

Recognition, Control and
Learning Algorithm Lab.

不良品検出のための デワーピング拡散モデル

Institute of
SCIENCE TOKYO

DENSO
IT LAB

NII 国立情報学研究所
National Institute of Informatics

内田 輝¹, 池畑 諭^{2,3}, 吉田 悠一², 佐藤 育郎^{1,2}

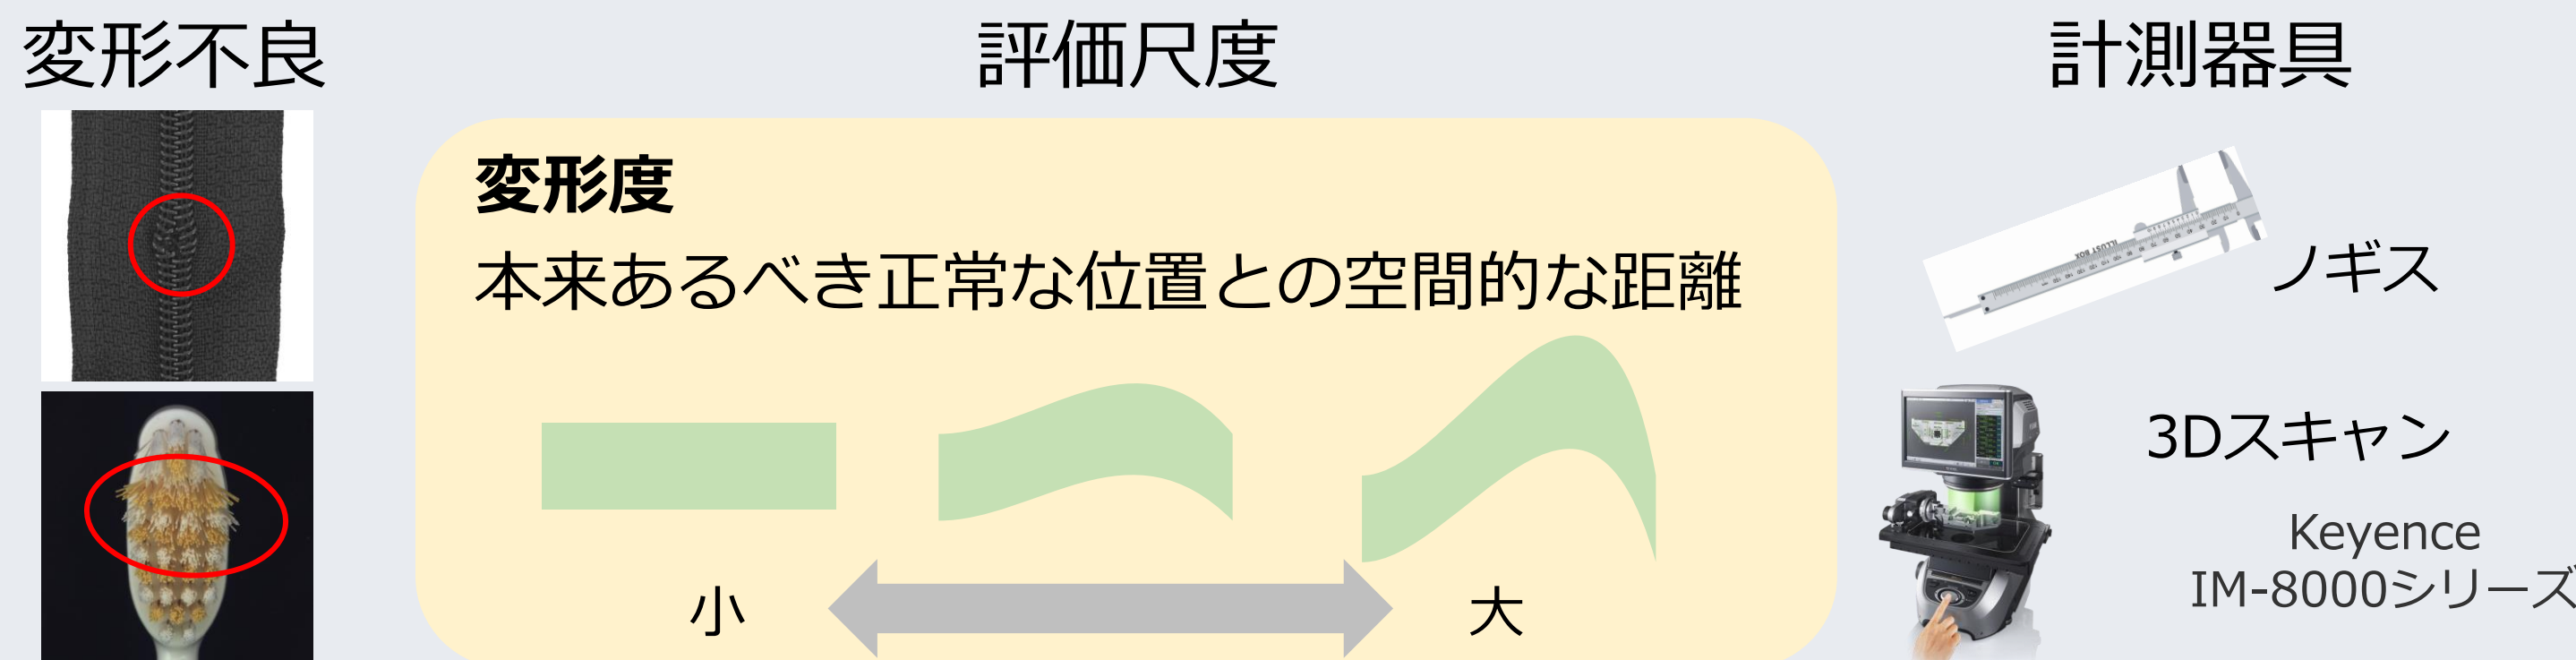
¹東京科学大学, ²デンソーITラボラトリ, ³国立情報学研究所

1. 背景

製造現場における不良品検査

- 稀に発生する様々な原因の不良品を検査
- 不良の種類ごとに適切な評価尺度で不良度を計測

例) 変形不良に対する評価尺度と計測器具



AIによる不良品検出の基本的な目的

良品画像のみの学習により不良品検出器を獲得


2. 従来手法

拡散モデルに基づく再構成型アプローチ (eg., Zhangら ICCV'23)

