

拡散モデルを用いた道路インフラ点検の自動化に向けた異常検知システム Anomaly Detection System Based on Diffusion Model for Automated Road Infrastructure Monitoring

藤田 生吹[†]
Ibuki Fujita

関根 栄子[†]
Eiko Sekine

1. はじめに

近年、道路インフラの経年劣化が進行しているため、補修のためにひび割れやポットホールといった損傷を自動検出する技術が求められており、画像処理による様々な手法が提案されている^[1]。現在、画像生成の分野で注目されている「拡散モデル (Diffusion Model)」^{[2][3]}は教師なし学習に基づいた手法であり、大量の損傷データを用意する必要がなく、正常データのみを学習させることで、損傷種別に応じた異常検知が可能である。例えば、工業用製品の不良品検出^[4]や、医療分野における MRI 画像の腫瘍検知^[5]に用いられるなど、その有効性が報告されている。本研究では、正常な路面画像のみを学習した拡散モデルを応用し、異常度に基づいて路面の損傷を自動的に検知するシステムの構築と性能評価を行うことを目的とする。

2. 拡散モデルの概要

本研究では拡散モデルの 1 つである Denoising Diffusion Probabilistic Model (DDPM)^{[2][3]}を使用する。DDPM では、入力データ $x_0 \sim q(x)$ に正規ノイズ $\epsilon \sim \mathcal{N}(0, \mathbf{I})$ を徐々に加えてゆき、完全なノイズ x_T に T ステップで変化する拡散過程を考える。拡散過程の x_{t-1} から x_t への推移は条件付き確率

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \sqrt{\alpha_t} x_{t-1}, \beta_t \mathbf{I}) \quad (1)$$

と定義されることから、サンプル x_t は式(2)で表される。

$$x_t = \sqrt{\alpha_t} x_{t-1} + \sqrt{\beta_t} \epsilon \quad (2)$$

ここで、 $0 < \beta_1 < \dots < \beta_T < 1$ は分散の大きさを制御するパラメータであり、 $\alpha_t := 1 - \beta_t$ である。これらをノイズスケジュールと呼ぶ。そして、完全なノイズ $x_T \sim \mathcal{N}(0, \mathbf{I})$ からスタートし、拡散過程を逆向きにたどりながらノイズを除去する操作を繰り返すことで再構成を行う。このプロセスを経て、各時間ステップでデータを破壊する過程を学習する。逆拡散過程のサンプル x_{t-1} は拡散過程で加えられたノイズを推定するモデル $\epsilon_\theta(x_t, t)$ を用いて式(3)で表される。

$$x_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left(x_t - \frac{\beta_t}{\sqrt{\beta_t}} \epsilon_\theta(x_t, t) \right) + \sqrt{\beta_t} \epsilon \quad (3)$$

ここで、 $\bar{\alpha}_t := \prod_{s=1}^t \alpha_s$ であり、 $\bar{\beta}_t := 1 - \bar{\alpha}_t$ である。また、DDPM の学習は次の目的関数を最小化するように行われる。

$$L(\theta) = \mathbb{E}_{x_0, \epsilon} [\|\epsilon - \epsilon_\theta(x_t, t)\|^2] \quad (4)$$

なお、式(4)における $\epsilon - \epsilon_\theta(x_t, t)$ は、加えられたノイズと推定されたノイズ間の誤差を表している。

3. 拡散モデルを用いた異常検知手法

拡散過程で入力画像を完全にノイズに変換してしまうと、物体固有の低周波成分が失われてしまう。そのため、異常度として元画像と再構成画像の差を取る方法では、特徴量の損失によって異常箇所以外でも異常度が高くなり、正確な異常検知ができないという問題がある。この対応として、拡散過程を途中で停止する手法や、正規ノイズ以外のノイズを付加する手法^[6]が提案されている。これらに対し、正常データを用いて $\epsilon_\theta(x_t, t)$ の学習を行い、拡散過程は実行せずに、逆拡散過程のみを行うことで異常検知の性能が高くなることが報告されている^[4]。この手法を路面の異常検知に適用すると、路面画像の損傷部を拡




