

LSTM を用いた諸災害における罹災証明書発行件数の予測
 Prediction of the number of certification in various disasters with LSTM

飯棲 俊介[†]
 Shunsuke IIZUMI

大枝 真一[‡]
 Shinichi OEDA

1. はじめに

災害が発生すると、住民は家屋の倒壊情報を書き込んだ罹災証明書を市町村などの行政機関に提出するが、大規模災害の直後は日々の生活や家屋の修復などに手一杯となり、提出できるまでの時間にはタイムラグが生じる。このタイムラグの発生によって自治体の窓口の混雑予測ができないため、適切な数の職員を配置することが難しい。そこで、自治体がネット上に公開している PDF データから罹災証明書の発行件数を抜き出して、この遅れを解析する。データは過去に規模の大きかった台風、地震、洪水といった種類の異なる災害時のものを用いて比較する。また日付毎に提出者の数を時系列の予測を行う LSTM を用いて予測する。この遅れや提出者数を予測することにより、自治体への提出者数のピークを予測して市役所に提言することで、災害時に適切な職員人数の配置に役立てることができると考える。

2. LSTM(Long Short-Term Memory)

LSTM は、時系列を扱う RNN(Recurrent Neural Network) を改良したモデルであり、RNN に比べ、長期間の依存関係を学習できるモデルとなっている。LSTM の構造を図 1 に示す。また、図 1 のモデルの時間 t における出力は以下の式 (1)~(6) で表される。

$$f_t = \sigma(W_f x_t + R_f h_{t-1} + b_f) \quad (1)$$

$$i_t = \sigma(W_i x_t + R_i h_{t-1} + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c x_t + R_c h_{t-1} + b_c) \quad (3)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (4)$$

$$o_t = \sigma(W_o x_t + R_o h_{t-1} + b_o) \quad (5)$$

$$h_t = o_t \odot \tanh(C_t) \quad (6)$$

W_*, R_* は重み行列, b_* は重みバイアス, σ はシグモイド関数 $\sigma(x) = \frac{1}{1+e^{-x}}$, \odot はベクトルの要素同士の積 (アダマール積) を表す。 f_t, i_t, o_t はそれぞれ忘却ゲート, 入力ゲート, 出力ゲートと呼ばれる, $0 \sim 1$ の範囲の要素を持つベクトルである。これらのベクトルと内部状態をアダマール積で計算することにより、内部状態をどれだけ引き継ぐか (忘却), 新たな入力をどれだけ取り込むか (記憶), 内部状態から何を出力するかが決定され、過去の情報を引き継いで予測を行うことが可能になっている。




図 1 LSTM の構造

3. 実験に用いるデータ

本研究では、過去に被害の大きかった災害である令和元年房総半島台風 (台風 15 号), 令和元年東日本台風 (台風 19 号), 平成 28 年広島土砂災害, 平成 28 年熊本地震の 4 種類の災害におけるデータを使用した。台風 15 号と 19 号は千葉県, 広島土砂災害は広島県, 熊本地震は熊本県のホームページに掲載されている, 災害時に随時更新される被害状況速報の PDF データから家屋の倒壊数の数値を抜き出した。家屋の倒壊数は全壊, 半壊, 一部損壊, 床上浸水, 床下浸水という種別に分けられている。この数値の変動が大きいほど罹災証明書の提出数は多くなり市役所は混雑したと考えられる。

4. 提案手法

LSTM を用いて、各災害の全壊, 半壊, 一部損壊の倒壊種別ごとにモデルの作成を行う。作成されたモデルを用いて他の災害の同じ種別の倒壊数の予測を行い、他の災害に対しても精度の良い予測ができるかを検証する。

5. 実験

5.1. 実験方法

LSTM に 1 度に学習させるデータ量 (ステップ数) を決め、データを学習してモデルを作成する。データはいずれも正規化し、時間間隔を 1 日毎に揃え、学習を行う。そして、予測するデータのうち最初からステップ数だけデータを取り、それ以降の予測を作成したモデルを使い予測を行う。

5.2. 実験の条件

本実験では、図 1 のモデルの出力に更に重み行列を加えたモデルを使用した。モデルの隠れ層の数は 30, 学習係数は 0.001, エポック数は 10000 とした。また、データのステップ数は 5 とした。

[†] Department of Information and Computer Engineering, National Institute of Technology, Kisarazu College

[‡] Department of Information and Computer Engineering, National Institute of Technology, Kisarazu College

5.3. 実験結果および考察

予測を評価するための指標として RMSE(Root Mean Square Error) を用いた。RMSE は式 (7) で表される。

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2} \quad (7)$$

予測した値が元の値に近いほど RMSE の値は小さくなり、予測精度が良いと言える。

各予測に対する RMSE の値を表 1~3 に示す。また、一例として台風 15 号を学習させた際の熊本地震の予測結果のグラフを図 2~4 に示す。表 1~3 を見ると倒壊種別に関わらず、台風 15 号、広島土砂災害を学習したモデルでは、どの災害に対しても比較的 RMSE の値が小さく正しい予測が出来ていることが分かる。また、一部損壊の予測では、全体的に RMSE の値が小さいことが分かる。これらは、被害状況速報の更新頻度が多かったり、倒壊数の値が大きかったりすることでモデルが変動を適切に学習出来ているのだと考えられる。

表 1 全壊の倒壊数の予測

モデル作成に 用いたデータ	予測を行ったデータ			
	台 風 15 号	台 風 19 号	熊本地 震	広島土 砂災害
台風 15 号	0.070	0.123	0.193	0.076
台風 19 号	0.629	0.171	0.596	0.467
熊本地震	0.700	0.168	0.659	0.535
広島土砂災害	0.101	0.202	0.203	0.055

表 2 半壊の倒壊数の予測

モデル作成に 用いたデータ	予測を行ったデータ			
	台 風 15 号	台 風 19 号	熊本地 震	広島土 砂災害
台風 15 号	0.098	0.194	0.214	0.156
台風 19 号	0.587	0.173	0.601	0.456
熊本地震	0.343	0.221	0.121	0.420
広島土砂災害	0.102	0.209	0.235	0.074

表 3 一部損壊の倒壊数の予測

モデル作成に 用いたデータ	予測を行ったデータ			
	台 風 15 号	台 風 19 号	熊本地 震	広島土 砂災害
台風 15 号	0.042	0.080	0.118	0.135
台風 19 号	0.209	0.058	0.284	0.196
熊本地震	0.103	0.076	0.052	0.227
広島土砂災害	0.099	0.085	0.196	0.039




図 2 全壊の予測結果




図 3 半壊の予測結果




図 4 一部損壊の予測結果

6. まとめ

本研究では被害状況を示した PDF データから被害棟数を抽出し、LSTM によって他の災害への予測を行った。今後は被害棟数の値が混雑状況に結び付くという検証を行ったり、モデルや指標を変更して災害時にリアルタイム上で運用できるようなモデルを追求する。

参考文献

- [1] 大枝真一, 稲毛惇人, 篠田拓樹, 飯棲俊介, 宮島 亜希子, “異種情報源の統合による令和元年千葉県激甚災害の被害状況の可視化”, AI・データサイエンス論文集 (土木学会), 1 巻 J1 号, pp. 286-294, 2020 年.