

屋外観測による都市内歩行者高さの超過風速推定

瀬田, 航己

九州大学大学院総合理工学府総合理工学専攻機械・システム理工学メジャー

<https://hdl.handle.net/2324/7178764>

出版情報 : Kyushu University, 2023, 修士, 修士
バージョン :
権利関係 :



屋外観測による都市内歩行者高さの超過風速推定

機械・システム理工学メジャー 瀬田航己

1. はじめに

都市域の風環境は建物群の幾何形状に大きく依存した乱流場を形成することから、安全で快適な風環境を実現するためには稀に吹く突風のような低頻度で高インパクトな事象を評価する必要がある。こうした背景から、歩行者空間風速の確率密度分布や超過風速を用いた強風の頻度と強度の評価が行われている。Wang ら¹⁾は、風速の確率密度分布を風速のモーメントをパラメータとする Weibull 関数によってモデリングする手法を提案し、単体角柱周りの風速のパーセンタイル値を統計値によって推定した。同様に瀬田ら²⁾は、モデリングの関数にガウス分布を高次のモーメントで補正する Gram-Charlier Series (GCS) を用いて単純街区周辺の風速の確率密度分布を推定するモデルを検証した。以上の方法は、風速の確率密度分布を既知の関数を用いてモデリングするパラメトリック手法である。一方で、機械学習モデルを用いた研究として、Li ら³⁾は風速のモーメントからパーセンタイル値を推定する Artificial neural network (ANN) を提案し、パラメトリック手法と比べて高い推定精度を持つことを報告した。既往研究から Weibull, GCS, ANN を用いた各推定モデルは都市キャノピー内の超過風速の推定に適していることが示唆されたが、実際の屋外で観測される風速に対する各推定手法の適用可能性については未だ議論されていない。以上のことから、本研究では屋外観測を実施することで都市内の風速の時系列を取得し、Weibull, GCS, ANN による超過風速推定の精度検証と相互比較を行う。

2. 推定モデル

風速 $v_a(t)$ の平均 μ 、標準偏差 σ より n 次モーメント m_n を以下に定義する。

$$m_n = \lim_{T \rightarrow \infty} \frac{1}{\sigma^n T} \int_T (v_a(t) - \mu)^n dt \quad (1)$$

ここで、3次モーメントは歪度 S_k 、4次モーメントは尖度 K_t である。また、パーセンタイル値は以下に定義する。

$$F = \int_{-\infty}^{v_{af}} p(v_a) dv_a \quad (2)$$

F [%]は累積確率密度である。本論文では風速のモーメント μ 、 σ 、 S_k 、 K_t からパーセンタイル値を推定する手法として Weibull, GCS, ANN の各モデルを検証する。

Weibull モデルは、式 (3) に定義される Weibull 関数によって累積密度分布をモデリングする。ここで α 、 β 、 ζ はパラメータであり、 $\zeta = 0$ のときを2W、 ζ を含む3つのパラメータで定義する Weibull 関数を3W とする。2W のとき σ/μ は式 (4)、3W のとき S_k は式 (5) のように β の関数として定義できる。同様にピークファクタ $PF_F = (v_{af} - \mu)/\sigma$ は Weibull 関数の定義より β の関数として式 (6) となる。以上から式 (4)–(6) より β を介して、2W は σ/μ から PF_F を、3W は S_k から PF_F が得られ、 $v_{af} = \mu + PF_F \sigma$ よりパーセンタイル値が推定される。

$$F(x) = 1 - \exp\left(-\left(\frac{x - \zeta}{\alpha}\right)^\beta\right), x \geq \zeta \quad (3)$$

$$\sigma/\mu = \frac{(\Gamma(1 + 2/\beta) - \Gamma^2(1 + 1/\beta))^{1/2}}{\Gamma(1 + 1/\beta)} \quad (4)$$

$$S_k = \frac{\Gamma\left(1 + \frac{3}{\beta}\right) - 3\Gamma\left(1 + \frac{2}{\beta}\right)\Gamma\left(1 + \frac{1}{\beta}\right) + 2\Gamma^3\left(1 + \frac{1}{\beta}\right)}{(\Gamma(1 + 2/\beta) - \Gamma^2(1 + 1/\beta))^{3/2}} \quad (5)$$

$$PF_F = \frac{(-\ln(1 - F))^{1/\beta} - \Gamma(1 + 1/\beta)}{(\Gamma(1 + 2/\beta) - \Gamma^2(1 + 1/\beta))^{1/2}} \quad (6)$$

