

画像認識精度を向上させる ディープラーニング技術を用いた学習用画像の自動生成

Deep Learning Data Augmentation Technique to Improve Image Recognition Accuracy

伊藤 秀将 入本 勇宇次 榎本 晋一

■ ITO Hidemasa ■ IRIMOTO Yuji ■ KASHIMOTO Shinichi

少子高齢化に伴い労働人口の減少が進む中、点検や検査などを実施する際に習熟した保守作業員（エキスパート）による正常か異常かの判断を、AIを活用した画像認識技術でアシストあるいは自動化したいというニーズが高まっている。画像認識では、現場で収集した大量の実画像を用いて学習し画像認識精度を向上させる必要があるが、作業内容や業種によっては十分な数の実画像を収集することが難しい場合がある。

東芝デジタルソリューションズ（株）は、ディープラーニング（深層学習）技術の一つである敵対的生成ネットワーク（GANs）によって学習用画像を自動生成する、独自の技術を開発した。送電線の巡視・点検を想定した画像を用いて検証を行った結果、実画像の数が不十分な場合でも、自動生成した画像を含めて学習することで、画像認識精度を高められることを確認した。

In recent years, the need has arisen for the support or automatic implementation of inspection and monitoring work applying image recognition technologies powered by artificial intelligence (AI) instead of experts with technical know-how due to the declining labor force accompanying the shift to an aging society with fewer children. Large amounts of actual image data for learning are required in order to improve image recognition accuracy. However, it is difficult to collect a sufficient number of actual images in some types of operations.

Toshiba Digital Solutions Corporation has developed a unique technique to automatically augment image data using generative adversarial networks (GANs), one of the deep learning technologies. We have conducted image recognition simulations using images of power lines to represent inspection and monitoring work, and confirmed that image recognition accuracy is enhanced by learning that incorporates augmented image data when the amount of actual image data is insufficient.

1 まえがき

ディープラーニング技術は機械学習の一手法であり、データの特徴を深く学習したニューラルネットワークにより、様々な分野の認識や分析などに用いられている。例えば、ディープラーニング技術を画像認識に適用する場合、良質かつ大量の学習用画像を用意することで、高い認識精度を実現できる。一方で、適用する対象によっては学習用画像を十分に用意できない場合も多い。この場合、画像認識精度を実用レベルに到達させることは困難である。

画像認識による異常検知の精度を高めるためには、十分な数の異常及び正常の学習用画像があること、及び学習用画像に異常／正常などの正確なラベルが付与されていることが重要となる。例えば、送電線の巡視・点検などの電力インフラ向け業務は、通常エキスパートの目視で実施されており、エキスパートの知見を画像認識技術で代替するために必要な、大量の学習用画像が保存されていない（図1）。また、異常の発生頻度が低い場合、正常時の学習用画像を多数収集することは原理的に可能であるが、異常時の学習用画像の収集は難しい。

学習用画像は多数あるが、ラベルが付いているものが少ない場合は、次のような手法を適用する。

(1) 半教師あり学習⁽¹⁾ 少数のラベルあり画像に加え、




図1. 送電線の巡視・点検における画像の例 — 送電線の巡視・点検は、通常エキスパートの目視で実施されており、送電線の画像が余り保存されていない。

Example of image of power line for inspection and monitoring

多数のラベルなし画像も学習に利用する。

- (2) 能動学習⁽²⁾ 教師あり学習において、識別精度に影響がある少数の学習用画像を選択的にラベル付けることで、効率的に学習を行う。
- (3) 転移学習⁽³⁾ 良質の大規模な教師あり画像セットを用いて適切に学習させた特徴抽出器が、他のタスクへ転用可能であることを利用する。

しかしこれらの手法は、学習用画像が大量にあることが前提であるため、学習用画像そのものの数が不足している問題を解決することは困難である。

そこで、学習用画像が少なく、認識精度が十分に得られないという問題を解決するために、東芝デジタルソリューションズ(株)は、異常時の画像と正常時の画像とを合わせてディープラーニング技術を用いて解析することで、類似した画像を大量に作り出す、学習用画像の自動生成手法を開発した。

2 学習用画像の生成に必要な要件

自動生成した学習用画像を用いて画像認識精度を向上させるためには、生成画像にエキスパートが正常か異常かのラベルを付与することで人間の知見を与え、画像認識モデルのニューラルネットワークに再学習させる。これを模式的に示したのが、図2である。

