Vol.2020-MPS-127 No.16
2020/3/2

深層畳み込みニューラルネットワークによる建物外装石材画像からのひび検出

鈴木 藍雅[1,2,a)]　柳本 貴司[3,b)]　中村 良平[3,c)]　坂本 成弘[3,d)]　坂無 英徳[1,2,e)]

概要：建物の保守点検において，外壁落下事故に繋がるひび割れの早期発見は非常に重要である．その点検方法の一つとして，外壁面を撮影した画像を元に検査が行われることがあるが，建物の規模によって撮影枚数は数万枚にも及ぶ場合があり，作業者の負担が大きく見落としが生じる危険性もある．特に石材の画像検査においては，模様や陰影とひびとの区別は非常に難しい課題である．そこで本研究では，外壁のひび割れの早期発見作業を支援するために，深層畳み込みニューラルネットワークを用いたひび割れ検出システムを開発した．本システムにおいては，元画像から切り出した小領域ごとにひびを含むかどうかを推定するモデルを訓練し，その推定結果をヒートマップとして元画像に重畳することで，ひびの発見作業を支援するものである．実験では実際の花崗岩の外壁材を用いた大規模建物の外壁データに本システムを適用し，高い精度でひび領域の呈示が可能であることを示した．

キーワード：image inspection, crack detection, deep convolutional neural networks, image recognition

Crack Detection from the External Wall of Stones using the Deep Convolutional Neural Network

Aiga Suzuki[1,2,a)]　Takashi Yanagimoto[3,b)]　Ryohei Nakamura[3,c)]　Shigehiro Sakamoto[3,d)]
Hidenori Sakanashi[1,2,e)]

Abstract: Early detection of the crack in the external wall, which may cause falling incidents, is the critical task in inspection items of building maintenance. As one of the inspection ways, an image-based inspection has an advantage in terms of cost and efficiency; however, it requires much effort in the case of high-rise buildings because of a massive number of taken pictures. Specifically, it is hard to distinguish the cracks in the walls made of natural stones from their complex texture pattern. To support such inspection to decrease oversights, we developed the computer-aided diagnosis system to find wall cracks by using deep convolutional neural networks. This system finds a wall crack and visualizes probabilities of including cracks as a heatmap for each local region. We demonstrated that the system provides proper inference for real buildings by applying to the tower building that has granite wall panels.

1　産業技術総合研究所 人工知能研究センター
茨城県つくば市梅園 1–1–1
2　筑波大学 システム情報工学研究科
茨城県つくば市天王台 1–1–1
3　大成建設株式会社 技術センター
神奈川県横浜市戸塚区名瀬町 344–1
a)　ai-suzuki@aist.go.jp
b)　t-yanagi@isd.taisei.co.jp
c)　nkmruh00@pub.taisei.co.jp
d)　shigehiro.sakamoto@sakura.taisei.co.jp
e)　h.sakanashi@aist.go.jp

1. はじめに

建物を長期にわたって安全に運用するためには，定期的な保守点検作業が非常に重要となる．建物の点検項目は給排水設備，換気設備，非常照明設備など設備機器に関するものから，屋根，屋内の防火及び避難など，建物そのものに関するものまで非常に多岐にわたるが，建物の耐用性および安全に関わる重要な検査対象として外壁が挙げられ

