

# 深層学習におけるネットワーク及び出力値の違いによる 定点観測画像からの土砂災害危険度分類精度の評価

徳本 敬祐<sup>†</sup> 小林 真<sup>†</sup> 新 浩一<sup>†</sup> 西 正博<sup>†</sup>

<sup>†</sup>広島市立大学大学院情報科学研究科

## 1 はじめに

広島市では土砂災害が発生し、多くの人的被害が発生している。平成30年7月豪雨の際、広島県において避難率が約0.7%であった[1]。我々は、早期避難を促し、人的被害減少を目的として土砂災害監視カメラシステムの開発を行っており、危険箇所の撮影画像をWebページに公開することで地域住民にも確認できるようにしている[2]。しかし、危険箇所の画像だけでは避難が必要であるかの判断が難しい。そこで、より分かりやすいパラメータとして危険度を数値で示すことが有効であると考えた。本研究では深層学習を用いて、定点観測画像を3段階の危険度への分類を試みた。提案した深層学習のネットワークの分類精度、危険度として提示するのに適切な出力値の評価を行った。

## 2 深層学習を用いた定点観測画像危険度分類手法

### 2.1 使用データ

土砂災害監視カメラシステムは広島市内の8箇所に設置されている。広島市河内地区の撮影画像を図1に示す。本研究では取得した定点観測画像に対して有効なネットワーク・出力値を評価するために広島市河内地区の画像を使用した。本画像は5秒おきに24時間連続で撮影している。使用する期間は2017年1月1日から2021年11月30日である。2017年1月1日から2020年12月31日までのデータを学習用データ、2021年1月1日から2021年11月30日までのデータを検証用データとして用いた。

画像データを分類するラベルを0:平常時、1:危険時、2:非常時の3クラスとし、これを危険度とした。学習データに対する正解ラベルは土砂災害に関する注意報・警報を発令する基準である土壌雨量指数を使用した[3]。広島県佐伯湯来の気象庁の過去データの内、10分毎の降水量をもとに土壌雨量指数を算出した。広島市の基準を土壌雨量指数の閾値とし、90未満で危険度0、90以上115未満で危険度1、115以上で危険度2として定義し、10分間隔で抽出した[4]。

### 2.2 使用ネットワーク

図2に使用したネットワークのアーキテクチャを示す。畳み込み処理時のフィルタサイズが大きいくほど表現力は上がるが計算量が増えるという特徴がある。一般的な動物や物体の



図1: 河内地区の定点観測画像

分類には $3 \times 3$ フィルタが利用されることが多い。しかし本研究で用いる画像は水面の濁りや流れの激しさなどの特徴を捉えなければならないため、従来の小さなフィルタサイズで十分であるかは不明である。そこで提案するネットワークでは複数のフィルタサイズの畳み込みを並列して行い、学習の過程で適したフィルタサイズの畳み込み処理が大きな影響を持つよう設計した。Rethinking the Inception Architecture for Computer Visionでは $1 \times n$ と $n \times 1$ の畳み込み処理を順に行うことは $n \times n$ と同等の特徴抽出が可能であり、計算量の削減になると述べられている[5]。フィルタサイズが7以上の畳み込み処理に関しては、フィルタサイズ $n$ に対して $1 \times n$ と $n \times 1$ の畳み込み処理を順に行うことで実現している。また畳み込み処理を多数行っているため、勾配の消失を防ぐために各層でフィルタサイズ $1 \times 1$ の畳み込み処理の結合を行った。

### 2.3 出力値

深層学習では最終的にそれぞれのクラスである確率を出力する。従来のアルゴリズムでは出力された確率のうち、最も確率の高いものを分類結果として出力する。しかしデータによっては近い時間の画像であっても激しく変動する場合があります。危険度として提示するには不適切である。そこで3分間あたりの最頻値を出力値として評価した。本来、危険度は連続値であるが、従来のアルゴリズムでは離散値となっている。それぞれのクラスである確率から期待値を算出して、3分間あたりの移動平均を連続的な値として出力可能かを評価した。

## 3 評価

### 3.1 ネットワーク

図3にネットワーク別の正解率の推移を示す。横軸は学習の段階である。提案したネットワークと既存のネットワークであるInceptionResNetとVGG16を比較した[6, 7]。全てのネットワークが40エポック以降での正解率が頭打ちになっているため、学習回数は十分であると言える。表1に学習間の正解率の計算値を示す。標準偏差はVGG16と提案ネットワークが小さく、正解率の変動が小さいことがわかる。Inception Res Netは正解率の変動が大きい。これは学習における重みの変動が出力結果に与える影響が大きくなるようなネットワーク構造になっているためだと考えられる。また平均値は、Inception Res Netと提案したネットワークが約