図2(a)のように、初めは学習用画像が少ないため、学習用画像が分布する空間の中で、正常か異常かを適切に識別する境界を定めることが難しく、不安定な状況である。続いて、学習用画像が分布する空間を満たすような内挿的な画像を生成する(図2(b))。次に生成画像に対して、エキスパートが正常か異常かのラベルを付ける(図2(c))。生成画像を含めて再学習することで、学習用画像が分布する空間の中で識別境界が明確になり、画像認識モデルが正常か異常かを精度良く認識できるようになる(図2(d))。

真の学習用画像の分布は連続的であることが想定されるが、実際に与えられる学習用画像は高次元空間に離散的に存在する。したがって、この自動生成手法は、学習用画像が分布する空間を満たす連続的かつ内挿的な画像を生成できることがポイントとなる。

また、細かい傷などでも異常として画像認識できる必要がある。こうした異常を再現するために、ぼやけずシャープな画像を生成できるモデルでなければならない。

3 学習用画像の自動生成手法の提案

敵対的生成ネットワーク(GANs)は、近年注目を集めている画像生成モデルの一つであり、教師なし学習によりリアルな画像を生成できるのが特徴である。画像を生成する生成モデル(Generator)と、その画像が生成モデルによって作られたのかどうかを判別する識別モデル(Discriminator)を用い、これらの二つのモデルが競い合うように学習を行うことで、より良い生成モデルを得る手法である⁽⁴⁾。

図3に示すように、基本的なGANsの画像生成モデルは、生成器と生成画像識別器から構成される。生成画像識別器は実画像と生成画像を見分けるように学習し、生成器は生成画像識別器をだますような画像を作るように学習する。これは実画像の分布と生成画像の分布を、特定の距離尺度で最小化することに相当する。

しかし、生成画像識別器をだますように学習するだけでは、画像認識モデルの特徴空間上で二つの分布に大きな差異が生まれることがあった。生成画像の再学習で画像認識モデルの精度を向上するには、人間の目だけでなく、認識モデルにとっても、実画像と生成画像の分布に違いがないようにする必要があるのである。