© 2020 Information Processing Society of Japan

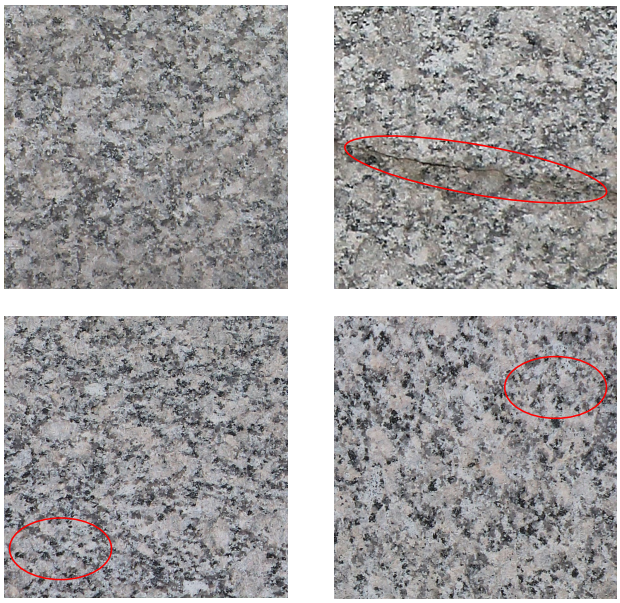

図 1　花崗岩石材パネルに生じるひび割れの例．赤丸で囲った部分にひび割れが生じている．(左上) ひび割れのない正常パネル; (右上) 判別の容易なひび割れの例; (左下・右下) 判別の難しいひび割れの例

る．建物の外壁にはデザイン性や耐用性に優れた建材として石材パネルが用いられるが，経年劣化などにより発生する石材面のひび割れは建物の耐用性や美観を損なうのみならず，破片の剥落により人的被害を伴う重大事故に繋がる恐れがあり，早期発見が非常に重要である．石材パネルのひび割れを発見するための検査手法としては目視検査が一般的であるが，カメラを用いて撮影した外壁面の画像を作業者がまとめて観察する画像検査が行われることがある．

画像検査では，外壁面の撮影に建築の専門知識は不要であるが，その一方で大規模建物の場合は撮影枚数が数万毎にも及ぶことがあり，その検査には大変な労力を要する．特に天然石材パネルのひび割れは，図 1 に示すように石材の模様との判別が非常に難しく，見落としを生じやすいという問題がある．そこで画像検査作業の負荷を軽減し，かつひび割れの見落としを防ぐため，コンピューターによりその作業を支援するシステムの開発が望まれている．

本研究では深層畳み込みニューラルネットワーク (deep convolutional neural network; DCNN) を用いて，壁面画像からひび割れを検出するシステムを開発した．本システムにおいては，石材パネルの画像と対応するひび割れの位置を示したアノテーション画像から，ひび・非ひびのパッチ画像を生成するサンプラにより生成した訓練用データセットを用いて，小領域ごとにひびを含むかどうかを判別するよう DCNN の学習を行う．推論の際には入力された壁面画像を分割した小領域ごとに DCNN にて計算された，「ひびを含む確率」をヒートマップの形で元画像に重畳し，ひび候補領域を呈示することで検査作業の支援を行う．実験においては，実際に大規模建物で撮影した花崗岩の石材パネルの画像に対して提案手法を適用し，良好な分類性能を示すとともに，未知の画像から効率的なひび領域の呈示が行えることを示す．

2. 深層畳み込みニューラルネットワーク (DCNN)

DCNN は深層学習 (deep learning) 技術の一つに数えられる，階層型ニューラルネットワークで，哺乳類初期視覚野の人工モデルであるネオコグニトロン [1] に端を発するモデルである．DCNN は特に画像認識の分野において非常に高い性能を示すことが多数報告されており，近年における画像認識問題のデファクトスタンダードとなっている．従来の画像認識手法と比較した DCNN の利点として，従来は人手で設計していた画像特徴量の抽出プロセスを，誤差逆伝搬法による損失関数の最小化の過程で自動的に獲得できることが挙げられる．

分類問題における DCNN は，入力画像を分類しやすい特徴表現に変換する特徴抽出部と，実際に識別を行う全結合のニューラルネットワークである識別部に大きく大別できる．前段の特徴抽出部では畳み込み処理と，空間プーリング処理がその本質を担っている．畳み込み処理は画像処理における畳み込みフィルタリングに対応した処理であり，入力の画像，あるいは特徴マップに対して複数の畳み込みフィルタを適用することで異なる多チャンネルの特徴マップへ変換を行う．空間プーリング処理は空間サブサンプリング処理とも呼ばれ，特徴マップの局所領域ごとに代表画素を算出し，その空間的解像度を落とす処理である．プーリング処理は特徴マップの次元を削減するとともに，入力の微小移動に対する出力の普遍性を担保する処理である．DCNN はこれらの処理を階層的に積み重ねることによって，入力画像を識別に有用な特徴を捉えた多チャンネルの特徴マップに変換する．

