

科学研究費助成事業 研究成果報告書

平成 26 年 6 月 19 日現在

機関番号：14501

研究種目：基盤研究(B)

研究期間：2011～2013

課題番号：23300038

研究課題名(和文) 機械学習の枠組みに基づく映像検索システムの再構築

研究課題名(英文) Video Retrieval System based on Machine Learning

研究代表者

上原 邦昭 (Uehara, Kuniaki)

神戸大学・システム情報学研究科・教授

研究者番号：60160206

交付決定額(研究期間全体)：(直接経費) 15,600,000円、(間接経費) 4,680,000円

研究成果の概要(和文)：映像例示型検索(QBE: Query By Example)は、クエリとして与えられた映像から、色、エッジ、動きなどの特徴量に基づいて、クエリに適合する映像としない映像を識別するための分類器を構築する機械学習の問題とみなせる。そこで、事例、特徴量、学習アルゴリズム、データ量といった機械学習の観点からQBEの改良に取り組んだ。最終的に、大規模な映像データから、クエリに適合する映像を高速かつ高精度に検索可能な手法を開発した。さらに、開発手法を物体認識に応用して、米国NIST主催の世界的な映像解析コンテストTRECVID 2012において、世界最高精度を達成することに成功した。

研究成果の概要(英文)：Query-By-Example (QBE) can be considered as a machine learning problem. Here, given videos for a query, a classifier is built to discriminate between relevant and irrelevant videos based on features like color, edge and motion. This research has explored QBE from the perspectives of machine learning, such as training examples, features, learning algorithms and data size. As a result, we have developed a fast and accurate method which can retrieve videos relevant to a query from a large amount of video data. Furthermore, by applying the developed method to object recognition, we have achieved the highest performance at TRECVID 2012 that is a NIST-sponsored annual worldwide competition on video analysis.

研究分野：総合領域

科研費の分科・細目：情報学 メディア情報学・データベース

キーワード：マルチメディア 機械学習 映像データ 映像検索

1. 研究開始当初の背景

本研究では、QBE (Query By Example) と呼ばれる映像検索技術に焦点を当てる。QBE は、ショットそのものを与えてクエリを表現し、色、エッジ、動きなどの特徴量に基づいて、与えられたショットと類似したショットを検索する手法である。一方、QBE は与えられたショットとの類似度に基づく検索モデル(分類器)を学習するという観点から、機械学習における“例からの学習”と考えることができる。しかしながら、QBE に機械学習のアプローチを応用するためには、事例数、特徴量、学習アルゴリズム、データ量など、様々な問題が山積している。本研究では、これらの問題点を検討して、革新的な QBE を開発することを目標としている。

2. 研究の目的

(1) 事例の曖昧、不確実性：ショットは様々な撮影技法・状況下で撮影されるため、クエリの条件を満たすショットでも、特徴量(見た目)が大きく異なってくる。ゆえに、ショットは、非常に曖昧、不確実な事例であると言える。そこで、“ラフ集合理論”を用いて、曖昧、不確実なデータから、クエリの条件を満たすショットの部分集合を特定可能な、できる限り一般性のあるルール(分類器)を抽出する。

(2) 類似度計測の困難さ：機械学習手法を QBE に応用する際、事例間の類似度計測が非常に重要になる。ここで、映像から抽出される特徴量は非常に高次元である。高次元特徴量を用いた場合、分類に不適切な次元の影響で、事例間の類似度を適切に測れなくなる。そこで、線形計画問題に基づく事例間の最適マッチング、類似尺度の学習、高次元データに有効な分類器に基づく類似度算出などのアプローチについて検討する。

(3) 過学習問題：汎化性の高い分類器を学習するためには、一般に次元数の 10 倍以上の事例が必要である。しかしながら、QBE では、ユーザがクエリとして与えることができるショット数はせいぜい数十個程度である。そのため、少数の事例だけからは、高次元特徴量における有用な統計情報は得られず、分類器が、意図するクエリとは無関係な次元に過剰に適合してしまう“過学習”が問題となる。そこで、“ランダムサブスペース法”という、高次元特徴量からランダムに次元を選択して学習された複数の分類器を組み合わせる手法を用いる。これにより、各分類器の学習では、多数の次元を削減した低次元特徴量が用いられるため、過学習の危険性を軽減できる。

(4) 負例の欠如：分類器の学習には、クエリに適合するショットの例としないショットの例が必要になる。以後、前者を“正例”、後者を“負例”と呼ぶ。QBE では、ユーザから与えられたショットが正例となるが、負例は与えられない。そこで、正例以外のショッ