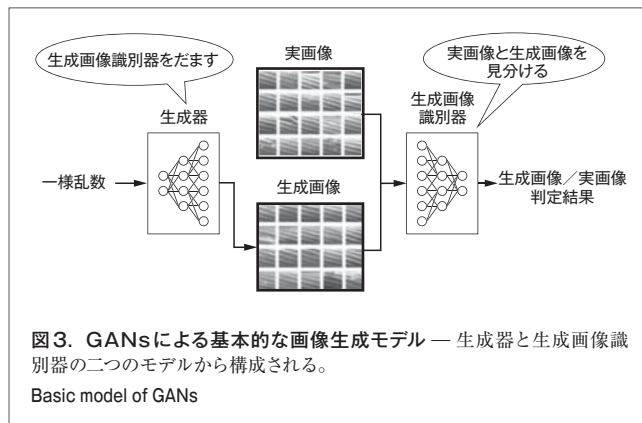


図3. GANsによる基本的な画像生成モデル — 生成器と生成画像識別器の二つのモデルから構成される。
Basic model of GANs

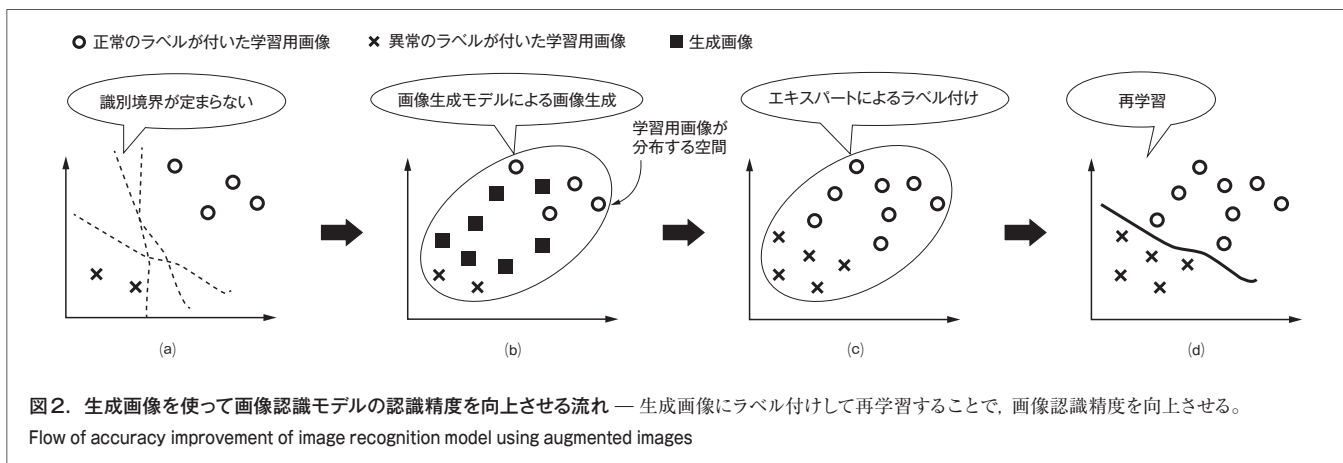
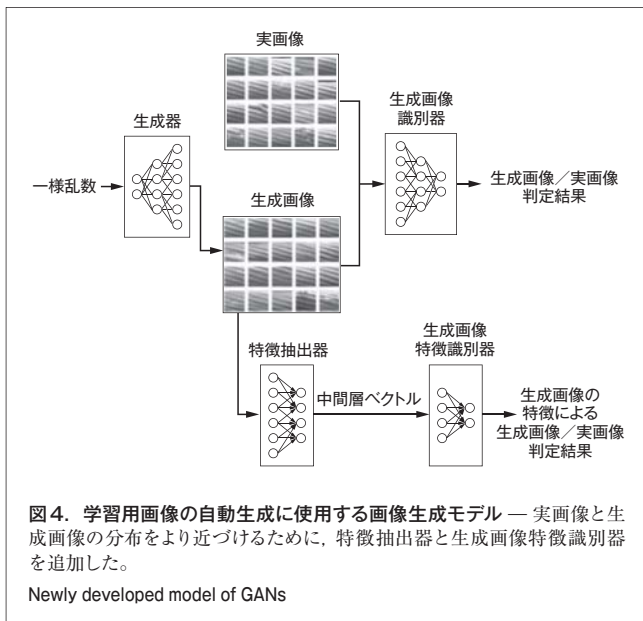


図2. 生成画像を使って画像認識モデルの認識精度を向上させる流れ — 生成画像にラベル付けして再学習することで、画像認識精度を向上させる。
Flow of accuracy improvement of image recognition model using augmented images



そこで、図4に示すように、特徴抽出器と生成画像特徴識別器を追加した。生成画像識別器によって生成画像の分布を実空間上で実画像の分布に近づけるように学習すると同時に、生成画像特徴識別器によって、特徴抽出器を通した空間上でも生成画像の分布が実画像の分布から離れ過ぎないように制約を設ける。これら二つの識別器から得られる判定結果の尤度(ゆうど)の重み付き和をもって、生成モデルを学習する。

4 送電線のアーク痕画像を用いた検証

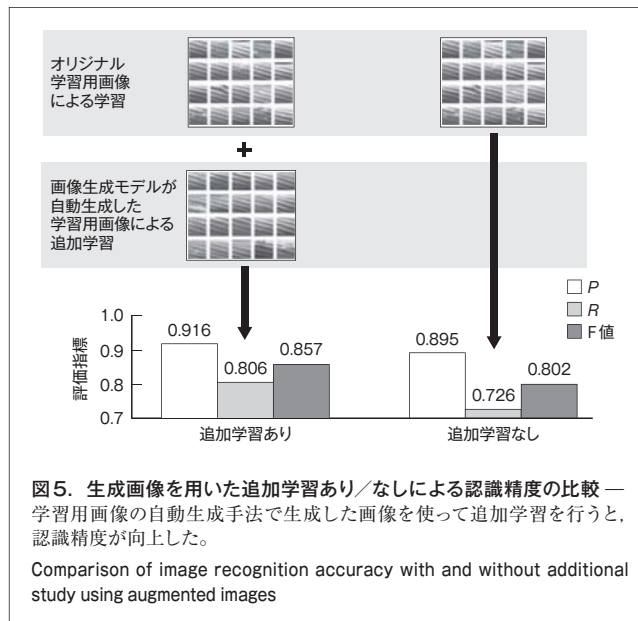
送電線のアーク痕画像を用いて、提案した学習用画像の自動生成手法の効果を検証した。

送電線のアーク痕は、落雷によるアーク放電で送電線表面の一部が溶解したものであり、これにより送電線の当該箇所に雷が落ちたことが分かる。検証に用いる異常(アーク痕あり)の学習用画像は、送電線巡視・点検エキスパートの監修の下、送電線に溶接器具やニッパーなどで人工的にアーク痕を付けて作成した。正常/異常の画像を合わせて、オリジナル学習用画像1,600枚、チューニング用画像400枚、及び検証用画像400枚を用意した。