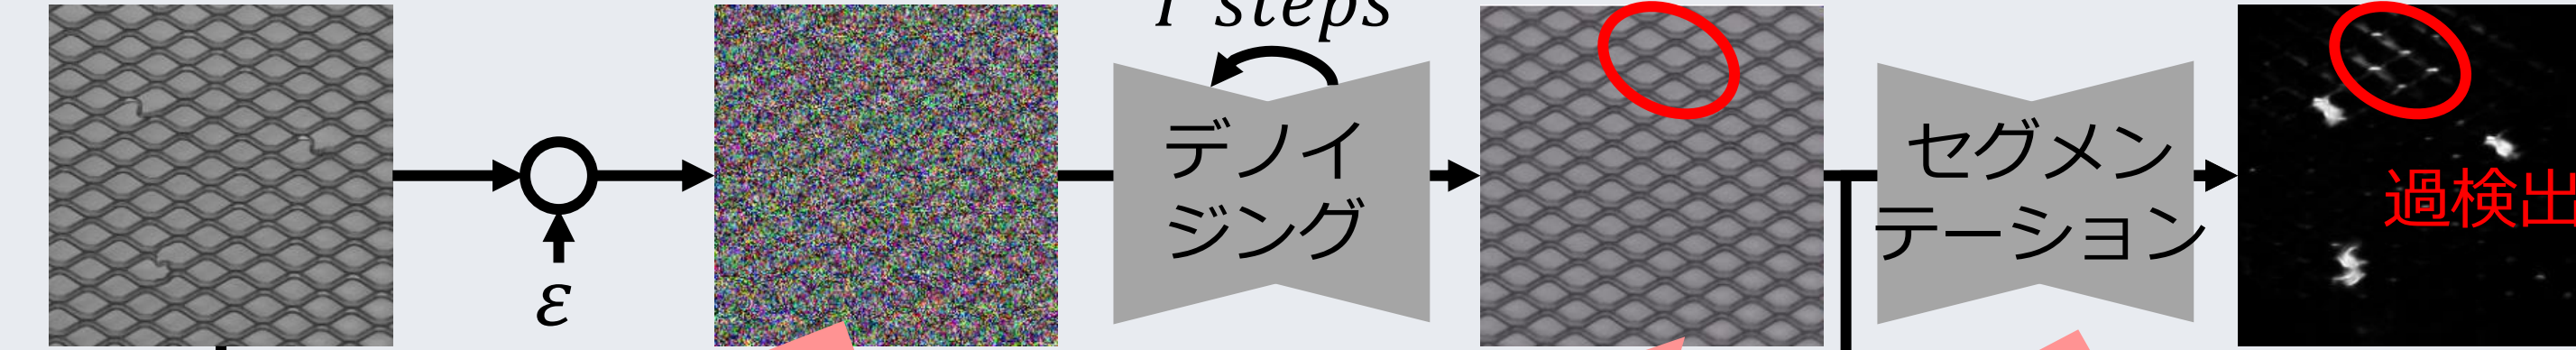
高精度な画像生成が可能な拡散モデル[Hoら Neurips'20]に着目

拡散モデル 時刻 t に従い反復的に良品画像をモデリング

拡散過程: 段階的なノイズ重畳 逆拡散過程: 段階的なノイズ除去



テスト 良品画像で学習されたモデルを用いて不良品画像を再構成
テスト画像 ノイズ画像 再構成画像 検出結果



大域的なノイズを付与後
デノイジングモデルに入力

良品箇所の
微細な変化のおそれ

セグメンテーション
による検出

- 課題**
- 実際の製造現場でニーズのある不良度の表現がしづらい
 - 大域的なノイズ付与と再構成により良品箇所の過検出のおそれ

3. 提案手法

変形度を近似推定するデワーピング拡散モデルを提案


新しい拡散モデルの定義

拡散過程:

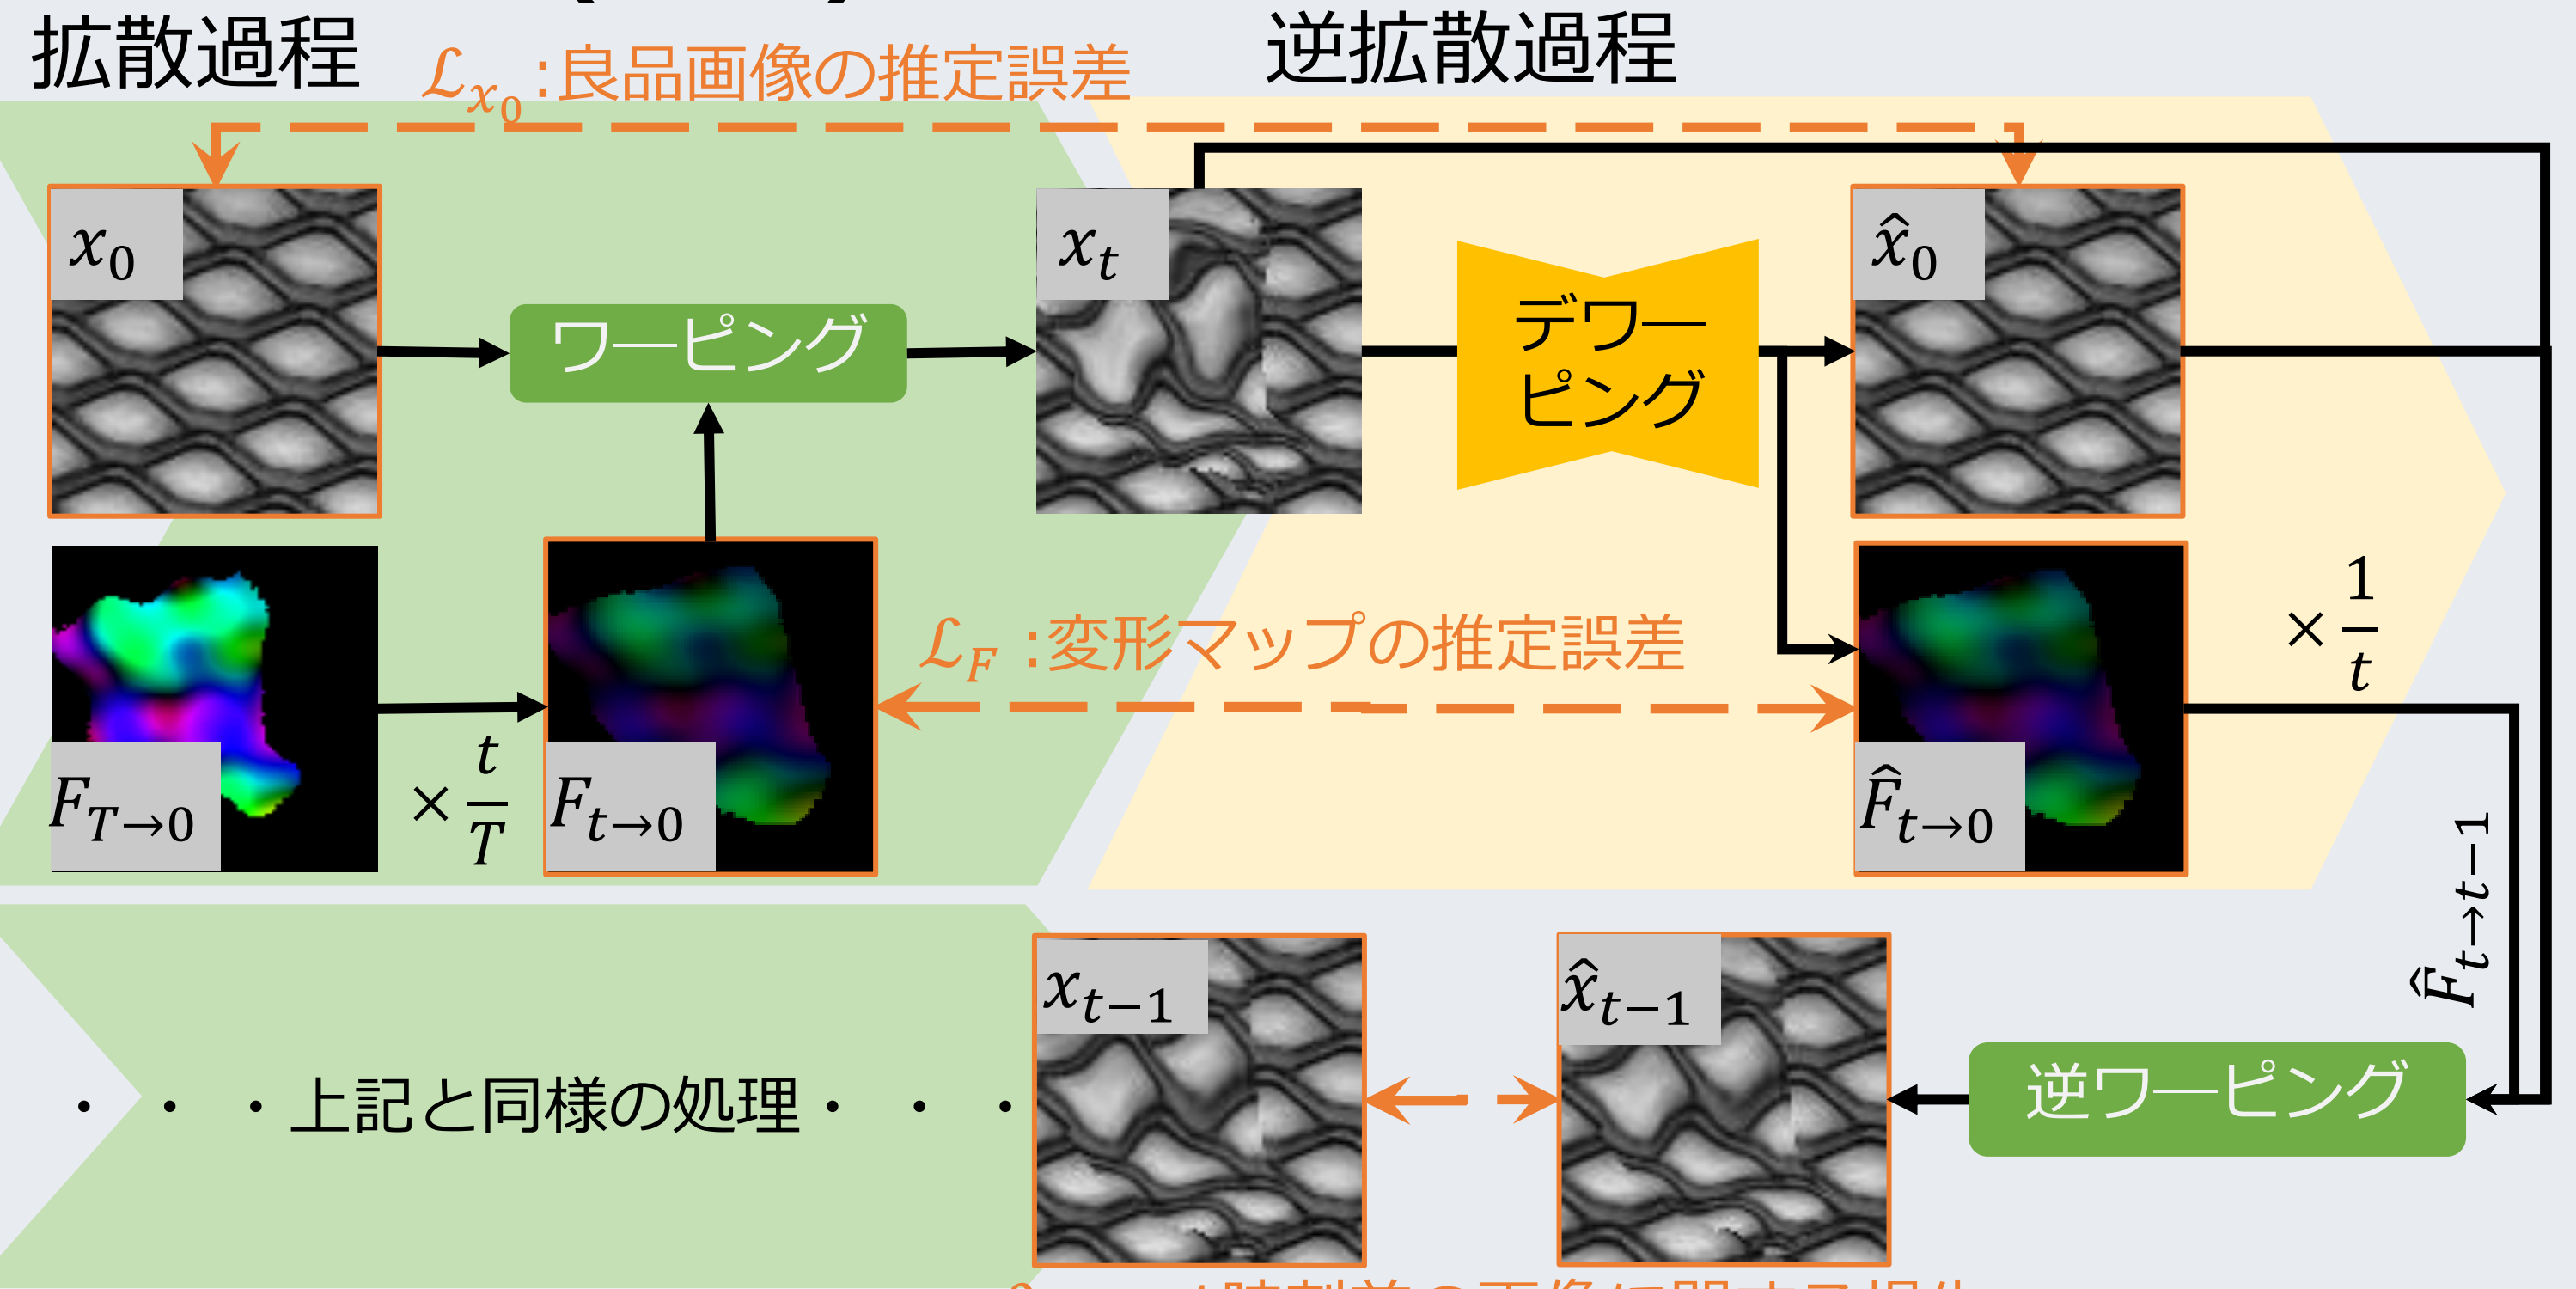
画像処理による疑似的な変形度の増幅

逆拡散過程:

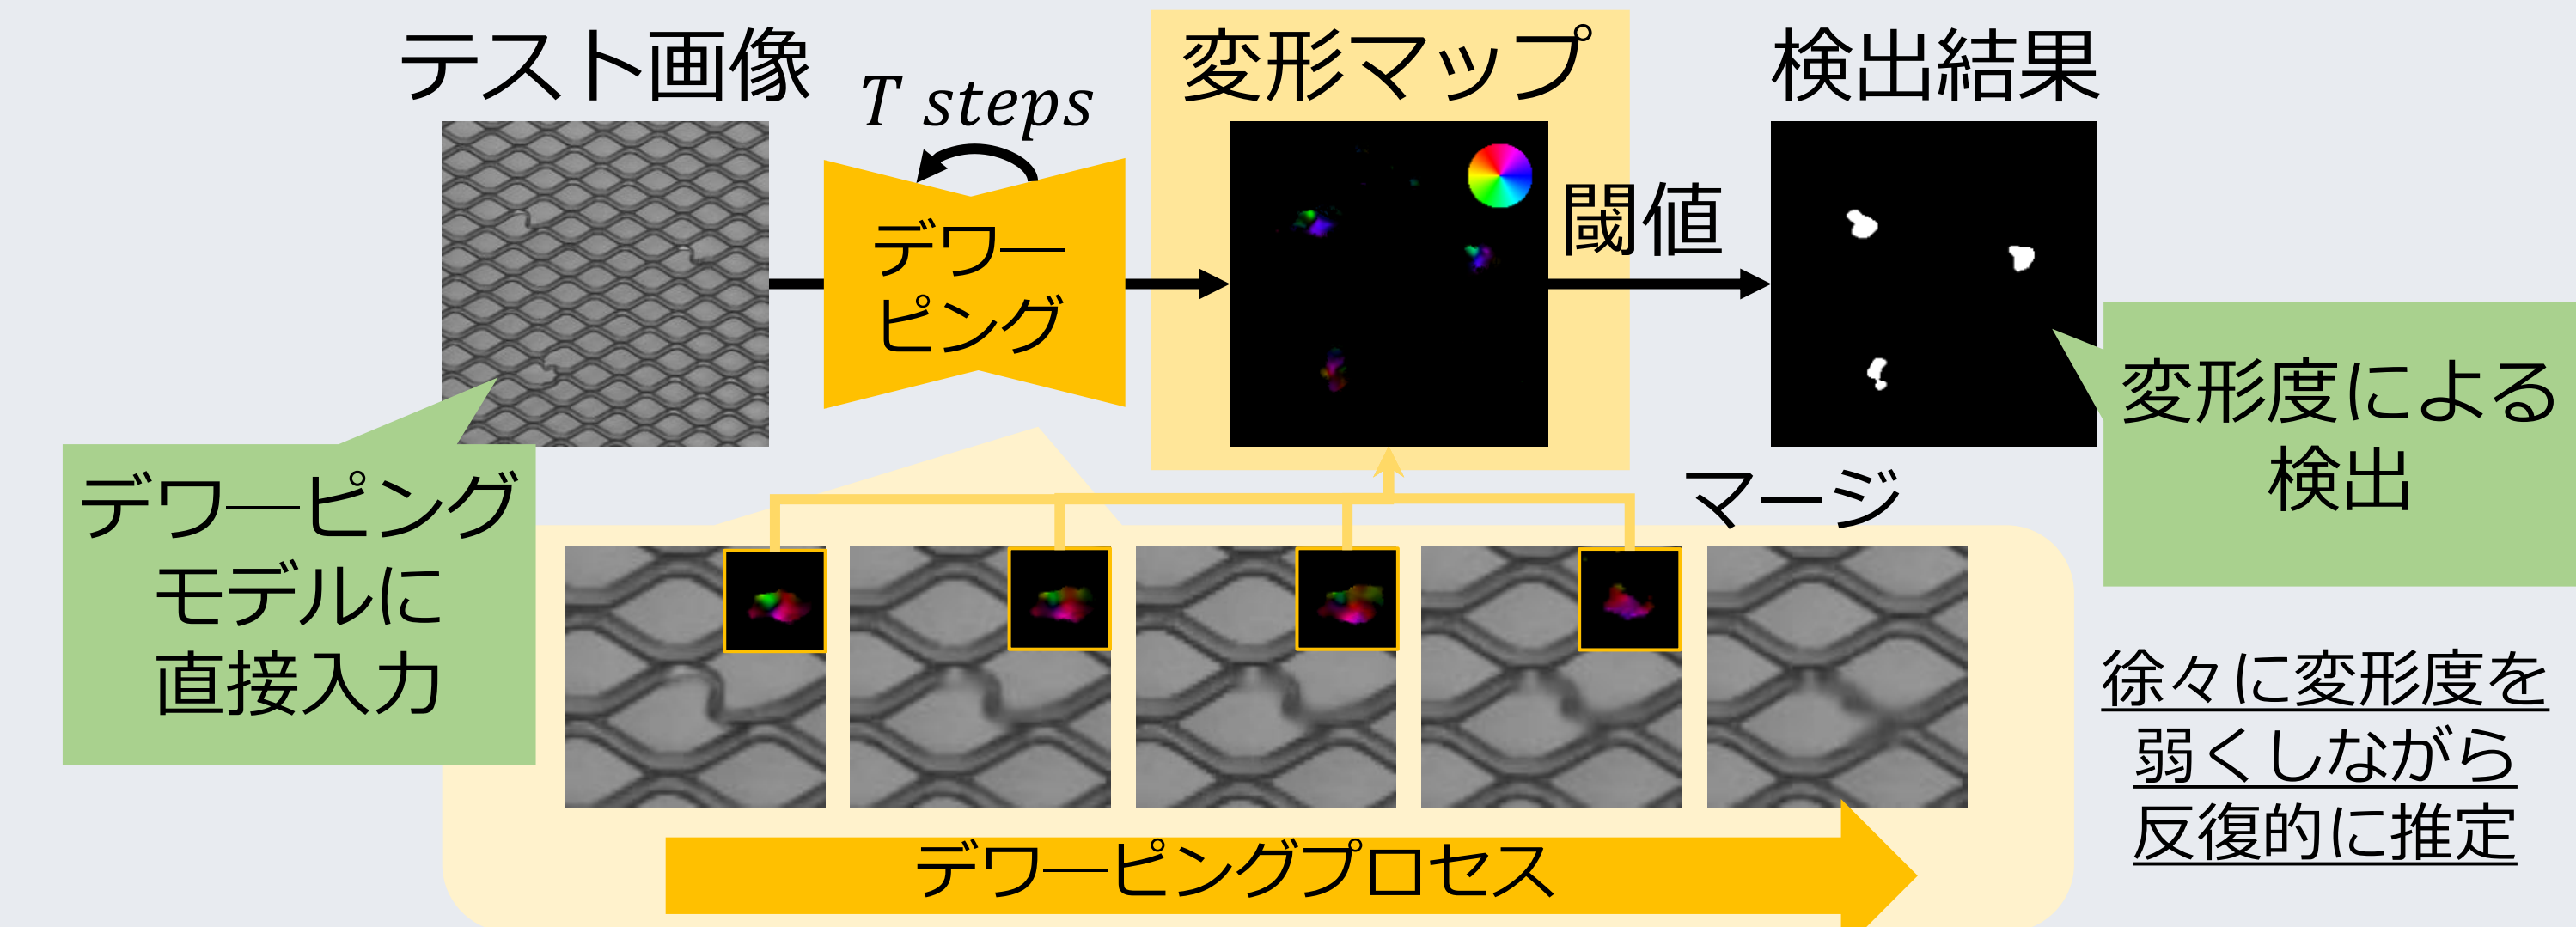
モデルによる変形度の減衰



トレーニング(時刻 t) 3つのロスでデワーピングモデルを学習



テスト 変形マップを反復的に推定し、その大きさによって検出



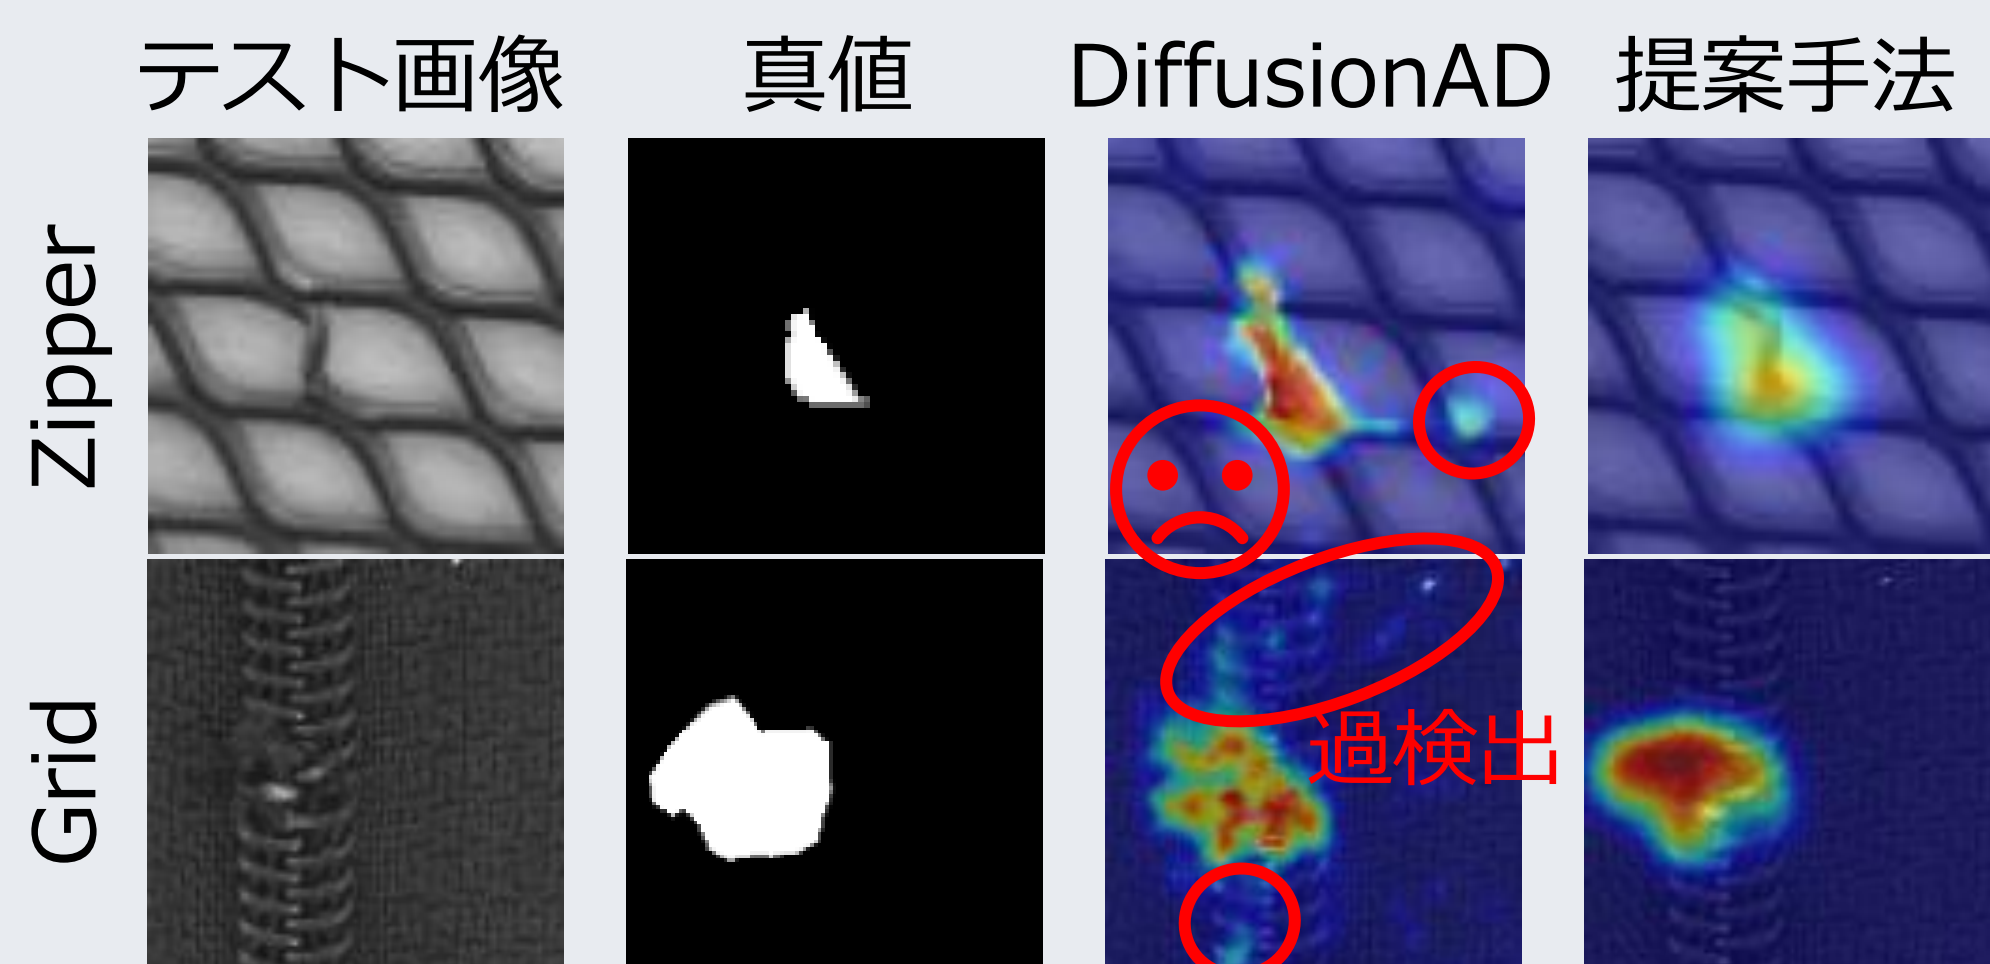
4. 評価

実験条件 デワーピングモデルにはU-Net [Olafら, MICCAI 2015] を利用し、各クラスごとに学習

検出性能の評価 変形が主な不良であるカテゴリにおいてセグメンテーションネットワークを必要とせず最新手法を上回る精度

セグメンテーションネットワーク有

セグメンテーションネットワーク無






	DiffAD Zhangら ICCV'23	DiffusionAD Zhangら arxiv'23	AnomDiff Luら ICCV'23	MDPS Wuら IJCAI'24	提案手法
Grid	99.7	99.7	99.1	99.4	99.4
Tooth brush	99.2	98.8	98.9	98.8	99.3
Zipper	99.0	99.2	97.6	98.5	99.4
平均	99.3	99.2	98.5	98.9	99.4

MVtecAD [Bergmannら, CVPR 2019]における定性結果

MVtecADにおける定量結果 (Pixel-AUROC)

推定変形マップの評価

提案手法によって推定した変形マップの大きさは高精度に変形度を近似可能



MVtecADと自作AnoClipデータセットにおける推定変形マップ

自作AnoClipデータセットによる真の変形度と推定値の関係グラフ