本研究では DCNN のアーキテクチャとして，ResNet-34 を用いた．これは畳み込み層の入力から出力へ恒等写像を介した足し合わせの処理を導入し，畳み込み層で入出力の残差を学習させることで深いネットワークにおける学習の安定性を担保した ResNet[2] と呼ばれるいくつかのモデルのうち，34 層構造を持つ DCNN である．

3. 提案手法

DCNN を用いて画像中のひび領域の検出を行う先行研究として，コンクリートに生じるひびをピクセル単位でひびであるかを分類するセマンティックセグメンテーションのモデルである fully convolutional neural network を用いて検出する [3] が挙げられる．しかし，[3] で対象としている画像は 224x224 と比較的小さいのに対して，本研究で対象とする壁面を撮影した画像は 4000x6000 と非常に大きな画

像であり，セマンティックセグメンテーションモデルの適用は計算量などの観点から困難である．そのため，提案手法では画像の小領域ごとにパッチ画像を抽出し，これらをひび/非ひびの 2 クラスに分類するよう DCNN を学習し，予測の際には小領域のラスタスキャンによって大きな元画像上にひび領域を呈示する．この小領域ごとに認識を行うアプローチにおいて，その学習および推論結果の可視化における提案手法の詳細を以下に述べる．

3.1 適応型パッチサンプラ

DCNN の学習には壁面ひび割れの画像検査従事者が作成した，元画像から石材パネル面を切り出した画像と，画像中のひび位置のアノテーションのマスク画像のペアを用いた．学習データの例を図 2 に示す．

これらの学習画像から学習に用いるパッチ画像をサンプリングする手法として最も単純なアプローチとしては，固定幅のストライドごとに小領域をラスタスキャンする手法が挙げられる．しかし，固定幅のストライドを用いる方式では学習に用いるひびの形状・位置にバリエーションをもたせることができない他，画像に占めるひびの領域は非常に小さいことから，学習に用いるデータセットが強くクラス不均衡になる問題が生じる．そのため，アノテーションマスク画像から多様なひび/非ひびのサンプリング候補領域を生成する適応型サンプラを用いた．適応型サンプラの概要図を図 3 に示す．

適応型サンプラは，実際にサンプリングを行う対象のひびを含む石材の画像と，ひび位置がマークされたアノテーションマスク画像をペアにして用いる．はじめにアノテーションマスク画像のひび位置を表す白画素に膨張 (dilation) フィルタを適用し，パッチサイズ k，マージンパラメータ m を用いて $k+m$ ピクセルの膨張処理を行う．得られた膨張後の白画素位置の集合 $\mathcal{P}$ をひびパッチの中心位置候補として，$\mathcal{P}$ からのランダムサンプリングによってパッチ画像を生成する．ここでマージンパラメータ m は「パッチ画像の端 m ピクセルにはひび領域を含まないようにする」パラメータであり, この処理によって画像の端のごく小さな領域のみにひびが含まれているひび割れ正例パッチが生成されるのを防ぐことができる．また，固定ストライドのメッシュ分割処理とは異なり，ラベルに紐付けてひび，非ひびそれぞれの等数サンプリングを行うことができ，DCNN の学習の際にひび領域の見落としを抑制する効果が期待される．

3.2 元画像を用いた正常学習

アノテーション作業の容易性などの要因から，ひび画像の学習データとして与えられているのは，図 2 に示したように，パネル領域切り出し後の画像と対応するアノテーション画像である．しかし，実際の検査工程においてひび

図 2 学習に用いるひび石材パネル画像 (上) とひび位置のアノテーションマスク画像 (下) の例．パネル画像は目地などを含まないようパネル部のみが切り出され，パース補正，輝度補正が行われている．