図5に検証の手順と評価結果を示す。画像生成モデルによる生成画像を用いた追加学習ありの場合を図5の左側、追加学習なしの場合を右側に示す。

まず、オリジナル学習用画像で画像認識モデルの学習を行い、更にチューニング用画像でチューニングした。

追加学習に使用する学習用画像は、3章で述べた学習用画像の自動生成手法を用いて、正常/異常の学習用画像を合計1,600枚生成し、エキスパートによる判断で画像ごとに、正常/異常のラベル付けを実施した。追加学習ありの場合は、



この画像を用いて、画像認識モデルの追加学習を行った。

追加学習ありと追加学習なしの画像認識モデルを、それぞれ検証用画像を用いて評価した。認識精度の評価指標としては、認識誤りの少なさを表す適合率P、認識漏れの少なさを表す再現率R、及び式(1)で算出されるPとRの調和平均F値を使用した。F値が大きいほど、認識精度が高いことを示す。

$$F \text{ 値} = 2PR / (P+R) \quad (1)$$

図5の下段に示すとおり、追加学習ありでは、追加学習なしの場合に比べて、P、R、及びF値の全てが大きくなっており、認識精度が向上していることを確認した。


次に、認識漏れを少なくする効果について検証した。追加学習の前にはアーク痕のある異常画像を誤って正常画像と認識したが、追加学習後にアーク痕を正しく認識できた画像について考察する。画像認識モデルのニューラルネットワークの途中出力を領域ごとに分析することによって、注視領域を可視化する手法を用いて、注視領域が、追加学習の前後でどのように変化したかを調べた。

図6(a)に、アーク痕を含む元画像を示す。左下の黒くなっている部分がアーク痕である。

図6(b)に、追加学習前の画像認識モデルのニューラルネットワークによる注視領域を、図6(c)にこの注視領域を元画像に重ねたものを示した。緑色の霧状に示されている領域が注視領域である。追加学習前にはこのアーク痕部分を注視しておらず、異常と分類できていない。

同じ画像を画像認識モデルの追加学習後に認識させた結果が図6(d)と図6(e)である。追加学習後にはアーク痕部分を注視しており、この画像を異常と分類できた。

このように、送電線のアーク痕画像を使用して、検証を行っ



た結果、学習用画像の自動生成手法で生成した画像を用いて画像認識モデルを追加学習することで、認識精度の向上と、認識漏れの低減の効果が確認できた。

5 あとがき

画像認識による異常検知において、学習用画像が少なく、異常時の学習パターンが十分に得られないという問題を解決するために、GANsの画像生成モデルに独自の技術を導入して、学習用画像を自動生成する手法を開発した。

送電線のアーク痕画像の認識に適用して検証し、この技術が認識精度の向上と、認識漏れの低減に貢献できることを確認した。

生成した学習用画像が大量になればなるほど、またその画像間の違いが繊細になればなるほど、エキスパートによるラベル付け作業が難しくなる。多数のエキスパートが分担して長期間にわたってラベル付け作業をすると、ラベル付けのばらつき

や誤りといった問題も増加する。今後は、ラベル付け作業をサポートする技術を含めて更なる開発を進めていく。

文献

- (1) 田中遼平, ほか. 識別境界付近のデータを選択的に用いる半教師あり学習. 信学技報. 116, 528, 2017, p.1-6.
- (2) 東京大学 杉山・佐藤・本多研究室. 機械学習と統計的データ解析. 東京大学. <<http://www.ms.k.u-tokyo.ac.jp/research-jp.html#theory-active-learning>>, (参照2017-06-28).
- (3) 中山英樹. 深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習. 東京大学. <http://www.nlab.ci.i.u-tokyo.ac.jp/pdf/CNN_survey.pdf>, (参照2017-06-28).
- (4) Goodfellow, I. J. et al. "Generative Adversarial Nets". Neural Information Processing Systems (NIPS) Proceedings. Montreal, Canada. 2014-12, NIPS Foundation, Inc., 2014, p.2672-2680.



伊藤 秀将 ITO Hidemasa

東芝デジタルソリューションズ(株) ソフトウェア& AIテクノロジーセンター ディープラーニング技術開発部
情報処理学会会員
Toshiba Digital Solutions Corp.



入本 勇宇次 IRIMOTO Yuji

東芝デジタルソリューションズ(株) ソフトウェア& AIテクノロジーセンター ディープラーニング技術開発部
Toshiba Digital Solutions Corp.



榎本 晋一 KASHIMOTO Shinichi

東芝デジタルソリューションズ(株) ソフトウェア& AIテクノロジーセンター ディープラーニング技術開発部
電子情報通信学会会員
Toshiba Digital Solutions Corp.