トを“ラベルなし事例”と見なして、正例とラベルなし事例から分類器を学習する“部分教師つき学習”として QBE を定式化する。

(5) 不均衡問題：負例には、クエリに適合しないあらゆるショットが含まれる。そのため、ユーザが収集可能な正例数が数十個であるのに対して、部分教師つき学習によってラベルなし事例から収集される負例数は数千、数万個になる。この場合、正例数と負例数の大きな偏りから、汎化性の高い分類器が学習できない“不均衡問題”が生じる。そこで、“バギング”という、ランダムに選択された事例から学習された複数の分類器を組み合わせる手法を用いる。すなわち、正例数と負例数に偏りがないように分類器を学習して、不均衡問題を回避する。

(6) 大規模データに対するスケーラビリティ：映像データ検索には、機械学習手法の分類精度と実行速度という2種類のスケーラビリティが重要になってくる。まず、分類精度に関して、一般に検索対象となる映像の本数、ジャンル数が増えれば、特徴量の観点から類似しても、クエリに適合しない分類困難なショットの数が増えてくる。ゆえに、分類精度の評価には、大規模なベンチマークデータが必須である。そこで、NIST 主催のワークショップ TRECVID で使用されている、ベンチマークデータ(838 本の映像、約 240GB)を用いる。実行速度に関しては、行列演算を用いて、多数の事例間の類似度を一括して計算することにより、機械学習アルゴリズムを高速化させる。

3. 研究の方法

平成 23 年度は、「(1) 事例の曖昧、不確実性」に対してラフ集合理論、「(2) 類似度計測の困難さ」に対して分類器に基づく類似度算出、「(3) 過学習問題」に対してランダムサブスペース法、「(5) 不均衡問題」に対してバギングを用いて、これら 4 つの問題を解決し、QBE のプロトタイプを構築した。

まず、ラフ集合理論では、ルールの構成要素となる識別特徴量をいかにして決定するかという点が重要である。このため、映像から抽出される特徴量の高次元性を考慮して、“分類器ベースのアプローチ”を採用した。具体的には、各特徴量ごとに、高次元データに対する汎化性の高い分類器として知られている SVM を構築する。そして、事例間の類似度を、それらが SVM によって同じクラスに分類されるかどうかによって計測するようにした。最終的に、このような SVM の分類結果を識別特徴量として、正例の部分集合と負例の全集合を正確に分類可能な識別特徴量(SVM)の組み合わせルールを抽出するラフ集合理論を開発した。

上記の分類器ベースのアプローチでは、不均衡問題と過学習問題を解決する必要がある。不均衡問題の原因は、少数の正例に対して、一度に大量の負例を使用することにある

ため、妥当な数の負例をサンプリングして SVM を学習すれば解決できる。しかし、大量の負例の一部だけしか考慮していないため、SVM を組み合わせても多数の不適切なショットが誤って検索されてしまう。そこで、バギングを用いて、正例と負例をランダムに選択して、多数の SVM を学習し、ラフ集合理論を用いてそれらを組み合わせるルールを抽出する手法を開発した。

過学習問題の原因は、高次元特徴量の全ての次元を用いて SVM を学習することにあるため、高次元特徴量を低次元特徴量に変換すれば解決できる。ただし、学習に用いる事例数が少なすぎるため、主成分分析やフィッシャー判別分析のような、事例の分布に依存した手法は有効ではない。そこで、ランダムサブスペース法を用いて、高次元特徴量をランダムにサンプリングした次元からなる低次元特徴量に変換し、SVM を学習する手法を開発した。ただし、1 回のランダムサンプリングでは、有用な次元を見落としてしまう可能性があるため、複数回のランダムサンプリングを行って複数の低次元特徴量を得て、それぞれに対して SVM を学習している。これにより、過学習問題を回避しながら、ラフ集合理論により SVM を組み合わせれば、多数の次元を考慮したルールを抽出できる。また、使用する次元によって SVM の分類境界が変わってくるため、バギング同様、ランダムサブスペース法は、抽出されるルールのバリエーションを増やし、多様なショットを網羅的に検索するためにも有効である。

