

ディープラーニングによる建物特性の抽出と台風被害想定の手法 Identifying building characteristics by deep learning and a method of assessing typhoon losses

岡崎 豪^{*1}
Takeshi Okazaki

レブル オリオル^{*1}
Oriol Gaspa Rebull

^{*1} エーオンベンフィールドジャパン株式会社
Aon Benfield Japan Ltd.

In order to facilitate typhoon damage assessment, we propose an evaluation method that can predict the total number of damaged houses with high accuracy immediately after a disaster. The exposure was developed in building level and the buildings characteristics were taken into consideration such as construction year, roof shape, and roof area. Since the roof related information was not collected in any industry, analyzed by deep learning applied to aerial imageries. When applied to three typhoons in 2015 and validated the method, we confirmed that it can be well reproduced in any prefecture.

1. はじめに

台風による被災状況を早期に把握することは、損害保険会社や共済団体(以下、まとめて損保業界と呼ぶ)にとって損害査定を円滑に行うために不可欠なことである。しかし、勢力の強い台風が上陸した場合、被災地域は広域におよび、被災の全体像の把握には少なくとも数日間を要している。この要因として、被災状況を把握する主な方法が、電話での伝達となっていることが挙げられる。もしこの手段の代替となるシステムを開発し、台風による被害を被災直後に把握できれば、被災地に応援要員を急派すべきかの意思決定を早期に行うことができ、被災者への迅速な支援が可能となる。

現状、行政機関はヘリコプターからの映像、航空写真や衛星画像などから被災の全容を把握している。また、今後は携帯電話の通信情報、SNSの情報も活用される計画である。しかし、いずれも被災から1~3日後に得られる情報であり、被災直後には得られない。

気象庁は台風の進路予報の他、気象警報・注意報、最大風速などの気象情報を発表しており、気象の専門家であれば、これら情報から強風が発生する地域を推定することはできる。しかし、被害想定には建物に係わる情報も必要となり、気象情報のみから推定することには限界がある。

内閣府は地震防災情報システム(DIS: Disaster Information Systems)を開発し、平成8年4月から運用を開始している[内閣府 17]。このシステムは地震の被災状況を推定するものであり、台風は対象としていない。損保業界では1990年代から台風シミュレーションモデル(以下、台風モデルと呼ぶ)を開発し、継続的に改善している[岡崎 16]。各社はこの台風モデルから得られる被害想定の結果を経営判断の一部として活用している。しかし、それらシステムやモデルの推定の精度には限界があり、現状は被害の規模感を掴む位置付けとなっており、精度の向上が課題となっている。

以上の背景において、本研究では、被災直後に被災状況を把握でき、且つ高い精度で被災状況を予測できるシステムの開発に取り組んだ。まず被災直後に被災状況を把握できるようにするため、気象庁の地上観測網で記録された風速データを入力値とした。このデータは観測から1時間以内に発表されるた

め、ほぼリアルタイムでの分析が可能となる。風速データは気象レーダーや数値予報モデルからも得られるが、地表面の観測にはAMeDASなどの地上観測網で観測された風速データが最も適しており、それを選択した。

精度の向上に対しては、建物特性を考慮することで改善した。例えば、台風により最も被害が発生しやすい部位は屋根である。そのため、屋根形状などのリスクファクターをモデルに反映できれば、精度が向上すると考えられる。そこで、本研究ではディープラーニングを航空写真に適用し、個々の建物の屋根形状を分析した。そして、それら建物特性を考慮して被災状況を予測するシステムを開発した。なお、本研究で用いる航空写真は通常時の建物の画像であり、被災直後の航空写真ではない。また、本手法は被災前後に撮影された航空写真を比較する手法とは異なる。以下、被害想定の手法、使用したデータを示したのち、2015年の台風に基づいて検証した結果を示す。