GCS で推定される確率密度分布 $p_n(\zeta)$ は式 (7) に定義される。ただし、 $\zeta = (v_a - \mu)/\sigma$ 、 $f_3 = S_k(\zeta^3 - 3\zeta)/6$ 、 $f_4 = (K_t - 3)(\zeta^4 - 6\zeta^2 + 3)/24$ である。GCS は $n = 2$ のときガウス分布となり、 $n \geq 3$ のとき p_n を n 次GCSとした。GCS はモーメントから確率密度分布を決定し、式 (2) よりパーセンタイル値が推定できる。本論文では、ガウス分布 (2次)、3次GCS、4次GCS を検証した。

$$p_n(\zeta) = \frac{\exp(-0.5\zeta^2)}{\sqrt{2\pi}} \left(1 + \sum_{i=3}^n f_i\right) \quad (7)$$

ANN は、入力層、中間層、出力層からなり、本論文では入力層をモーメント、出力層をパーセンタイル値とした。中間層はアフィン層と活性化層 (シグモイド関数) から成りそれぞれ式 (8)、(9) で表される。 $\mathbf{x}$ は前層の値からなる次元 $(1 \times N)$ の行ベクトルであり、 $\mathbf{a}$ は次元 $(1 \times M)$ の行ベクトル、 $\mathbf{W}$ は次元 $(N \times M)$ の重み行列、 $\mathbf{b}$ は次元 $(1 \times M)$ のバイアスである。 $\mathbf{W}$ 及び $\mathbf{b}$ を学習によって最適化される。最適化には誤差関数 $L = \sum_i (y_i - t_i)^2$ を用いる。ここで、 y_i はモーメントを入力して得られたパーセンタイル値であり、 t_i は時系列から直接算出したパーセンタイル値の教師データである。 L より式 (10)、(11) によってパラメータを更新する。 n は学習試行回数、 η は学習率を示し $\eta = 0.01$ とした。本論文ではミニバッチ 64 のミニバッチ学習を採用し、学習の試行回数は 25×10^4 エポックとした。

$$\mathbf{a} = \mathbf{x}\mathbf{W} + \mathbf{b} \quad (8)$$

$$y_i = 1/(1 + \exp(-a_i)) \quad (9)$$

$$W_{ij}^{n+1} = W_{ij}^n - \eta \frac{\partial L}{\partial W_{ij}} \quad (10)$$

$$b_i^{n+1} = b_i^n - \eta \frac{\partial L}{\partial b_i} \quad (11)$$

ANN は各層の次元によって推定精度が変化することからいくつかの次元で学習を行い、 $(n, 24, 12, 16, 8)$ を採用した。 n は入力するモーメントの最大次数であり、ANN- n とした。つまり ANN-4 は、 μ 、 σ 、 S_k 、 K_t を入力とし、任意のパーセンタイル値を推定する。

3. 屋外観測データベース

屋外観測は東京都港区の東京工業大学附属科学技術高等学校の敷地内 ($35^\circ 38' 38.8''\text{N}$, $139^\circ 44' 50''\text{E}$) にて、2021 年 12 月 11 日 12 時 00 分から翌 12 日 12 時 00 分までの 24 時間実施した。最寄りのアメダスによると、観測日の天気は晴れのち曇り、風向は 11 日の午後は南風が、12 日の午前は北西風が卓越していた。観測には超音波風速計 (CYG-81000 / R.M. Young Company) を用い、速度成分 u 、 v 、 w をサンプリング周波数 10Hz で計測し、速度成分 u は東風、速度成分 v は北風とした。また風速 $v_a = \sqrt{u^2 + v^2}$ より速度成分 u 、 v から平面風速を得た。図 1 に観測点を示す。測定点 R1、R2 では、地面から約 18m の高さの屋上面において、高さ 3m の風速を、P1–P7 では、歩行者高さ 1.5m の風速を計測した。