平成 24 年度は、「(4) 負例の欠如」に対して、与えられた正例に基づいて、データベース中のショットから、高精度な検索に有用な負例を収集するための部分教師つき学習手法を開発した。具体的には、クエリに適合するショットとしないショットの境界を明確に定義するために、以下の 2 段階フィルタリングにより、「正例に類似しているが、クエリに適合しないショット」を負例として収集する手法を開発した。まず、1 段階目のフィルタリングでは、特徴量に関して、正例と明らかに類似していないショットを排除する。そして、2 段階目のフィルタリングでは、物体認識技術を用いて、正例と類似した物体が認識されているショットはクエリに適合する可能性が高いとして排除する。このようにして、有用な負例を適切に選別・収集することにより、検索精度が向上するだけでなく、検索時間も短縮できるようになる。

平成 25 年度は、「(6) 大規模データに対するスケーラビリティ」に対して、行列演算に基づいて、事例間の類似度を一括して計算して、高速に SVM を学習・テストする手法を開発した。具体的には、従来は、各事例、各次元ごとにループを繰り返して計算していたユークリッド距離計算に関して、事例を列ごとに並べた行列から、各要素が 2 つの事例間のユークリッド距離を表す行列を一括して

計算できるようにしている。

また、高精度な SVM を学習するためには、ショット中の様々な位置、時間（フレーム）に映し出される意味内容を表現可能な特徴量が必要になってくる。そこで、大量の局所領域に対する確率密度を一括して計算し、高速に特徴量を抽出する手法を開発した。概要としては、多次元正規分布の確率密度計算が重み付きのユークリッド距離計算に帰着できることに着目して、上記の高速なユークリッド距離計算手法を拡張した。

4. 研究成果

まず、平成 23 年度に開発した、バギングとランダムサブスペース法を導入したラフ集合理論の性能評価を行う。実験には、TRECVID 2009 の映像データを用いた。このデータは、219 本の訓練用映像（36,106 ショット）と 619 本のテスト用映像（97,150 ショット）から構成されている。そして、5 つのクエリに関する検索性能を評価した。各クエリに対する検索は、訓練用映像から、正例と負例を選択し、ラフ集合理論を用いてルールを抽出する。そして、抽出されたルールを用いて、テスト用映像を検索した。

バギングとランダムサブスペース法を導入したラフ集合理論の有効性を評価するために、以下の 4 種類の検索手法を比較した。(1) Baseline : SVM による検索である。各特徴量ごとに、全ての正例と負例、次元を使用して、合計 6 個の SVM を構築する。そして、各 SVM ごとに、評価値の高い上位 1,000 ショットを検索結果とする。その後、最も性能の高かった SVM を最終的な検索結果として採用する。

(2) RST_only : ラフ集合理論だけを用いた検索である。全ての正例と負例、次元を用いて、1 つの特徴量につき 1 個の SVM を構築し、ルールを抽出する。

(3) RST+BG : ラフ集合理論にバギングだけを組み合わせた検索である。1 つの特徴量につき、正例の 75%、負例の 75%をランダムに選択して、3 個の SVM を構築している。

(4) RST+BG+RS : ラフ集合理論、バギング、ランダムサブスペース法を組み合わせた検索である。1 つの特徴量につき、正例の 75%、負例の 75%、及び全次元の 50%をランダムに選択して、10 個の SVM を構築している。

表 1 の各要素の数値は、検索結果に含まれていた、クエリに適合するショット（正解ショット）の数を表している。特に、一般性を求めるため、10 回の検索結果における正解ショット数の平均を表している。ここで、Baseline よりも多くの正解ショットを検索できたことを太字で表している。RST_only は、クエリ 1 とクエリ 4 で Baseline よりも検索性能が低く、有効であるとは言いがたい。一方、RST+BG と RST+BG+RS は、全てのクエリにおいて Baseline よりも性能が高い。ここで、RST_only、RST+BG、RST+BG+RS に関して、上

から2つ目の斜体の数値は、ラフ集合理論により抽出されたルールを表しているが、RST_only に比べて、RST+BG、RST+BG+RS では多数のルールが抽出されている。ゆえに、バギング、ランダムサブスペース法を用いて SVM のバリエーションを増やすことは、異なる撮影技法・状況で撮影された多様なショットを検索するために有用であることが分かる。また、RST+BG と RST+BG+RS を比べると、正解ショット数に大差はない。ただし、それぞれの行の上から3つ目の数値で表されている AP (Average Precision: 正解ショットが検索結果の上位にランク付けされているかを表す指標) に関して、クエリ 4 以外で、RST+BG+RS の平均精度が明らかに高い。すなわち、RST+BG+RS の方が検索性能は優れていると言える。