2. 被害想定の手法

2.1 評価の手順

地上観測網の風速データ、建物データベース、罹災率曲線に基づいて台風時の被災件数を予測する手順を示す。評価のフローを図1に示す。

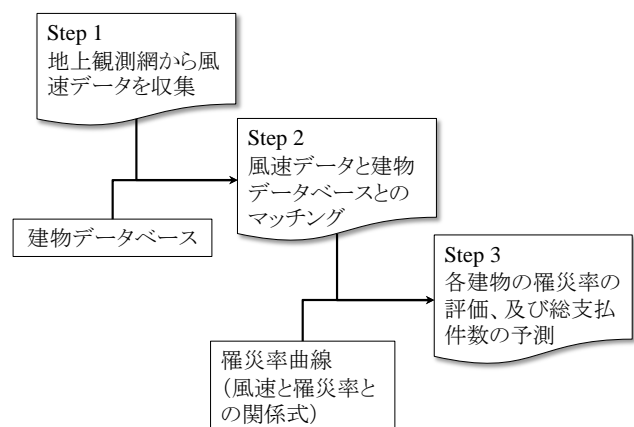


図1 被害想定の評価手順

連絡先: 岡崎 豪, takeshi.okazaki@aonbenfield.com, エーオンベンフィールドジャパン株式会社, 03-4589-4237, 東京都千代田区永田町 2-10-3 キャピトルタワー11階

Step 1 において、台風通過時に観測された風速データを取得する。Step 2 において、建物データベースに含まれる建物の位置情報から、各建物が受ける風速を判定する。Step 3 において、風速と罹災率曲線から、各建物の罹災率を評価する。罹災率とは、建物に被害が発生する確率を意味する。これらステップにより、建物ごとに罹災率を評価し、それらを合計することで 1 台風による支払件数の合計を予測する。支払件数とは損保業界が保険契約者に保険金を支払う件数を意味する。以下、それぞれのデータの内容を示す。

2.2 地上観測網の風速データ

気象庁は AMeDAS, 気象台, 測候所, 特別地域気象観測所において観測された風速データを website で配信している。2017 年 1 月時点の総観測地点数は 927 であり、この観測網の空間的な間隔は約 20km² に相当する。所在地の分布を図 2 に示す。これら地上観測網において測定された風速データは、測定から約 40 分後に入手できる。

風速の測定値には、風速(平均風速とも呼ぶ)と瞬間風速がある。風速は前 10 分間の平均値であり、瞬間風速は前 3 秒間の平均値である。風速計は 0.25 秒間隔で観測するため、瞬間風速は 12 個の観測値の平均値に相当する。そして、ある期間中の風速の最大値を最大風速、ある期間中の瞬間風速の最大値を最大瞬間風速と呼ぶ。

友清・前田は、台風による建築物の被害は最大風速よりも最大瞬間風速の方が相関の高いことを報告しており[友清 09], 本研究でも最大瞬間風速を採用した。また、ここでの期間とは、それぞれの台風の発生から消滅までの期間に相当する。



図 2 地上観測網(AMeDAS, 気象台, 測候所, 特別地域気象観測所)の所在地

2.3 建物データベース

既往の損保業界の台風モデルは市区町村や郵便番号などの区分で契約データを集約し、それら区分で支払件数を評価することが一般的である。これは膨大な契約データに対応するための実務的な処置と言える。しかし、この扱いにより同じ構造であれば、すべて同じ罹災率と評価している。実際は同じ構造でも、建築年や屋根形状などが異なれば、罹災率も異なることが報告されている。既往の台風モデルはこの建物特性を考慮していないため、精度の向上に限界があったと言える。

そこで、本研究では建物特性を考慮した建物データベースを構築した。一般に風災の被害に影響を与えらるる建物

特性を表 1 に示す。これら建物特性のうち、データが得られた建築年(新築年), 階数, 屋根材, 屋根の経年劣化/状態, 屋根面積, 屋根形状, 外壁を対象として検証した。

表 1 風災に係わる建物特性の一覧

| 建物特性 | 検証 | 適用 |
|------------|----|----|
| 住宅性能 | | |
| 物件用途 | | |
| 建築年(新築年) | ✓ | ✓ |
| 建物の階数 | ✓ | |
| 屋根材 | ✓ | |
| 屋根の経年劣化/状態 | ✓ | |
| 屋根面積 | ✓ | ✓ |
| 屋根形状 | ✓ | ✓ |
| 屋根との固定 | | |
| 屋根の釘の数 | | |
| 筋交いによる固定 | | |
| 建物基礎との固定 | | |
| 外壁 | ✓ | |
| 屋外設備 | | |
| 開口部の対策 | | |

