

# さりげなく作業支援を行う映像メディア Video-Based Interactive Media for Gently Giving Instructions

小阪 拓也<sup>†</sup>  
Takuya Kosaka

中村 裕一<sup>‡</sup>  
Yuichi Nakamura

大田 友一<sup>†</sup>  
Yuichi Ohta

亀田 能成<sup>†</sup>  
Yoshinari Kameda

## 1. はじめに

料理やプラモデルの組み立てのような作業を行っている場合、何をすべきかわからないといったことがしばしば起こる。そのような場合、もし熟練した人間の先生がいたならば、そのユーザの状況を判断して、状況に適したわかりやすい説明をしてくれるだろう。

本研究では、「さりげなく作業支援を行う映像メディア」を提案する。従来の「電子マニュアル」とは異なり、ユーザの状態に合わせた情報を提示してくれること、次に何をするかという主導権がユーザにあることが本研究の特徴である。現在は簡単な机上作業である、ブロックの組み付け作業を対象として研究を進めている。

## 2. さりげなく作業支援を行う映像メディア

本研究で必要な要素技術は以下の4つである。図1にその関係を示す。

1. 教示映像へのインデキシング
2. 物体とユーザの動作の認識
3. ユーザの現在の作業状況の推定
4. ユーザの作業状況に関連した情報の提示

このうち教示映像へのインデキシングについては既に我々はQEVICO[1]で提案している。物体と動作の認識は、現在のところ簡単な認識処理によって行っている段階であるが、物体追跡に関する研究[2]の研究成果を利用する予定である。

一方、ユーザの現在の作業状況の推定部分については、検出した物体と、教示映像中のインデクスとを対応付けることで実現する。その際にユーザにできるだけ干渉しないように、可能な限りシステム内部で処理し、ユーザの状況が不明になった場合にのみ、ユーザに問い合わせる。これにより、ユーザの作業や思考を邪魔せずに作業支援することをめざす。以降、本稿では上記2-4の要素について述べる。

## 3. ユーザの作業状況の推定

### 3.1 定義と記述方法

まず、以下のような概念を定義する。

作業: 教示の目標である。タスクの集合により記述する。

タスク: 目的とした作業を達成するために行う動作。タスクは一連のアクションと関連する物体で構成される。本稿では、基本的な動作である「移動」「組み付け」の2種類を想定している。

アクション: 画像処理による認識に対応したプリミティブな動作を指す。本稿では、「持ち上げる」「置く」「(物体同士が)接触する」を想定している。各アクションは、ID、動作名、関連する物体で記述する。

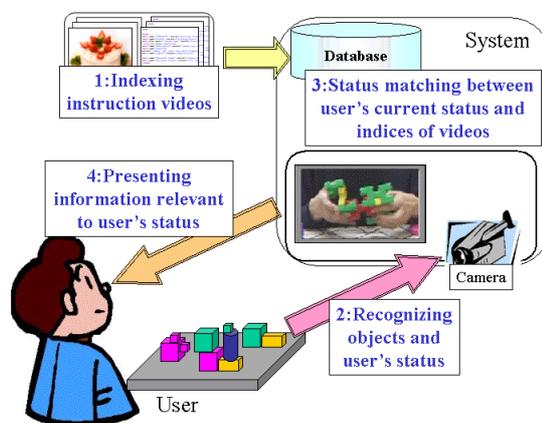


図 1: システムの概要

物体: 動作の対象となる具体的形状をもつもの。ID, 画像特徴(色, 形等)で記述する。

### 3.2 ユーザの現在の作業状況の推定

ユーザの作業状況の推定方法の概要を示す。

- (a) 教示映像のインデキシング情報を読み込み、作業のタスクと物体に関する情報を予め取得する。
- (b) ユーザが何らかのアクションを行った場合、アクションと関連する物体の情報を時系列順に記録する。
- (c) (a)と(b)を照合することで、ユーザの現在の作業状況を推定する。その際の照合には以下の類似度を用いる。

物体の類似度  $S(O_i, O_j)$ : 色や形状等の画像特徴に基づく。本稿では、物体領域の色ヒストグラムを比較することで、類似度を求めている。

アクションの類似度  $T(A_i, A_j)$ : 動作名の類似度と関係する物体の類似度の積で計算する。アクション  $A_i(N_i, O_{i1}, O_{i2}, \dots, O_{in})$  と、アクション  $A_j(N_j, O_{j1}, O_{j2}, \dots, O_{jn})$  との類似度  $T(A_i, A_j)$  は以下の式で求められる。ここで、 $N_i$  は動作名、 $O_{ik}$  は関連する物体を意味する。

$$T(A_i, A_j) = \delta(N_i, N_j) \left( \prod_{k=1}^n S(O_{ik}, O_{jk}) \right)^{\frac{1}{n}} \quad (1)$$

$$\delta(X, Y) = \begin{cases} 1 & (X = Y) \\ 0 & (X \neq Y) \end{cases} \quad (2)$$

作業状況の推定は、以下で述べる部分探索と全探索の組合せで実施される。

部分探索: システムは、教示映像中のタスクと対応するユーザの一連のアクションを探す。その際、DPマッチングを適用することで、教示映像に記録されたとおりに行動していない場合でも、柔軟に対応す