図 1. 元画像、再構成画像に対するヒートマップ

散過程で加えられたノイズであると考えられることになる。本研究では、拡散過程は行わず、逆拡散過程で再構成のみを行う手法を採用する。拡散過程で加えられたノイズの予測には U-Net を用いた。実装には、Hugging Face の diffusers ライブラリ^[6]で提供される UNet2DModel において、U-Net の Encoder と Decoder 共に 4 階層の構造を定義した。拡散過程の分散計画にはコサインスケジュール^[7]を用いた。再構成された画像は式(5)の正規分布に従う性質がある。

$$p_\theta(x_0 | x_1) = \mathcal{N}(x_0; \mu_\theta(x_1, 1), \beta_1 \mathbf{I}) \quad (5)$$

従って、ステップ $t = 0$ における画像の i 番目の画素 x_0^i の負の対数尤度 NLL_i を画素単位の異常度として使用した。

$$NLL_i = \frac{1}{2\beta_1} (x_0^i - \mu_\theta(x_0, 0))^2 + \frac{1}{2} \log(2\pi\beta_1) \quad (6)$$

ここで、 $\mu_\theta(x_0, 0)$ は逆拡散過程におけるステップ $t = 0$ でのモデルの平均を表す。画像単位の異常度は、画素単位の異常度を三次元方向に平均プーリングした異常度の最大値とした。図 1 に元画像、再構成画像、画素単位の異常度のヒートマップの一例を示す。平均プーリングのカーネルサイズは、画像サイズの 1/25 を切り捨てた (15, 15, 3) とし、ストライドは 2 とした。

4. データセットとハイパーパラメータ

使用するデータセットは、一般道路及び高速道路を走行中に、ダッシュボードに取り付けたフル HD カメラ(1920×1080 画素, 30fps)で撮影したビデオデータから、路面の正常箇所と損傷箇所を矩形に切り出すことにより作成した。切り出し領域の矩形サイズは保持したまま 400×400 画素の透過背景に張り付ける加工を施し、拡大・圧縮を用いずに画像サイズを統一した。学習データには、損傷がない路面画像 1000 枚を 90 度単位で回転、および水平に反転させる処理を施した 8000 枚を使用した。学習はバッチサイズ 32 で 100 エポック分行い、損失の収束を確認した。U-Net の各階層におけるチャンネル数は (16, 32, 64, 128) とし、DDPM のステップ数は $T = 1000$ とした。

5. 実験結果

ひびがある路面画像および、ポットホールを含む路面画像に対して検知性能を評価した。路面画像の再構成に用いる、デノイズングを行う逆ステップ数は [1, 2, 3, 5, 8, 14, 23, 39, 64] の 9 つとし、各ステップ数で異なる 20 のシード値で AUROC を計算した。図 2 はひび割れのある路面の結果であり、テストデータには 141 枚のひびがある路面画像と、141 枚の正常な路面画像を用いた場合の AUROC を示す。逆ステップ数が大きくなるにつれ、検知性能が向上しており、逆ステップ数 64 で平均 AUROC は 0.960 の検知性能を有することを確認し

[†] 茨城大学 Ibaraki University





図 2. AUROC による異常検知の性能評価



(a)密度関数


(b)混同行列

図 3. 逆ステップ数 64 における密度関数と AUROC の一例

た. 図 3a は, 逆ステップ数 64 において正常データと異常データにおける異常度の密度関数をカーネル密度推定で近似した分布の一例である. 図 3b は 2 つの分布の交点を閾値として混同行列を作成した例である. このように, 双峰性が確認できる例では, 真陽性率が 95.74%, 擬陰性率が 4.26%であった. また, 真陰性率が 92.91%で, 擬陽性率が 7.09%であった. しかし, 図 4 のように本来検知してほしい部分とは別のところを異常と判定しているものが確認された. この原因として, 当初の学習データは, 主にテクスチャが均質な路面で構成されていたことが考えられる. そのため, モデルはアスファルトに埋め込まれている白い小石を異常と誤認識してしまったと考えられる. そこで, 白い小石を含むアスファルトのような特徴を持つ損傷がない路面画像を新たに追加学習させた. 図 5 は, 元画像 200 枚に同様の前処理を施した 1600 枚を追加学習させ, 再構成した結果である. 追加後は再構成画像で白い小石を含む部分が異常として消えておらず, ヒートマップを見ても損傷がある部分を正しく異常と捉えるようになった. また, 図 6 は追加後の AUROC である. 図 2 と比較し, 逆ステップ数が [39, 64] の場合に, これまで観測されていた AUROC の下振れが解消され, 性能のばらつきが抑制されていることが確認できる. 下振れに該当するシードでは, 正常データと異常データの分布に双峰性が見られず(図 7a), 真陽性率を高くするような閾値決定ロジックにより, 過検知が 98.58%と多くなってしまっていた(図 7b). 追加後は同じシードに対して双峰性を持つ分布となり(図 7c), 過検知も 9.93%まで抑制されていることが確認できる(図 7d). このように, 複雑な路面画像における検知性能の向上と, シードによる検知性能の下振れ抑制は, 学習データの多様性を増すことでモデルの汎化性能と特徴識別能力が向上したことを示している.