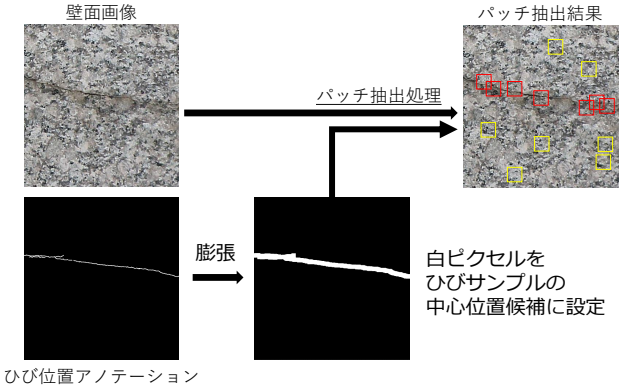

図 3 提案する適応型サンプラの概要図．サンプリング対象の画像と，ラベルと紐付いた位置アノテーション画像からアノテーションされた領域を含むサンプル点を生成し，パッチ画像のランダムサンプリングを行う．

の検出を行う対象画像は，パネルの間の目地やゴンドラレール，窓や背景などのアーティファクトを含む未調整の画像である．切り出し後の画像にはこうしたパネル以外の領域は含まれていないため，切り出し後のパネル画像のみで学習を行う場合，大量の過検出が生じる問題がある．この問題を解決するために，元画像から上述の外壁パネル面以外の領域をサンプリングし，正常 (非ひび) として学習させることで，過検出の抑制を行う．

この外壁パネル面以外のサンプリング処理には，3.1 節で述べた適応型サンプラと同様のアルゴリズムを用いた．

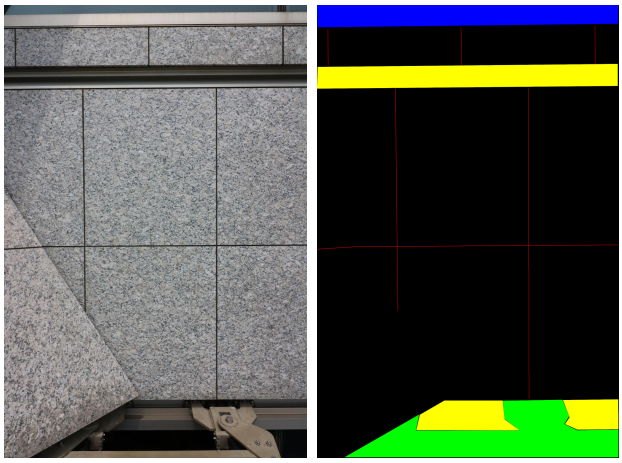

図 4 (左) 正常学習に用いる建物外壁面を撮影した元画像. (右) 正常クラスアノテーション

図 4 に示すように，元画像に対して

赤　目地
青　窓・窓枠
黄色　ゴンドラレール
緑　背景・その他

としてアノテーションを行い，各領域ごとにひび領域の適応型サンプリングと同様の手続きで，パッチ画像のサンプリングを行う．これらのパッチ画像を学習時に正常パネルに加えて正常として学習させることで，過検出の抑制を図る．

3.3 ヒートマップによるひび領域の可視化

本システムの運用において外壁石材パネルのひびの有無に関する最終判断は，構築した認識モデルではなく，画像検査作業者となる人間が下すことを想定している．そのため，作業に際して作業者の視線をうまくひびの候補領域に誘導するための，推論結果の効率的な可視化手法が必要になる．画像認識における検出 (detection) においては，その認識結果は元画像の検出領域へ矩形のバウンディングボックスを重畳する形で可視化されることが多い [4]．しかし，今回対象とするようなひび割れは画像中の長い領域に渡って連続することが多く，またその形状も複雑なため，バウンディングボックスによる可視化ではひび領域を隠してしまい，かえって作業効率の悪化に繋がる．

そのため，本研究では推論結果のひびである確率を示す DCNN のソフトマックス層の出力値に対してしきい値を定め，ひびを含む確率の高い領域をその確率に応じたヒートマップで表示し，元画像とのアルファ合成により重畳する可視化手法を用いた．この可視化手法によってヒートマップの活性のある部分へと作業者の視線誘導を図れる他，元画像が透過しているため，最終的な目視による検査にも影響を及ぼさない形でシステムの予測結果を呈示することができる．