建築年, 階数, 屋根材, 外壁は損保業界の契約データの情報を用いた。屋根の経年劣化/状態は屋根の汚れ, すなわち屋根の色との相関が高いことから、屋根の色の状態から判別した。具体的には、航空写真の画像をグレースケールに変換した後、グレイヒストグラムのピーク値を評価し、ピーク値が低ければ屋根が劣化していると判別した。屋根面積は航空写真から個々の建物の屋根部分に相当する面積を計測した。屋根形状はディープラーニングを航空写真に適用することで判別した。航空写真の撮影時期は地域により異なるが、2016 年 6 月時点における最新の画像を使用した。

ディープラーニングの適用においては、ランダムに選択した建物の画像 2,700 枚を訓練データとして用意し、それぞれの屋根形状を目視でラベリングした。屋根形状は陸屋根, 方形屋根, 寄棟屋根, 切妻屋根, 入母屋屋根の 5 つに分類した(図 3)。それら画像により学習したアルゴリズムを別の 300 枚のテストデータに適用し、テスト誤差を確認した。ディープラーニングのフレームワークは Chainer を選択し、ネットワークは Alexnet, Googlenet, NIN (Network in network)を試行し、テスト誤差の結果とメモリ使用量の観点から最終的に NIN を選択した。画像のサイズは 256x265, ミニバッチは 10, エポック数は 54 とした。学習曲線の推移を図 4 に示す。




図 3 日本の屋根形状の分類

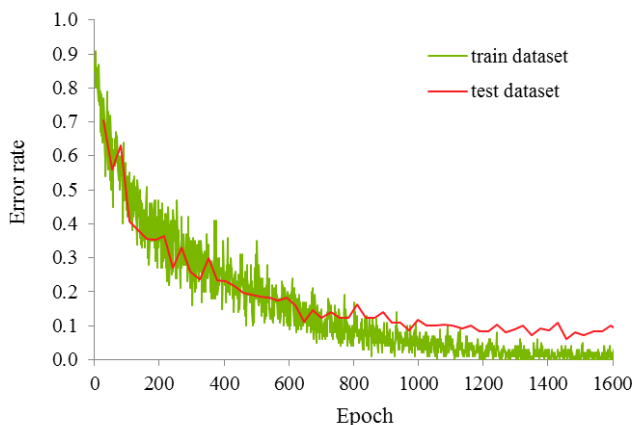


図4 学習曲線の推移(屋根形状の分類)




図5 建物データベースのカバーエリア(全国のすべての建物が含まれる)

過去のロスデータに基づいて建物特性を検証した結果、最終的に罹災率との相関が高かった建築年、屋根形状、屋根面積を風災の建物特性として採用した。これら建物特性は全国のすべての建物を対象として構築している(図5)。

2.4 罹災率曲線

罹災率とは、災害により被害が発生する確率を意味する。すなわち、罹災率は損害額の大小とは関係なく、被害の有無を評価する指標となる。そして、罹災率曲線とは最大瞬間風速と罹災率との関係式を意味する。本研究で用いた罹災率曲線は保険の目的別(建物と家財)、構造別(木造、コンクリート造、鉄骨造など)に構築されている。この罹災率曲線と最大瞬間風速から建物ごとに罹災率を評価した。

罹災率を評価した後、建物特性を反映させるため、罹災率に補正を加えた。過去のロスデータに基づいて分析したところ、屋根面積が大きくなるほど罹災率は高くなり、建築年が古いほど罹災率が高くなる。また、屋根形状は入母屋屋根の罹災率が他の形状よりも高くなることが確認された。これら傾向を反映させるべく、ロスデータに基づいた適切な修正係数を設定し、補正を加えた。

3. 検証

本手法を2015年の3台風のロスデータに適用し、その予測誤差を検証した。以下、台風の概要、比較結果、今後の課題を示す。

3.1 台風の概要

検証においては、2015年の台風のロスデータを使用した。2015年には4つの台風が日本に上陸し、そのうち台風11号、15号、18号が大きな被害を及ぼした。図6に3つの台風の経路を示す。台風11号は7月16日23時頃、中心気圧965hPaの勢力で高知県室戸市付近に上陸した。台風15号は8月25日、中心気圧945hPaの勢力で午前4時頃に鹿児島県阿久根市付近を通過した後、午前5時過ぎに熊本県宇城市付近を通過し、午前6時過ぎに955hPaの勢力で熊本県荒尾市に上陸した。台風18号は9月9日午前10時過ぎに中心気圧990hPaの勢力で愛知県西尾市付近に上陸した。



