最新コンピュータビジョンの実利用を目指して

岐阜大学工学部 電気電子・情報工学科情報コース 加藤研究室

Kato Laboratory, Informatics Course, Department of Electrical, Electronic and Computer Engineering,
Faculty of Engineering, Gifu University

〒501-1193 岐阜市柳戸 1-1 准教授 加藤邦人

TEL : 058-293-2756

URL : <http://www.cv.info.gifu-u.ac.jp>

E-mail : kkato@gifu-u.ac.jp

1. 研究室内の概要

岐阜大学工学部 電気電子・情報工学科情報コース 加藤研究室は、加藤邦人准教授と学部生 10 名、修士課程 7 人、博士課程 2 名で構成されており、研究にイベントに、パワフルかつアクティブな研究室です (図 1)。

私たちの研究室では、「コンピュータビジョン」についてさまざまな研究を行っています。コンピュータビジョンは、画像認識技術であり、「コンピュータの眼を実現しよう」という研究分野です。最近ではディープラーニング技術の発展により、非常に注目されています。

私たちの研究室でもディープラーニングを用いたコンピュータビジョンの研究に取り組んでいます。ディープラーニングが日本で本格的に注目を集め始めたのは、2014 年ごろだと思います。私たちの研究室では、その技術のすごさ、革新性に引かれ、早くから従来の画像認識手法をやめ、研究室全員がディープラーニングの研究に関わるようになりました。最近では、ディープラーニングの基礎理論だけでなく、「実用的な」コンピュータビジョンにも主眼を置いています。

2. 研究概要

2.1 コンピュータビジョンの外観検査応用

外観検査は、古くから画像認識が最も実用化されている領域の一つだと思われます。しかし、現在でも画像認識でできることは限られ、多くは人の目視によって検査が行われています。これを、ディープラーニングを用いてさらに高度にしようという試みが近年多くなっています。

生産現場での検査を考えた場合、良品のサンプルは大量に手に入りますが、不良品のサンプルを入手することが困難な場合が多いのです。このような場面では、データサンプルの偏りにより、一般的なディープラーニングによるク

ラス分類はうまく働きません。そこで、異常検知という考え方が必要になります。異常検知は、正常を学習し、その分布から外れた場合に異常と判断するアプローチです。この考え方であれば、良品サンプルのみで学習が可能となります。私たちの研究室では、このディープラーニングによる異常検知手法について多数研究し、多くの企業との共同研究により現場に役立てています。

まず、正常サンプルをまったく用いない方法を紹介します。研究成果にもいくつかアプローチがありますが、ここでは GAN (Generative Adversarial Networks) を用いた方法を紹介します。GAN はジェネレータとディスクリミネータの二つのニューラルネットワークがだまし合いながら学習を進めていくニューラルネットワークです。

GAN は、モデルの確率密度分布を推定します。GAN を用いた異常検知では、「異常は、GAN で学習した正常モデルの分布の中には存在しない」との仮定に基づいて異常を検知します。近年の GAN による異常検知での問題は、入力画像を正常モデルにどのように射影するか、が議論されています。私たちの研究室で開発したニューラルネットワークモデルは、この問題を Bi-Directional GAN を用いて解決します。さらに、Cycle Consistency loss を用いることで、画像と潜在空間のマッピングをより高精度に行います (図 2)。

本手法は MVTEC Anomaly Detection Dataset の Metal Nut の実験において、従来手法を大きく超える異常検知性能を実現しました (図 3, 表 1)。

次に、異常サンプルが少量は手に入る場合のアプローチで、ここでは Adversarial AutoEncoder (AAE) を用いた方法を紹介します (図 4)。AAE は GAN と同じく敵対

図 1 研究室集合写真 (2019 年 12 月)

図 2 Bi-Directional GAN と Cycle Consistency loss を用いた異常検知

図3 MVtec Anomaly Detection Dataset (Metal Nut)

表1 Metal Nut を用いた定量評価実験

Model	AUROC
AutoEncoder	0.63
AnoGAN	0.76
Bi-directional GAN (Concatenate) (EGBAD)	0.78
Bi-directional GAN (Projection)	0.77
Bi-directional GAN (Concatenate) + Consistency Loss (ours)	0.79
Bi-directional GAN (Projection) + Consistency Loss (ours)	0.84

図4 Adversarial AutoEncoder を用いた異常検知

的学習をする方法ですが、ディスクリミネータは、AutoEncoder の潜在空間に制約をもたせるために用いられます。私たちの方法は、正常分布は正規分布であると仮定し、AutoEncoder で抽出される正常分布をディスクリミネータにより正常分布に近づけるように学習を行います。

ここで、学習サンプルに少しだけ(数%)の異常サンプルを含めてやることで、正規分布の中心に正常特徴が、外側に異常特徴が集まるように学習が行われます。すなわち、正規分布の外側が、正常と異常の識別境界のような働きをするわけです。これにより、非常に高い精度で異常検知を実現しました。本手法は、表面実装 IC チップのハンダ検査に用いられ、57 万サンプルにおいて誤検出(不良を良品と判定)はゼロ。過検出(良品を不良と判定)は3例という非常に高い性能を実現しました(図5)。

2.2 目で見て理解するロボット

東海国立大学機構航空宇宙生産技術開発センターでは、航空宇宙産業における生産技術の高度化の研究を推進しており、私たちの研究室も中心研究者として参画していま

図5 Adversarial AutoEncoder を用いたハンダ検査

図6 End to End なロボット操作を学習するニューラルネットワーク

す。その中での研究として、産業用ロボットへのディープラーニングの応用を行っています。工場内を走る搬送ロボットの制御において、時系列画像だけを入力とし、操作コマンドを出力する、End to End なニューラルネットワークの開発に取り組んでいます(図6)。

学習サンプルとして、人がコントローラーでロボットを操作したときの動画と、操作コマンドの時系列を用意します。このような学習を模倣学習といいます。問題は、人は非常にうまくロボットを走らせることができってしまうということです。このような人の操作だけを学習サンプルとして学習したロボットは、一見うまく走れますが、思わぬ出来事の際の操作法を知りません。そこで、人が操作するときにランダムでコントロール不能の状態を短時間起こしてやります。すると、人がその状態をリカバリーするようにロボットをコントロールする学習サンプルが得られます。これにより、ロボットは思わぬ出来事の際にどのように回復すればいいかを学習できることが分かりました。

3. おわりに

私たちは研究室の中にとどまらず、多数の企業との共同研究を通して、「現場で役立つコンピュータビジョン」を合言葉に研究を進めています。

私たちの研究室は、「世界に通用するコンピュータビジョンの研究室」を目指し日々研究に励んでいます。本稿で紹介した研究はごく一部です。多数の研究は研究室ホームページ(<http://www.cv.info.gifu-u.ac.jp>)をご覧ください。