

知的情報処理特論 レポート

学籍番号 T15M080

氏名 平田健人

講義日 5月14日

4.4.環境の変化によるリアルタイム適応行動選択

さらなる実験として、ロボットに見せるオブジェクトを変えて行動の変化を確認する。アプローチとしては、クロスモーダルメモリ検索と時系列予測の組み合わせである。周期的に、ロボットの各関節角度に対する目標指令として予測関節角度を使うことで、ロボットが環境の変化に応じて動作する。最初の試行として、入力画像に対して、ロボットが適切に表示されたオブジェクトに応じて行動を選択することを確認した。画像特徴ベクトルの信頼性は環境の照明条件に影響されることわかった。そこで、色領域分割と、知覚安定性のある色プロブの重心の座標を使用した。その結果、提示されたオブジェクトに基づいて複数の動作を切り替えることに成功した。図 8 はある動作からある動作への移行を示した写真である。

4.5.マルチモーダル特徴空間の可視化

図 9 は、取得したマルチモーダル特徴に対して主成分分析を行い、第 3 主成分までの結果を三次元の散布図で示している。マルチモーダル特徴ベクトルは、時系列学習ネットワークのトレーニングデータを認識し、中央の中間層の活性化を記録することによって生成される。特徴空間は、異なるオブジェクト操作の動作と特徴ベクトルに自己組織化されている複数のクラスタによって分割される。複数の行動を学習させると、取得したマルチモーダル特徴と行動のカテゴリとの対応関係をモデル化することができ、これがマルチモーダル特徴空間の構造である。

4.6.マルチモーダル特徴を使用して行動認識性能を評価する

取得したマルチモーダル特徴を使って行動認識タスクのロバスト性にどのように寄与するかを検討する。学習の枠組みでは、生の感覚入力が見覚特徴に変換され、感覚特徴の複数のソースはオートエンコーダの次元圧縮関数を利用してマルチモーダル特徴を生成するために一緒に統合される。より高レベルの特徴であるマルチモーダル特徴を使用することは、行動認識タスクで、次の 2 つの効果が期待できる。(1)圧縮された表現は汎化能力が高いため、ノイズの多い感覚入力に対する分類性能を向上させることができる。(2)複数のマルチ

な表現を統合すると、一つのモダリティの信頼性が低くても他のモダリティが補ってくれるので信頼性の低下を補完することができ分類性能の低下を抑制することができる。

これを検証するために、6種類のオブジェクト操作の行動に対応する関節角度テストシーケンスを用いて、異なるトレーニング条件下で動作判別メカニズムのノイズ耐性を評価した。具体的には、関節角度配列にガウス雑音を重畳し、標準偏差の違いに応じて行動認識率の変化を比較する。次元圧縮と高レベルの特徴であるマルチモーダル特徴の影響を調べるために、以下の4つの異なるトレーニング条件下で分類器の性能を比較した。

(1a)MTN(生)：生の関節角度を入力として使用する。

(1b)MTN(圧縮)：関節角度特徴ベクトルを入力として使用する。特徴ベクトルはオートエンコーダを利用して関節角度配列を圧縮することによって生成される。

(2a)MTN(圧縮) + IMG：マルチモーダル特徴ベクトルを入力として使用する。特徴ベクトルは、関節角度配列と時系列学習ネットワークを利用し、対応する画像特徴配列を圧縮することによって生成される。画像特徴配列は、テストデータから取得したクリーンな画像配列を圧縮することによって生成される。

(2b)MTN(圧縮) + IMG(仮想)：マルチモーダル特徴ベクトルを入力として使用する。この場合、画像特徴配列は、外部で生成されたテストデータの代わりに、ネットワーク内部で自己生成される。

ケース(1a)を除いたトレーニング条件としては、統計的に10回複製された学習結果で評価される。

圧縮された特徴ベクトル配列は時系列ネットワークの中央の中間層の活性化パターンを記録することによって取得される。優れた汎化能力を持つ最も人気のある分類アルゴリズムの一つとして、サポートベクターマシン(SVM)がある。SVMで使う関数としてはRBFカーネルとSequential Minimal Optimizer(SMO)というものがある。

図10は、関節角度シーケンスにガウス雑音を重畳した標準偏差の変化に応じた行動認識率の変化を示す。結果として、行動認識タスクに対して高レベルの特徴を利用すると三つの点に着目できる。まず、(1a)と(1b)の結果を比較すると、行動認識のロバスト性は生の関節角度より圧縮された関節角度特徴の方が優れた性能を示している。第二に、(1b)と(2a)の結果を比較すると、マルチモーダル特徴は関節角度の信頼性の低下に起因する悪影響を抑制できており、単一なモード特徴よりマルチモーダル特徴の方が優れている。第三に、(1b)と(2b)の結果を比較すると、関節角度モダリティが唯一の入力として提供される場合であっても、画像特徴のための自己生成配列がある方が低下を防止している。これらの結果より、生画像の圧縮と複数の入力を統合することでロバスト性が高くなることがわかった。

補足資料

図 8 :

表示されるオブジェクトの変化に応じてオブジェクト操作挙動のリアルタイム移行; 動作の変更は、ロープウェイ、ベルリング R、ベルリング L の順に表示される。

図 9 :

取得されたマルチモーダル特徴空間; PC1、PC2、PC3 と軸は、1、2、3 に対応する。

図 10 :

標準偏差の変化に応じて行動認識率 σ 関節角度配列に重畳ガウス雑音、関節角の振幅は 0 ~1 の範囲に正規化される。平均および標準偏差が 10 レプリケート学習実験から計算される。

・ロバスト性

ロバスト性またはロバストネスとは、ある系が応力や環境の変化といった外乱の影響によって変化することを阻止する内的な仕組み、または性質のこと。

・サポートベクターマシン(SVM)

サポートベクターマシン(SVM)は、教師あり学習を用いるパターン認識モデルの一つである。識別や回帰分析へ適用できる。サポートベクターマシンは、現在知られている手法の中でも認識性能が優れた学習モデルの一つである。サポートベクターマシンが優れた認識性能を発揮することができる理由は、未学習データに対して高い識別性能を得るための工夫があるためである。サポートベクターマシンの特徴の一つは、解きたい問題に応じてカーネルを適切に選び汎化能力を向上できることです。実際、問題の種類に応じて様々なカーネルが開発されています。

・RBF カーネル(ラジアル基底関数カーネル)

ラジアル基底関数(RBF, radial basis function)カーネルはデータに関する事前知識がない場合に用いられる汎用的なカーネル。最もよく用いられるカーネルの一つ。

・Sequential Minimal Optimizer(逐次最小問題最適化法)

逐次最小問題最適化法(SMO, Sequential Minimal Optimizer)はサポートベクターマシン(SVM)の訓練で生じる 2 次計画問題を解くためのアルゴリズム。