以上の条件で観測した時系列 v_a から検証に用いたデータセットを作成した。歩行者高さ P1-P6 を 10 分毎に分割し、10 分間統計値としてモーメントとパーセンタイル値を算出し、外れ値として $K_t \geq 10$ を除くことでデータ数 906 の統計値のデータセット P_Stat を得た。同様の手法で、時系列の分割時に 90% の重なりを許したデータ数 9008 のデータセットのうち約 70% の 6305 をランダムに選び学習データ P_Stat_C_Train としクラスタリングを行い、残りの 2703 を検証データ P_Stat_C_Test とした。

P_Stat_C_Train について、モーメント μ , σ , S_k , K_t を対象に階層的クラスタリングの 1 種である Ward-linkage 法によるクラスタリングを行った。クラスタ数は Calinski-Harabasz 指標から 3 とした。P_Stat_C_Train から得られた 3 つのクラスタ毎に中心を求め、P_Stat_C_Test を中心とのユークリッド距離が最も短いクラスタに分類した。図 2 に結果を示す。図 2(a) より、クラスタ同士の境界が不明瞭であることから、 μ や σ がクラスタリングに与えた影響は小さかったことが分かる。一方で図 2(b) より、 K_t に対してはよく分類されており、高次のモーメントがクラスタリングに与えた影響は大きかった。これは、各モーメントの値のばらつきが異なっていたためであると考えられ、各モーメントの平均と標準偏差によって正規化したモーメントに対してクラスタリングをすることで、 μ や σ が反映されたクラスタリングとなるだろう。




図 1 観測地点 (Map Data: ©2022 Google)




図 2 P_Stat_C_Train 及び P_Stat_C_Test のクラスタリング後の統計量 (a) σ , (b) K_t の μ に対する分布。

4. 推定モデル検証結果

推定精度の検証を目的に、データセット P_Stat を用いて各推定モデルによるパーセンタイル値の推定を行い、パーセンタイル値毎に 2 乗平均平方根誤差 RMSE を算出した。GCS, Weibull は全データによって、ANN-2-ANN-4 は P_Stat のうち約 70% にあたる 630 をランダムに選び学習データとし、残りの 276 によって RMSE を求めた。図 3 にその結果を示す。パラメトリック手法である、GCS と Weibull は次数によらず、0.1, 99.9 パーセンタイル値の RMSE が他のパーセンタイル値に対して非常に大きいのにに対し、ANN モデルはその傾向が小さいことがわかる。

よって、 F が 0 または 100 に近いパーセンタイル値を推定する場合、風速の確率密度分布を既知の関数でモデリングするパラメトリック手法よりも、確率密度分布を経ずに直接パーセンタイル値を推定する ANN が優れていることが示唆された。また、ANN-2-ANN-4 を比較すると次数が高いほど RMSE が小さくなる傾向にあることが分かる。したがって、高次のモーメントには確率密度分布やパーセンタイル値に関わる情報が含まれており、高次のモーメントが含まれたデータセットによって適切な学習を行うことで低次のモデルより精度が向上することが確認された。

P_Stat_C_Train の 3 つのクラスタ毎に n 次の ANN を学習し、P_Stat_C_Test の 3 つのクラスタを用いてそれぞれパーセンタイル値を推定し RMSE を算出したものを C-ANN- n とする。図 4 より、次数に関わらずクラスタ毎に学習した C-ANN- n がクラスタリングを用いずに学習した ANN- n よりも RMSE が小さく、クラスタリングが ANN の精度を向上させることが示唆された。




図 3 各推定モデルの RMSE




図 4 クラスタリングによる RMSE の変化

5. 結論

本論文は、歩行者高さの風速のパーセンタイル値の推定を目的に、モーメントからパーセンタイル値を推定するモデルとして GCS, Weibull, ANN を提案し、屋外観測の時系列を基にしたデータセットによって検証した。 μ , σ , S_k , K_t を入力する ANN が最も推定精度が良く、またクラスタリングによって ANN の精度向上が期待されることが分かった。

【参考文献】

- 1) W. Wang, T. Okaze, Build Environ 209 (2022) 108644.
- 2) K. Seta, W. Wang, N. Ikegaya, Journal of Wind Engineering and Industrial Aerodynamics 239 (2023) 105427.
- 3) Y. Li, W. Wang, N. Ikegaya, Build Environ 250 (2024) 111171.