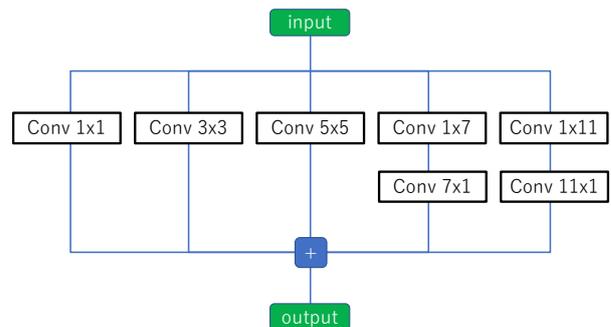


図2: ネットワークのアーキテクチャ

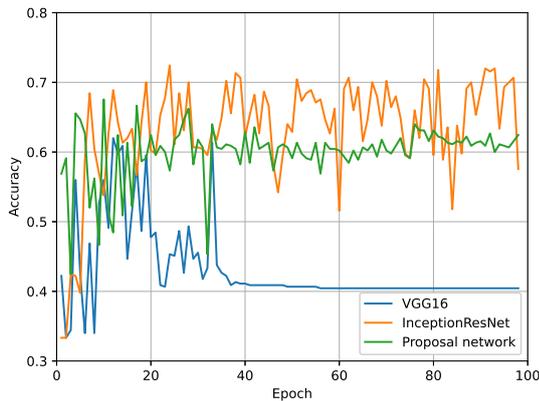


図 3: ネットワーク別正解率

表 1: 学習間の正解率の計算値 ※ 40 エポック以降

	InceptionResNet	VGG16	Proposal network
平均	0.634	0.430	0.600
標準偏差 ※	0.048	0.001	0.014
最大値	0.724	0.620	0.675

表 2: ラベルごとの予測回数

		予測値		
		0	1	2
正解 ラベル	0	146	1	0
	1	93	6	51
	2	7	5	138

6 割, VGG16 が約 4 割であった。前者のネットワークは残差接続を用いることで畳み込み層が多数組み込んである。さらにフィルタサイズ 7 以上の畳み込み処理が複数回行われているため、これらの層が分類精度の向上に関連していると考えられる。表 2 に、提案したネットワークの危険度の正解に対するネットワークの予測回数を示す。正解ラベル 0 と 2 の正解率は高かったが、正解ラベル 1 の正解率は 4%程度であった。これより、平均的に誤予測をしているわけではなく、特定のラベルに対する正解率が著しく低い事がわかる。

提案したネットワークは Inception Res Net と比べて、学習の進行に伴う正解率のばらつきは少なかった。しかし分類精度は劣っていた。安定して高い分類精度を保つことが課題である。

### 3.2 出力値

図 4 に 2020 年 7 月 24 日の各出力値の時系列変化を示す。土壌雨量指数の値より、11 時までは正解ラベルが 0、11 時から 15 時までが正解ラベルが 1、15 時以降が正解ラベル 2 である。従来手法での予測値は、大方正解ラベルと同じ推移をしている。しかし 11 時周辺や 18 時周辺のように予測値が安定しない場合がある。これは降雨などの影響で学習済みの特徴抽出が適合しなかったと考えられ、この出力は危険度として提示するには不適切である。3 分間あたりの最頻値は、従来手法の予測値の変動のうち 7 時から 8 時の変動と 11 時周辺の変動が抑えられている。18 時周辺の変動は最頻値も影響を受けており、最頻値をとる時間幅を広くする必要がある。期待値の移動平均は、従来手法や最頻値と類似した変動をしており、連続値として緩やかに変化することはなかった。

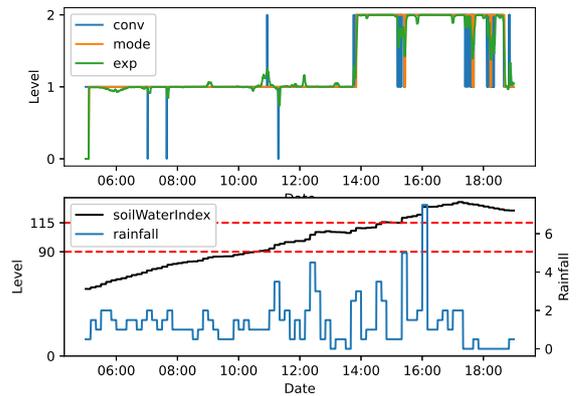


図 4: 各出力値の時系列変化

## 4 おわりに

本研究では、深層学習による土砂災害危険箇所の定点観測画像の危険度分類において、ネットワークと出力値の評価を行った。提案したネットワークは、約 6 割の正解率を安定して記録した。出力値の検討により、最頻値が予測値の出力を安定化させることを確認した。

謝辞 本研究の一部は総務省 SCOPE 社会展開指向型 19168001, JSPS 科研費 17K06437, 19K24352, 20K19787 のもとに行なった。

### 参考文献

- [1] 内閣府. 平成 30 年 7 月豪雨による被害状況等について. [http://www.bousai.go.jp/updates/h30typhoon7/pdf/300708\\_h30typhoon7\\_09.pdf](http://www.bousai.go.jp/updates/h30typhoon7/pdf/300708_h30typhoon7_09.pdf). (参照 2021 年 9 月 17 日).
- [2] 西正博, 古川達也, 新浩一. 電源自立型の土砂災害監視カメラシステムの構築と評価. 情報処理学会論文誌, Vol. 58, No. 3, pp. 736–744, 2017.
- [3] Yasuo Ishihara and Shigeki Kobatake. Runoff model for flood forecasting. *Bulletin of the Disaster Prevention Research Institute*, Vol. 1, No. 29, pp. 27–43, July 1979.
- [4] 気象庁. 警報・注意報発表基準一覧表. [https://www.jma.go.jp/jma/kishou/known/kijun/hiroshima/kijun\\_3410000.pdf](https://www.jma.go.jp/jma/kishou/known/kijun/hiroshima/kijun_3410000.pdf). (参照 2021 年 9 月 17 日).
- [5] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens, and Zbigniew Wojna. Rethinking the inception architecture for computer vision. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2818–2826, 2016.
- [6] Christian Szegedy, Sergey Ioffe, and Vincent Vanhoucke. Inception-v4, inception-resnet and the impact of residual connections on learning. *CoRR*, Vol. abs/1602.07261, pp. 1–12, 2016.
- [7] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition, 2015.