4. 実験

実験では実際の花崗岩の石材パネルを外壁材に用いた，大規模建物の壁面画像からのひび検出性能を検証した．全 68 画像ペアの壁面切り出し画像とひび位置アノテーションのうち，56 ペアを学習データ，残りの 12 ペアをテストデータとして評価を行った．学習・テストデータの分割においては判別が容易なひび，判別の難しいひびの割合が同一になるよう，調整を施した．DCNN には前述の通り ResNet-34 を用い，ImageNet データセットで学習済みのパラメータを初期値とした転移学習を用いた．学習の際の損失関数としては，ひびの見落としを削減するために，ひびの正例ラベルに対して 3 倍の重みをつけた Weighted Cross-Entropy 誤差関数 [5] を用いた．最適化アルゴリズムには AdaBound[6] を用い，その学習率を $\eta = 0.01$ と設定した．学習においては，適応型サンプラから, パッチサイズ 128×128 px, マージン $m = 20$ px として，(正常壁面:ひび割れ:壁面以外)=(1:1:2) の割合でサンプリングし，訓練誤差が十分に収束するまで学習を行った．

5. 結果

学習の結果，判別しきい値を 0.5 とした際のパッチ単位での精度 0.890, 再現率 0.715, F1 0.793 を達成した．また判別しきい値を変化させた際の ROC 曲線を図 5 に示す．このときの ROC-AUC は 0.908 であった．

テストデータに含まれるひびを撮影した壁面の元画像に対して，ヒートマップ表示しきい値 $p > 0.5$ として，ひび領域の検出を行った結果を図 6 に示す．これを見ると判別の難しい断続的なひびに対しても，正しく検出ができていることが分かる．画像上部の目地などに多少の過検出があるものの，その確度は低いことがわかる．パネル切り出し後の画像のみからのひび正例の学習によってもひびの検出が可能であること，また，元画像を用いた負例の正常学習を組み合わせることで，元画像における過検出を削減できていることがわかる．これは切り出し後のひび画像と切り出し前の未調整のパッチ画像間での混合ドメイン学習 [7] の例になっていると言えよう．

6. おわりに

本稿では，建物の保守点検作業における外壁の石材パネルの画像検査を補助する認識システムについて述べた．本システムでは DCNN を，画像の小領域ごとにひびを含むかどうかを判別するよう学習を行った．学習に際しては，ひび/非ひびクラスの不均衡問題の解消，およびひびの形状に多様性を持たせるための適応型サンプラによるランダムサンプリングを用いた．また，学習データに用いるパネル切り出し画像と実際に検査対象となる切り出し前の元画像とのドメイン間の差異による過検出抑制のため，混合ド

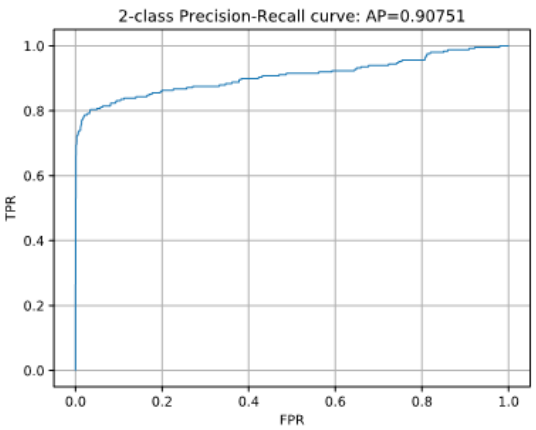

図 5 ResNet-34 によるパッチ単位での ROC 曲線．縦軸: 真陽性率 (true-positive rate; TPR), 横軸: 偽陽性率 (false-positive rate; FPR)

メイン学習に基づく正常学習を行った．実験では，実際の花崗岩の石材パネルを用いた大規模建物の外壁画像に対して提案手法を適用し，ひびの予測確率のヒートマップによる可視化を行うことで，ひび部の効率的な発見を行えることを示した．

参考文献

[1] Fukushima, K.: Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biological cybernetics*, Vol. 36, No. 4, pp. 193–202 (1980).

[2] He, K., Zhang, X., Ren, S. and Sun, J.: Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778 (2016).

