 形状に関する特徴量



## 改善結果1

### 右手と顔の隠蔽

改善後



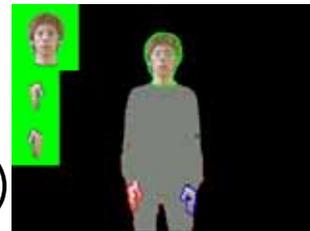
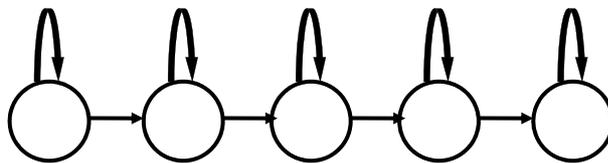
改善前



## 手話認識のための学習(HMM)

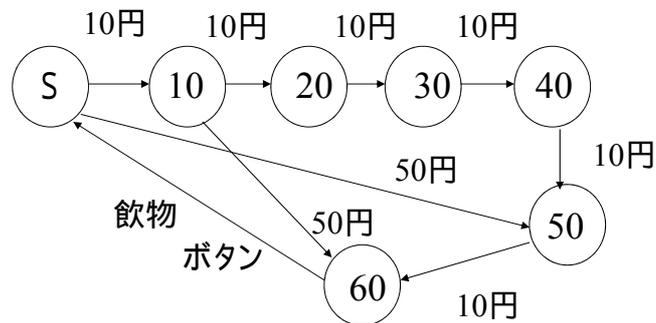
- HMMはLeft-to-Right
- 単語ごとに状態数を設定する必要がある
- 手の移動中、静止中、手の形を変化時に対して各々状態を1つ割り付ける

状態数決定の例(状態数:5)