6. おわりに

本研究では, 路面の損傷部を拡散過程で加えられたノイズと考え, 拡散を用いない DDPM を利用して路面の異常検知性能の評価を行った. 学習データである正常な路面画像に多様性を持たせることにより, 異常検知の汎化性能を向上させることができた. 今回の検討で用いた正常路面データは, 純粋な路面のテクスチャのみをモデルに学習させるために白線や路肩といった周辺環境を含まないように, アスファルト部分のみを矩形に切り出して作成した. そのため, 車のタイヤが通る場所に発生しやすいポットホールは小さく切り出さざるを得ず,




(a)元画像

(b)再構成画像

(c)ヒートマップ

図 4. 小石を含むアスファルトを誤検知した例



(a)元画像

(b)再構成画像

(c)ヒートマップ

図 5. 学習データ追加後の誤検知改善例


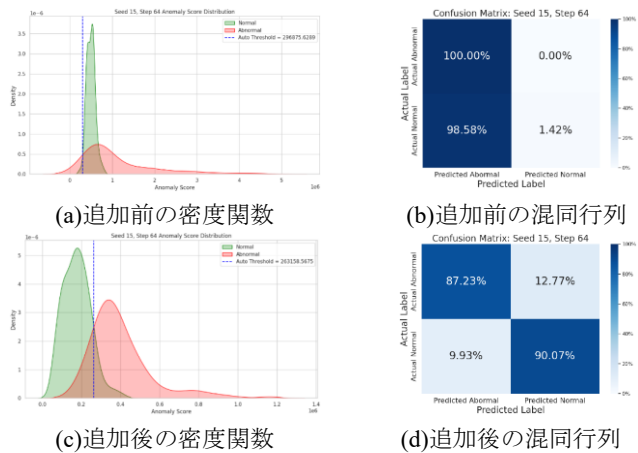


図 6. 学習データ追加後の AUROC による性能評価



(a)追加前の密度関数

(b)追加前の混同行列

(c)追加後の密度関数

(d)追加後の混同行列

図 7. 学習データ追加前後における分布の違い

矩形領域の大部分を異常領域であるポットホールが占めるため, 正常と異常の区別が難しくなり, 再構成に失敗する例が多数見られた. 今後の課題として, 学習データを白線や路肩などの多様な周辺情報を含む正常路面で構築し, より実環境に近い正常路面の状況をモデルに学習させる必要がある. これにより, ポットホールを含む多様な損傷種別に対して, 頑健な検知性能が期待できる.

参考文献

[1]Erick Axel Martinez-Rios, Martin Rogelio Bustamante-Bello, Luis Alejandro Arce-Saenz, A Review of Road Surface Anomaly Detection and Classifications Systems Based on Vibration-Based Techniques, Appl.Sci.12(19), 9413 (2022).
 [2]Jonathan Ho, Ajay Jain, Pieter Abbeel, Denoising Diffusion Probabilistic Models, arXiv:2006.11239 (2020).
 [3]岡野原大輔:拡散モデル データ生成技術の数理, 岩波書店 (2023).
 [4]相原悠, 松原崇:拡散モデルによる拡散を使用しない異常検知, The 36th Annual Conference of the Japanese Society for Artificial Intelligence, F5-GS-10-01 (2022).
 [5]Julian Wyatt, Adam Leach, Sebastian M. Schmon, Chris G. Willcocks, AnoDDPM : Anomaly Detection with Denoising Diffusion Probabilistic Models using Simplex Noise. In proceedings of the IEEE conference on computer vision and pattern recognition, pages650-656 (2021).
 [6]Patrick von Platen et al., Diffusers : State-of-the-art diffusion models, GitHub repository, Available : <https://github.com/huggingface/diffusers> (2022).
 [7]Alex Nichol, Prafulla Dhariwal, Improved Denoising Diffusion Probabilistic Models, arXiv:2102.09672 (2021).