表 1: バギング、ランダムサブスペース法を導入したラフ集合理論の性能評価

	クエリ 1	クエリ 2	クエリ 3
Baseline	136.3	102.2	151.1
RST_only	135.4 (6.5) (0.0637)	115.9 (5.9) (0.1571)	154.5 (6.6) (0.0694)
RST+BG	143.9 (154.9) (0.0669)	137.3 (185.3) (0.1805)	161.4 (159.8) (0.0713)
RST+BG+RS	140.6 (4238.7) (0.0705)	145.3 (2216.2) (0.1961)	164.3 (2165.5) (0.0739)

	クエリ 4	クエリ 5
Baseline	39.6	154.8
RST_only	26.8 (4.4) (0.0059)	168.9 (6.6) (0.0492)
RST+BG	40.3 (125.8) (0.0148)	188.3 (329.5) (0.0499)
RST+BG+RS	41.5 (2073.4) (0.0146)	189.9 (8851) (0.0541)

平成 24 年度に開発した、部分教師つき学習を用いた負例収集手法の有効性を評価するために、以下の実験を行った。まず、TRECVID 2009 の映像データを対象として、9 個のクエリに対する検索を行った。開発手法により収集された負例の有効性を検証するために、以下の3つの手法を比較した。

- (1) All: データベース中の全てのショットを負例とみなして、検索モデル (SVM) を構築する。
- (2) PSL: 開発手法により収集された負例を用いて、SVM を構築する。
- (3) Random: データベースの中から、ランダムに選択されたショットを負例として SVM を構築する。ここで、PSL と Random で用いている負例数は同一である。




図 1: All、PSL、Random による負例を用いた検索性能の比較

図 1 に、All、PSL、Random によって収集された負例を用いた検索性能の比較結果を示す。ここで、検索性能 (縦軸) は AP で評価している。さらに、PSL と Random はランダム性を伴うため、一般性を求めるため、10 回の検索結果を箱ひげ図の形式で示している。各クエリ名の下に、正例数、All で収集された負例数、PSL で収集された負例数を示している。全てのクエリに関して、PSL の AP が、All や Random より高いことが分かる。また、箱ひげ図の高さで表される AP の分散も、PSL の AP の分散は Random よりも大幅に小さい。ゆえに、PSL によって収集された負例は、高精度な検索結果を安定して得るために有用であると言える。




図 2: All、PSL、Random の検索時間の比較

図 2 に All、PSL、Random による検索時間の比較結果を棒グラフ形式で示す。クエリごとに、All、PSL、Random の検索時間をそれぞれ赤、緑、青の棒で示している。All に比べて、PSL の検索時間が非常に短いことが分かる。ゆえに、PSL によって、少数の有用な負例を選択すれば、高精度な SVM を短時間で構築できると言える。

平成 25 年度に開発した、行列演算に基づく SVM の学習・テスト手法 SVM_{mat} の高速性を検証するために、行列演算を用いずに事例間の類似度を1つずつ計算するベースライン手法 SVM_{base} と比較した。ここで、TRECVID 2012 で提供された、19,700 本の学習用映像 (400, 238 ショット)、8,263 本のテスト用映像 (145,634 ショット) を実験データとしてい

る。そして、 SVM_{mat} 、 SVM_{base} とともに、30,000 ショットの同一の学習例集合を用いて、図 3 のグラフの下に太字で示された物体（もしくは、情景）を認識するため SVM を学習・テストしている。さらに、両者ともに、CPU が Intel Xeon X5690 (3.47 GHz) の計算機上で動かし

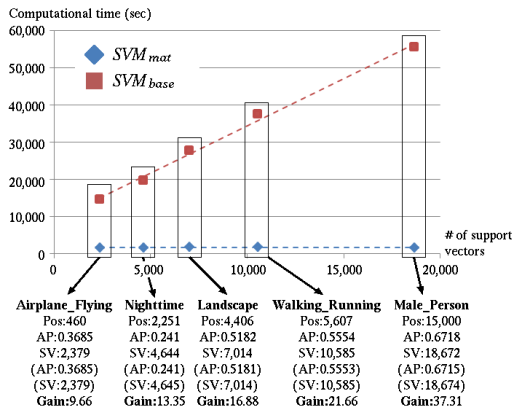


図 3: SVM_{mat} と SVM_{base} の計算時間の比較

図 3 では、 SVM_{base} の計算時間がサポートベクトル (SV) 数に比例することに基づいて、横軸を SV 数、縦軸を計算時間としている。ここで、SV は、SVM の学習の結果、分類に必要であると判定された学習例のことで、 SVM_{base} では、テスト時は SV とテスト例との類似度のみを計算している。ひし形が SVM_{mat} 、四角が SVM_{base} の計算時間を表している。点線は、 SVM_{mat} と SVM_{base} の計算時間の变化を直線近似したものである。理論通り、 SVM_{base} の計算時間は SV 数に比例して増大する一方、 SVM_{mat} の計算時間は SV 数によらず、ほぼ一定である。これは、 SVM_{mat} では、学習例が SV であるかどうかに関わらず、常に全 30,000 個の学習例とテスト例との類似度を計算していることによる。もちろん、SV である学習例のみと類似度を計算するようにすれば、さらなる高速化が見込める。

