

GAN を用いた CCTV 画像の災害被害検出

Detection of the damage from the natural disaster using CCTV image based on GAN

吉田 龍人^{*1} 安野 貴人^{*1} 藤井 純一郎^{*1} 大久保 順一^{*1} 天方 匡純^{*1}
 Ryuto Yoshida Takato Yasuno Junichiro Fujii Junichi Okubo Masazumi Amakata

^{*1} 八千代エンジニアリング株式会社
 Yachiyo Engineering Co.,Ltd.

When disasters occur, it is required to understand the damage as soon as possible. And, CCTV camera is good tool to monitor the damage in real time from remote location. However, CCTV camera that depends on visual check causes human errors like oversights. Purpose of this study is to develop methods that detects the damage automatically. Especially, this study focuses on the anomaly detection using GAN. As a result of this study, it was possible to detect the damage under simple condition.

1. はじめに

地球温暖化に伴う気候変動によって災害が激甚化しており、災害発生時の被害の早期発見が求められている。そうした中、常時インフラを定点監視し、遠隔地の被災状況をリアルタイムで確認できる CCTV カメラは、被害発見の有用なツールとなる。しかし、膨大な数のカメラから被害を自動検出する手法は開発されておらず、目視による判断では、緊急時において被害発見の遅れや見逃しが懸念される。

被害の自動検出を検討する場合、Detection や Semantic Segmentation といった画像認識 AI の技術を用いることも想定されるが、地割れや洪水といった発生事例の少ない現象を教師画像として収集することは困難であり、多岐にわたる被害を個別に検出するモデルを作成するのは現実的ではない。

そこで本研究では、CCTV カメラの持つ、定点連続撮影という利点に着目し、GAN [Ian J. Goodfellow 2014]による画像生成技術を用いて、CCTV カメラの画像から、災害による被害を自動で検出する手法を検討した。



図-1 CCTV 画像の例

2. 検討した被害検出手法

2.1 CCTV カメラ画像について

本研究では図-1 に示す、名古屋市が管理する CCTV カメラ画像を用いた。本カメラを選定した理由は 2 点ある。1 点は、画像に写るほとんどのものが人工物であり、雲のように経時変化の激しい物体があまり写っていないため、そしてもう 1 点はカメラが非可動式であり撮影アングル等が固定されているためである。

また、CCTV 画像を用いてモデルの学習を行う前に、画像の整理を行った。具体的には画像を生成する条件を簡易化するために、夜間の画像および近景に車の写っている画像を教師画像から人為的に取り除いた。この結果、教師画像として 2700 枚の画像が抽出できた。

次に、抽出した 2700 枚の画像に対して前処理を行った。まず、画像のノイズを低減させるため、 5×5 の平均化フィルタを 2 回かけた。

さらに、平均化フィルタによって滑らかになった画像を、グレースケールに変換することで、災害の被害検出に不要な情報を削ぎ、学習の効率化を図った。

2.2 GAN について

本研究では GAN の中でも DCGAN [Alec Radford 2016]による画像の生成および生成画像の差分による被害検知を行う。

特に画像生成時には、学習速度と被害検出の精度という実用時に求められる 2 項目の性能を考慮して、 320×240 のグレースケール画像を生成させた。さらに潜在変数は DCGAN の論文に倣い、100 次元とした。

3. 学習および被害検知結果

まず、道路の陥没を撮影した画像を CCTV 画像上にトレースすることで、疑似的に被害を発生させた図-2 (a)を作成した。この図から GAN の Generator によって正常時の CCTV 画像を生成し、生成元の画像との差分を取ることで、被害検出が可能か検証する。

3.1 2700 枚の画像を用いた学習結果

始めに、2.1 で概要を示した、2700 枚の画像を用いて学習を行った。

図-2 (a)の疑似被害画像を元に画像を生成した結果が図-2 (b)で、図-2 (a)と図-2 (b)の差分を取った結果が図-2 (c)である。

全体が影になっている図-2 (a)では、画像の生成前後で陥没のみが大きく変化し、差分画像で被害箇所を検出している。

一方、日なたを含んだ画像を元に作成した疑似被害画像の図-3 (a)から、同モデルを用いて、画像の生成を行った結果が図-3 (b)である。

図-3 (b)は、日なたを含んだ画像から生成しているにも関わらず、全体が影となった画像が生成されている。そのため、図-3 (c)に示す差分画像にも強いノイズが生じており、被害箇所の検出はできていない。

図-3 (b)のように 2700 枚で学習したモデルにおいて、影の形状が正しく生成されなかった原因は教師画像の不均衡であると考えた。対象現場では周囲の建物の影響で、画像全体が影となる時間帯は多く、今回用いた 2700 枚の教師画像においても、約 1400 枚は画像全体が影となっていた。

よって、日なたを含んだ教師画像の割合が少なく、学習への影響が小さかったため、適切な画像生成ができなかったのだと推察した。

3.2 1686 枚の画像を用いた学習結果

教師データの不均衡を改善するため、2700 枚の画像のうち、日なたの写った画像や路面が濡れた画像 1286 枚と全体が影となった平易な画像 400 枚の合計 1686 枚を取り出して再度学習を行った。

図-4 (a)は 1686 枚モデルによって図-3 (a)を元に画像を生成した結果で、図-4 (a)と図-3 (a)との間で差分を取った結果が図-4 (b)である。

図-4 (a)より、2700 枚モデルでは生成できなかった影が生成されていることが確認できた。また図-4 (b)の差分画像についても、図-3 (c)に比べてノイズが低減されていることが確認された。

以上より教師画像のバランスを整えることで、より高い再現性を持って生成画像を生成できるようになったと考える。

ただ、1686 枚モデルにおいても、影の形状を生成出来た時間帯と、できなかった時間帯があり、使用する教師画像のバランスを再度検討するべきであると考えた。

4. おわりに

4.1 本研究のまとめ

本研究では CCTV カメラ画像を用いた GAN による災害被害検出手法を検討した。その結果、全体が影に覆われた明度変化の少ない画像においては、被害箇所のみを正常に置き換えた画像が生成でき、差分から被害を検知することができた。

一方で、日の光が差し、明度変化の大きい画像では、全体が影に覆われた画像が生成され、被害検知は困難であった。しかし、教師画像のバランスを整えて学習することで、一部の画像において、影と日なたの形状を維持した画像を生成できた。

4.2 今後の課題

本研究の 1 番の課題は、被害の検出方法を改善することであると考える。GAN で監視カメラの平常状態を学ばせる手法自体は問題ないと思うが、本稿で用いた被害画像と生成画像との差分では、偶発的に除去された平常箇所がノイズとして現れる可能性が高い。したがって、差分ではない新たな評価方法を検討する必要がある。

また、複雑な条件下での画像生成の検証も重要である。本技術を運用することを想定した場合、天候、季節、交通車両の有無など、考慮すべき条件は無数にある。よって GAN が許容できる変化の程度を把握し、高品質な画像生成が可能となる条件を明らかにすべきである。


参考文献

[Ian J. Goodfellow 2014] Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio: Generative Adversarial Nets, arXiv:1406.2661v1, 2014.

[Alec Radford 2016] Luke Metz, Soumith Chintala: Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks, arXiv:1511.06434, 2016.



(a) 疑似被害画像 (b) 生成画像



(c) 差分画像

図-2 2700 枚モデルでの検知成功例



(a) 疑似被害画像 (b) 生成画像



(c) 差分画像

図-3 2700 枚モデルでの検知失敗例



(a) 生成画像 (b) 差分画像

図-4 1686 枚モデルで影が生成された例