[3] Dung, C. V. et al.: Autonomous concrete crack detection using deep fully convolutional neural network, *Automation in Construction*, Vol. 99, pp. 52–58 (2019).

[4] Zhao, Z.-Q., Zheng, P., Xu, S.-t. and Wu, X.: Object detection with deep learning: A review, *IEEE transactions on neural networks and learning systems*, Vol. 30, No. 11, pp. 3212–3232 (2019).

[5] Cui, Y., Jia, M., Lin, T.-Y., Song, Y. and Belongie, S.: Class-Balanced Loss Based on Effective Number of Samples, *CVPR* (2019).

[6] Luo, L., Xiong, Y., Liu, Y. and Sun, X.: Adaptive Gradient Methods with Dynamic Bound of Learning Rate, *Proceedings of the 7th International Conference on Learning Representations*, New Orleans, Louisiana (2019).

[7] 河内祐太，野里博和，村川正宏，坂無英徳：深層畳み込みニューラルネットを用いた内視鏡画像診断支援における混合ドメイン学習，情報処理学会コンピュータビジョンとイメージメディア研究会， Vol. 119, pp. 135–138 (2019).

© 2020 Information Processing Society of Japan

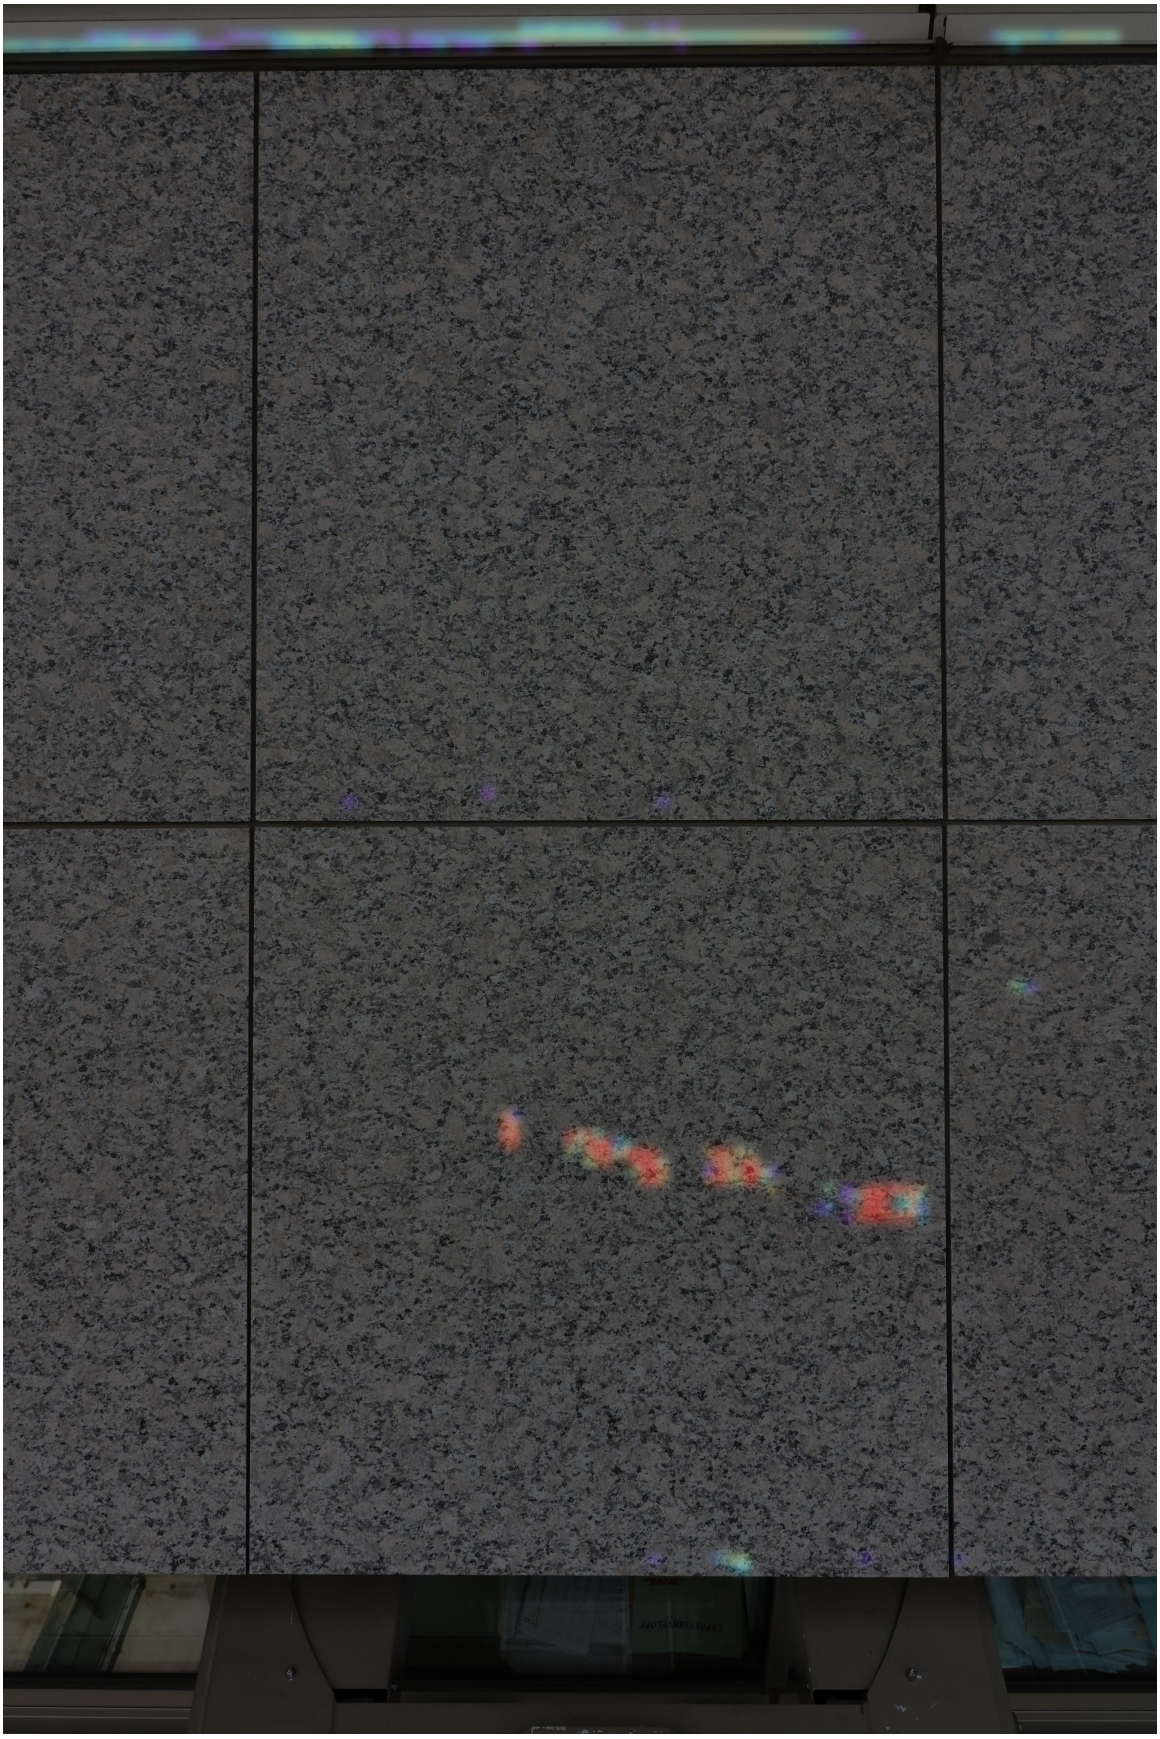

図 6 元画像からの検出結果例．赤くヒートマップが重畳されている部分が，高い確率でひびが存在していると判断された領域．下部パネル中央のヒートマップが活性している領域にひびが存在している．画像上側などに見られる青〜緑の低確率の活性部は過検出．

© 2020 Information Processing Society of Japan