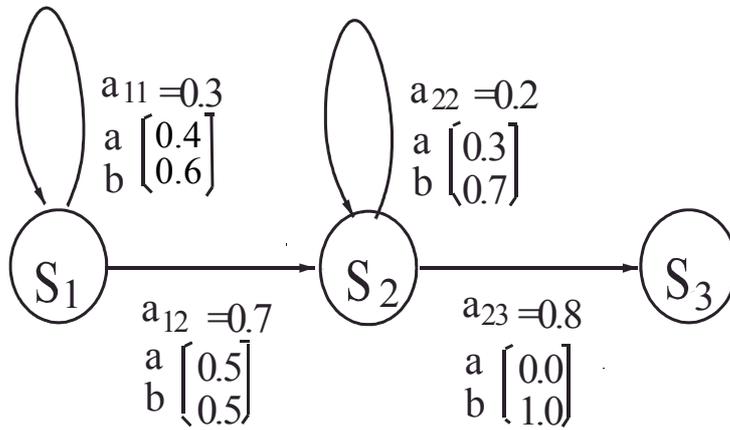


初期状態 移動中 静止中 移動中 最終状態

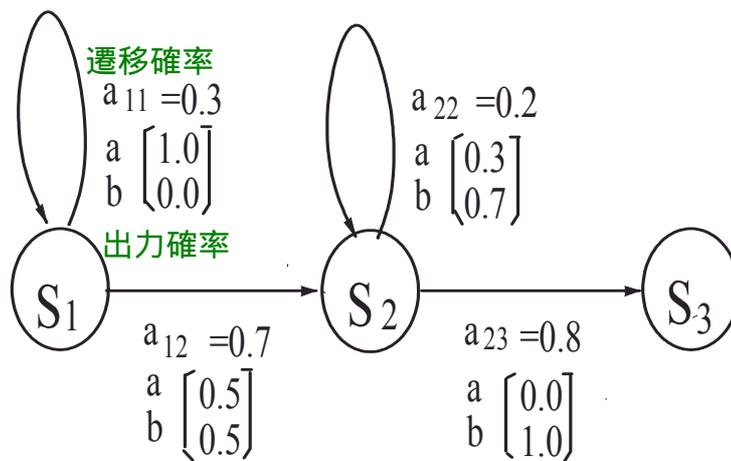
## 有限オートマトン



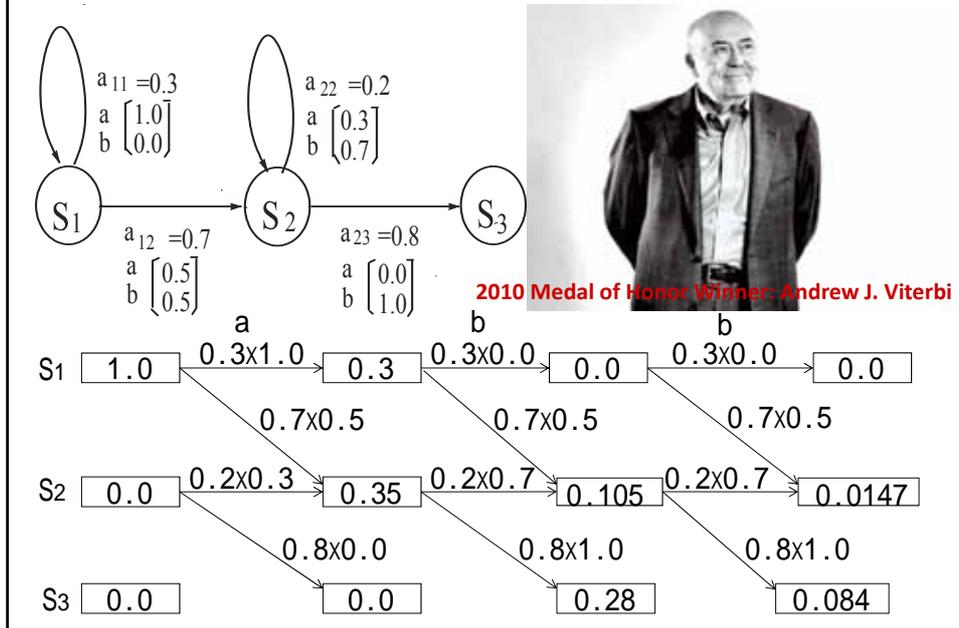
## 確率的オートマトン



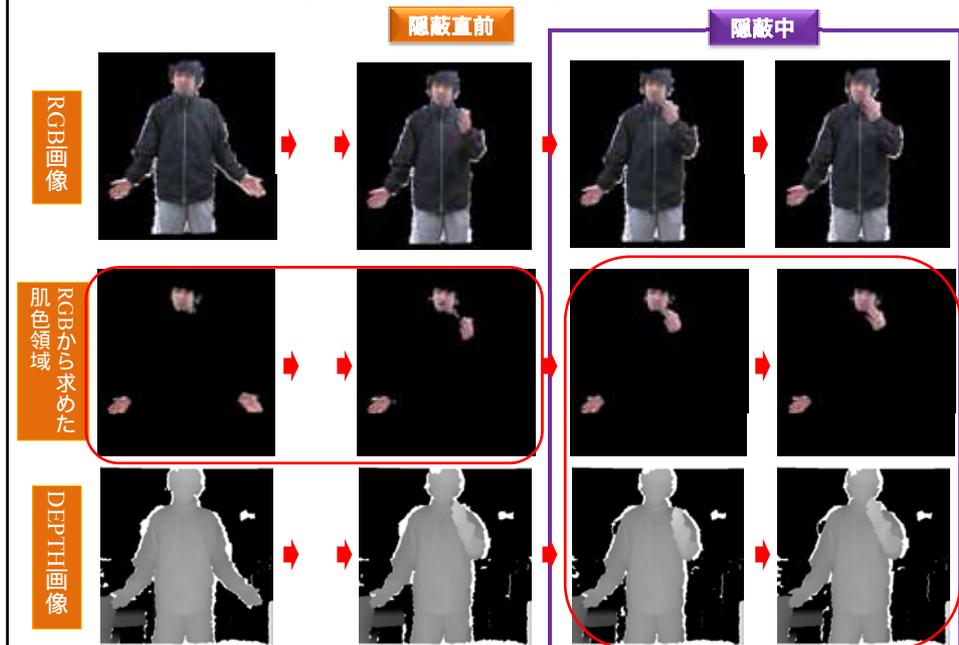
## HMMの例



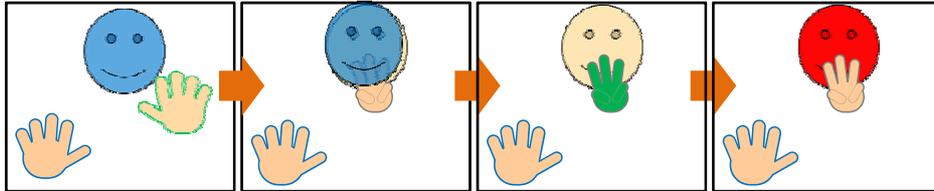
## Viterbiアルゴリズムのトレリス上での計算



## 距離情報を用いた隠蔽中の手指形状抽出



## 処理の概要



隠蔽前の顔の  
距離を記憶

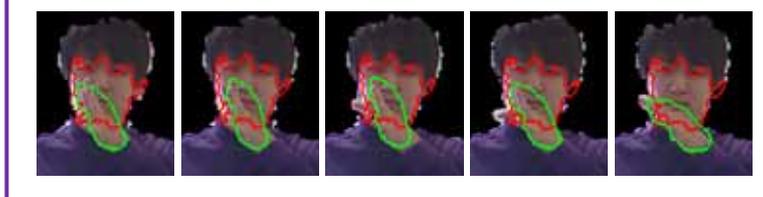
顔の距離テン  
プレートを照合

手領域抽出

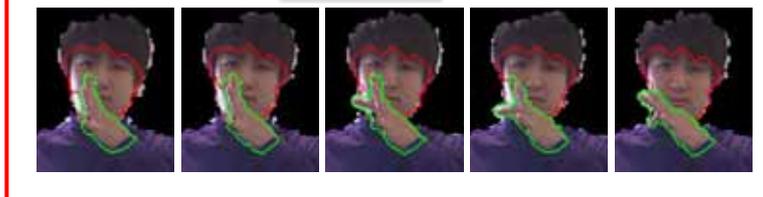
顔領域抽出

99

### 色情報のみ



### 提案手法



100

## コンピュータビジョンの今後

- 人間の視覚に迫る、夢を追う
  - 人の能力に近づける
    - 少数の例による学習
    - 生物に埋め込まれた能力
- 応用の拡大
  - 画像処理を部品として研究
  - マルチモーダル処理(インターネットから知識獲得)

## レポート課題

[shirai@ci.ritsumei.ac.jp](mailto:shirai@ci.ritsumei.ac.jp)

[www.i.ci.ritsumei.ac.jp/~shirai/](http://www.i.ci.ritsumei.ac.jp/~shirai/)

1. 講義した中で重要と思う技術を1つあげ、それを説明するとともに、なぜ重要化をできるだけ具体的に述べなさい。
2. 上記以外で、講義した中で自分の研究で応用してみたい技術を説明するとともに、どのような応用であるかをできるだけ具体的に述べなさい。なお、現在の研究でなく、将来行いたい研究あるいは仕事でもかまわない。
3. 講義の感想、講義以外で聴きたかったこと、及び来年の講義に参考になることを簡単に述べなさい。