<sup>†</sup>筑波大学 大学院 システム情報学研究所

<sup>‡</sup>京都大学 学術情報メディアセンター

る。この処理では、対応付けられる全ての可能性を  
求める。

全探索: タスクの一貫性を考慮に入れることで、起  
こりうる一連のタスクを推定する。本研究では、部分  
探索の結果を基に深さ優先探索を行うことで、起  
こりうるタスクの組み合わせを求める。

### 3.3 画像処理によるユーザ動作の認識

ユーザのアクションは物体に対して行われるため、把  
持物体の状態を追跡することで、ユーザのアクションを  
認識する。

フレーム間差分とテンプレートマッチングで求められ  
た領域を動領域とし、動領域から肌色部分を除いた領域  
を物体領域とする。

各アクションの認識方法を以下に示す。

持ち上げる: 物体領域の中心座標が一定の高さよりも  
高くなった場合に認識する。

接触する: 二つの物体領域の中心座標が一定の高さよ  
りも高く、さらにそれらの距離が接近している場合  
に認識する。

置く: 物体領域の中心座標が一定の高さよりも低くな  
った場合に認識する。

## 4. ユーザへの問い合わせ

ユーザの個々のアクションや物体の対応付けには常に  
曖昧性があるため、全探索の際、当てはまるタスクの組  
み合わせの数が爆発的に大きくなるという問題がある。

そこで本研究では、ユーザへの問い合わせにより曖昧  
性の解消を図る。まず、システムは最も曖昧な部分を調  
べる。その際、教示映像中の物体やタスクと対応付けら  
れた数が曖昧性を示す一つの指標となる。そして、曖昧  
性が一定の閾値を超えた場合において、物体やタスクの  
名前を問い合わせる。ユーザからの回答を反映させるこ  
とで、現場の物体/タスクと教示映像中の物体/タスクと  
を正しく対応付けることができ、曖昧性を大幅に削減す  
ることができる。

## 5. 実験

本システムの有効性を示すために、簡単な実験を行っ  
た。まず、アクションの認識精度、部分探索によるタスク  
の認識精度を調べた。組み立て作業の例として、ブロッ  
クを組み付けて「車」を作るという作業を対象とした。  
その作業は、50個の物体と30のタスクで構成される。

画像認識の結果、ユーザが全ての作業を終えるまでの  
間に、70のユーザのアクションを検出することができた  
が、50パーセントのアクションは誤検出であった。

次に、画像認識の結果が正しく行われたものとして、  
作業状況の推定を行ったところ、図2に示されるような  
precision recall グラフを得た。このグラフは、部分探索  
の際の類似度の評価について、照合されたかどうかを判  
断するための閾値を変化させて得たものである。

また、ユーザとのインタラクションにより、解釈の曖  
昧性を減らす方法の有効性を調べた。図3は、検出され  
た幾つかの物体とそれに対応付けられた物体の個数を示  
す。Num(1)は曖昧性を減らす以前の結果である。ID9の  
物体は19個の解釈候補があり、最も曖昧性の高い物体で

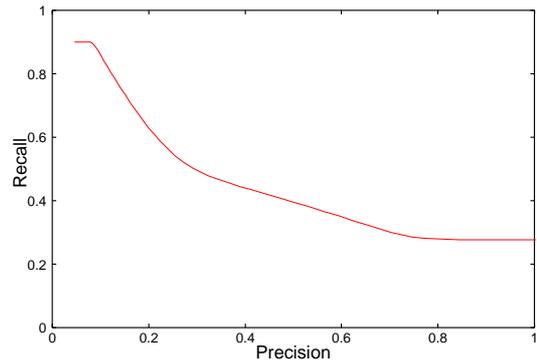


図 2: Precision recall グラフ

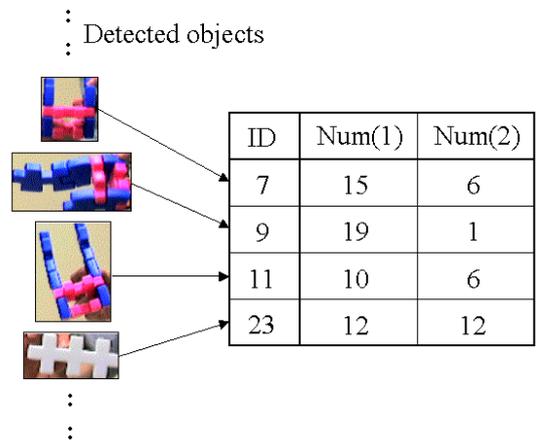


図 3: 対応付けられた物体の数

ある。ユーザに問い合わせることで、システムは物体同  
士の正しい対応付けを得て、その結果、図3の Num(2)  
に示される改善結果を得ることができた。

## 6. おわりに

本稿では「さりげなく作業支援を行う映像メディア」  
を提案した。ユーザの状態を認識するための枠組、また  
ユーザに問い合わせることで曖昧性を減らす方法につい  
て述べた。今後の課題は、物体追跡システムと組み合わ  
せることで物体認識の精度を高める、また実際にユーザ  
がリアルタイムで利用できるシステムを構築することだ  
である。

## 参考文献

- [1] H.IZUNO, et al: QUEVICO:A Framework for Video-Based Interactive Media. Proc. Int'l Workshop on Intelligent Media Technology for Communicative Reality (2002) pp.6-11.
- [2] M.ITOH, et al: Simple and Robust Tracking of Hands and Objects for Video-based Multimedia Production. IEEE Conf. on MFI (2003) pp.252-257.