同一の物体（もしくは、情景）に対する SVM_{mat} と SVM_{base} の計算時間を四角で囲っている。そして、グラフの下に、認識結果を示している。ここで、1 行目が物体の名称、2 行目が正例数、3、4 行目が SVM_{mat} による AP と抽出された SV 数、5、6 行目が SVM_{base} による AP と SV 数、7 行目が SVM_{mat} と SVM_{base} の計算時間の比率を表している。SVM の学習時に有効数字以下の誤差が蓄積されるため、 SVM_{mat} と SVM_{base} で微妙に結果が異なっているが (AP にして最大 0.0003、SV 数にして最大 2 個)、ほぼ同一とみなせる。このことと SVM_{mat} と SVM_{base} の計算時間の比率から、両者は同一の精度で、かつ SVM_{mat} の学習・テストは約 10 倍から 37 倍高速である。これは、行列演算に基づいて類似度を一括して計算することの有効性を示している。

図 4 に、行列演算に基づいて局所領域に対

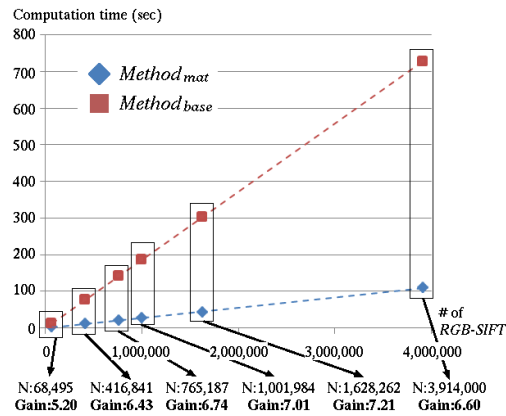


図 4: $Method_{mat}$ と $Method_{base}$ の計算時間の比較

する確率密度を一括して計算して特徴量を抽出する手法 $Method_{mat}$ と、確率密度を 1 つずつ計算する手法 $Method_{base}$ の計算時間の比較結果を示す。横軸が確率密度を計算した局所領域の数、縦軸が計算時間を表しており、ひし形、四角がそれぞれ $Method_{mat}$ 、 $Method_{base}$ の計算時間である。点線は、計算時間の变化を直線近似したものである。また、同一ショットに対する計算時間は四角で囲んでおり、グラフの下に、局所領域数 (1 行目) $Method_{mat}$ と $Method_{base}$ の計算時間の比率 (2 行目) を示している。 $Method_{mat}$ は、 $Method_{base}$ よりも約 5 倍から 7 倍高速であることが分かる。

最後に、上記の高速な SVM 学習・テスト手法、及び高速な特徴量抽出手法を応用して、TRECVID 2012 Semantic INDEXING (SIN) 部門に参加した。SIN では、例えば「人」、「車」、「建物」といった、人間にとって意味のある概念を自動認識することを目的としている。




図 5: TRECVID 2012 SIN (light) 部門で開発された手法のランキング

図 5 の棒グラフは、SIN (light) 部門での本手法の認識精度 (MAP) を表している。1 本の棒が 1 つの手法の認識精度を表し、我々の手法は白抜きの棒で示している。本研究で開発した手法が、世界 25 機関で開発された全 91 手法中、最高精度を達成していることが分かる。これは、上記の高速化手法により、他の研究機関よりも、多くの学習例を用いて高精度な SVM を学習できたこと、及び多くの局所領域を考慮して精巧な特徴量を抽出できたことによるものである。

5. 主な発表論文等

[雑誌論文](計5件)

Kimiaki Shirahama, Yuta Matsuoka and Kuniaki Uehara: Hybrid Negative Example Selection Using Visual and Conceptual Features, Multimedia Tools and Applications, 査読有(採録決定), DOI: 10.1007/s11042-011-0886-y