図6 2015年に上陸した3台風の経路

3.2 比較結果

図7~9に台風により実際に発生した件数(以下、実績件数と呼ぶ)と本手法により再現した件数(以下、予測件数と呼ぶ)との比較を示す。これらの結果から、いずれの県においても予測件数は実績件数に近い結果となっていることが確認できる。従来の台風モデルでは、建物が集積している都市部では予測件数が過大評価、地方では予測件数が過小評価となる傾向があった。そして、その要因は地域性と呼ばれるものであるとされてきた。例えば、地方の木造は建築年が古く、入母屋屋根の建物が多いことから、同じ風速でも罹災率が高くなる傾向がある。従来の台風モデルでは、これら情報が反映されていなかったが、本手法では建築年や屋根形状などの建物特性を考慮することで改善した。また、従来のモデルは契約データを郵便番号や市区町村で区分しているが、本手法は建物別に区分していることから、GISで描画した際、損害査定に役立つ多くの情報を画面に表示することができる。なお、図7~9の件数は建物特性の情報が得られた一部の母集団を対象として比較しており、実際に発生した総支払件数とは一致しない。




図7 台風15号による支払件数の比較




図8 台風11号による支払件数の比較




図9 台風18号による支払件数の比較

状、屋根面積である。屋根形状に関する情報は、損保業界を含めたいずれの業界でも保有していなかったことから、ディープラーニングを航空写真に適用することで判別した。2015年の3台風のロスデータに本手法を適用し、その予測誤差を検証したところ、いずれの県においても予測件数は実績件数に近い結果となった。

本システムは損保業界向けに開発したものであるが、今後、行政機関、防災専門機関(消防、病院等)、民間事業会社(インフラ、修理業者、修理業者等)などにおいても活用できる可能性がある。

参考文献

[内閣府 17] 内閣府, 地震防災情報システム(DIS), アクセス日時 2017年3月3日

<http://www.bousai.go.jp/kazan/kakonotaisaku/sinkasai/s308.htm>

[岡崎 16] 岡崎豪, 損害保険業界における台風モデルの活用, 日本風工学会誌, 日本風工学会, Vol. 41, No. 2 [No. 147], pp. 152-160, 2016.

[友清 09] 友清衣利, 前田潤滋, 強風による住家建物被害の拡大に及ぼす影響因子の抽出法に関する試みー強風被害発生要因の分析への構造物特性指標の利用例ー, 日本建築学会構造系論文集, 日本建築学会, Vol. 74, No. 642, pp. 1423-1431, 2009.

3.3 今後の課題

精度向上に関して、大きく2つの課題がある。1つは風速の観測地点数である。2017年1月時点の総地点数は927点であり、これは観測網が20km²間隔であることを意味する。この観測網の密度は都道府県レベルで風速の状況を把握するには十分であるが、建物レベルで把握するには不十分である。気象庁がAMeDASの観測地点数を大きく増やす計画はなく、信頼性の高い風速データを増やす方法が課題となっている。一方、観測とは別のアプローチとして、TwitterやSNSによる情報を活用する方法がある。Twitterなどの情報から局地的に大きな風速が発生したとされる場合、その地域の風速を補正する方法となる。

もう一つの課題は航空写真の解像度である。本研究で使用した航空写真の解像度は20~50cmであり、屋根形状の判別は可能である。しかし、これらの解像度では屋根瓦やスレート一枚一枚を判別することは困難である。将来的にドローンなどの撮影により、瓦の一枚一枚が判別できるようになれば、ディープラーニングを用いた屋根の劣化状態の把握が可能となる。また、被災前後の画像解析による一部損の被災判定も可能となること期待される。

4. まとめ

台風の損害査定を円滑に行うことを目的として、発災直後に被災状況を把握でき、且つ高い精度で被災状況を予測できる評価手法を提案した。精度を向上させるため、契約データは建物区分とし、建物特性を考慮した。建物特性は建築年、屋根形