白浜公章, 上原邦昭: 行列演算に基づく高速かつ厳密な大規模映像データ処理, 映像情報メディア学会誌, 査読有, Vol.67, No.7, pp.J241-J251, 2013, DOI: <http://dx.doi.org/10.3169/itej.67.J241>

白浜公章, 松岡悠太, 上原邦昭: ラフ集合理論を用いたクエリの帰納的定義に基づく例示映像検索, 映像情報メディア学会誌, 査読有, Vol.66, No.5, pp.J124-J135, 2012, DOI: <http://dx.doi.org/10.3169/itej.66.J124>

Kimiaki Shirahama and Kuniaki Uehara: Constructing and Utilizing Video Ontology for Accurate and Fast Retrieval, International Journal of Multimedia Data Engineering and Management (IJMDEM), 査読有, Vol.2, No.4, pp.59-75, 2011, DOI: 10.4018/jmdem.2011100104

Kimiaki Shirahama, Yuta Matsuoka and Kuniaki Uehara: Event Retrieval in Video Archives Using Rough Set Theory and Partially Supervised Learning, Multimedia Tools and Applications, 査読有, Vol.57, No.1, pp.145-173, 2011, DOI: 10.1007/s11042-011-0727-z

[学会発表](計10件)

Kimiaki Shirahama, Chen Li, Marcin Grzegorzec, Kuniaki Uehara: University of Siegen, Kobe University, and Muroran Institute of Technology at TRECVID 2013 Multimedia Event Detection, TREC Video Retrieval Evaluation (TRECVID) 2013 Workshop, November 21, 2013, Maryland, US

Kimiaki Shirahama, Kenji Kumabuchi and Kuniaki Uehara: Video Retrieval by Learning Uncertainties in Concept Detection from Imbalanced Annotation Data, The Fifth International Conferences on Advances in Multimedia (MMEDIA 2013), April 22, 2013, Venice, Italy

Kimiaki Shirahama and Kuniaki Uehara: Kobe University and Muroran Institute of Technology at TRECVID 2012 Semantic Indexing Task, TREC Video Retrieval Evaluation (TRECVID) 2012 Workshop, November 26, 2012, Maryland, US

Kimiaki Shirahama, Kuniaki Uehara and Marcin Grzegorzec: Examining the Applicability of Virtual Reality

Technique for Video Retrieval, The 10th Workshop on Content-Based Multimedia Indexing (CBMI 2012), June 29, 2012, Annecy France

Kimiaki Shirahama, Kenji Kumabuchi and Kuniaki Uehara: Video Retrieval by Managing Uncertainty in Concept Detection using Dempster-Shafer Theory, The Fourth International Conferences on Advances in Multimedia (MMEDIA 2012), May 1, 2011, Chamonix / Mont Blanc, France

Kimiaki Shirahama, Lin Yanpeng and Kuniaki Uehara: Kobe University at TRECVID 2011 Semantic Indexing and Multimedia Event Detection, TREC Video Retrieval Evaluation (TRECVID) 2011 Workshop, December 6, Maryland, US

Kimiaki Shirahama and Kuniaki Uehara: Utilizing Video Ontology for Fast and Accurate Query-by-Example Retrieval, The IEEE International Workshop on Semantic Multimedia in conjunction with the Fifth IEEE International Conference on Semantic Computing (ICSC-SMM 2011), September 21, 2011, California, US

Kimiaki Shirahama and Kuniaki Uehara: Effectiveness of Video Ontology in Query by Example Approach, The Seventh International Conference on Active Media Technology (AMT 2011), September 7, 2011, Lanzhou, China

[その他]

TRECVID 2012 で開発した物体認識手法の詳細は、以下のNISTサイトで公開されている。(意味インデキシング部門の概要、及び各研究機関で開発された手法の順位)

<http://www-nlpir.nist.gov/projects/tvpubs/tv12.slides/tv12.sin.slides.pdf>

(開発した物体認識手法に関する論文)

<http://www-nlpir.nist.gov/projects/tvpubs/tv12.papers/kobe-muroran.pdf>

(開発した物体認識手法に関する講演資料)

<http://www-nlpir.nist.gov/projects/tvpubs/tv12.slides/tv12.kobe-muroran.sin.slides.pdf>

6. 研究組織

(1) 研究代表者

上原 邦昭 (UEHARA, Kuniaki)

神戸大学・システム情報学研究科・教授

研究者番号: 60160206

(2) 研究分担者

白浜 公章 (SHIRAHAMA, Kimiaki)

日本学術振興会・海外特別研究員

研究者番号: 30467675