

機械学習に基づいたストリートレベルのウォーカビリティ評価 —Google Street View 画像を対象として

永田彰平・中谷友樹・埴淵知哉

Evaluation of street-level walkability based on machine learning approach: Analysis of Google Street View images

Shohei NAGATA, Tomoki NAKAYA and Tomoya HANIBUCHI

Abstract: There have been a lot of studies about GIS-based measurement of meso-scale walkability, such as the proximity to public facilities and the density of grocery stores. However, the measurement of street-level walkability for large areas needs extensive observations. In this study, using a deep learning approach in Google Street View images, we detected several segments that make up the streetscape. The results of regression analysis showed that the composition of detected segments were significantly associated with the street-level walkability. This indicates the possibility of the objective evaluation of street-level walkability for large areas through the machine learning approach.

Keywords: ウォーカビリティ (walkability), Google Street View, 機械学習 (machine learning), ディープラーニング (deep learning)

1. 背景

身体活動量が非感染性疾患の予防に寄与することはよく知られているが (Owen et al., 2010), 世界的に身体活動量の低下が進んでいる (Ng and Popkin, 2012). その背景には歩行を中心とした日常的な身体活動を阻害する近隣環境の出現があると考えられている。この問題意識に基づき, GIS を用いて施設への近接性や立地密度などを算出し, 歩行を促進する近隣環境の程度である街区レベルのウォーカビリティを評価した研究が多く行われてきた (中谷, 2011). しかし, 歩行者の視点からみた歩道や街路景観の状態といったストリートレベルのウォーカビリティも日常的な歩行量を規定すると考えられているものの (Kim et al., 2014), これを広範囲にわたって評価するには, 大規模な調査が必要となり大きなコストを要する。これに対し, 近年では Google Street View 画像(以下 GSV 画像)を用いた近隣環境評価の有効性が示されている (Bethlehem et al., 2014). さらに,

街路景観画像に機械学習 (ディープラーニング) を用いて評価する研究も見られるようになった (Yin and Wang, 2016; Wang et al., 2019). ただし, それらの研究が対象とする景観要素や健康アウトカムはまだ限定的であり, 街路景観を構成する複合的な要素とウォーカビリティの関係を分析した研究は見られない。

そこで本研究では, 機械学習により GSV 画像から街路景観を構成するセグメントを抽出し, これを用いた街路景観に対するウォーカビリティ (Street-landscape Walkability: SLW) 評価モデルを構築することを目的とする。

2. 使用するデータと方法

2.1 SLW 評価得点

本研究では, SLW の外的基準として, 事前に実施された人による GSV 画像の評価結果を用いた。人による GSV 画像の評価は, 東京都文京区の街路景観を対象に, 14 項目のチェックリスト (表-1)に基づく評価法 (Hanibuchi et al., submitted)により実施された。このチェックリストは, 評価者間および調査方法間 (現地調査と仮想的調査) の十

表-1 ウォーカビリティ評価チェックリスト

	チェック項目	チェック欄	説明
Q1	歩道はありますか？	1 ある 2 ない → Q3へ	段差や縁石で車道と物理的に区別された歩行者用の道。対象区間の 50%以上に存在＝「ある」。
Q2	歩道には十分な幅がありますか？	1 ある 2 ない	人がすれ違うのに余裕のある、約 2m 以上が目安。
Q3	歩行の邪魔になる物はありませんか？	1 ある 2 ない	右側通行の際、避けて通らないといけない段差や看板、電柱、自転車など。
Q4	急な坂はありますか？	1 ある 2 ない	自転車で座ったまま上るのが難しい程度の勾配。
Q5	路上駐車している車はありますか？	1 ある 2 ない	違反かどうかに関わりなく、運転手がいない車が路上にあるかどうか。
Q6	車の交通量が多いですか？	1 多い 2 少ない	頻繁に車が行き交う状況＝「多い」、たまに車が通り過ぎる程度＝「少ない」。
Q7	人通りが多いですか？	1 多い 2 少ない	頻繁に人が行き交う状況＝「多い」、たまに人が通り過ぎる程度＝「少ない」。
Q8	横断歩道はありますか？	1 ある 2 ない	出発地点と終点に当たる交差点も含む。
Q9	カーブミラーはありますか？	1 ある 2 ない	見通しが悪い交差点や車の出入口に設置されているもの。家庭用のガレージミラーも含む。
Q10	街灯はありますか？	1 ある 2 ない	路上の街灯に限る。電柱に併設されている照明設備も含む。
Q11	街路樹はありますか？	1 ある 2 ない	路上の木々に限り、住宅や商店の敷地にある植栽は除く。
Q12	通り沿いの景観は魅力的ですか？	1 はい 2 いいえ	主観的な評価として美しい／面白い／心地よいと感じるかどうか。
Q13	落書きや放置されたゴミはありますか？	1 ある 2 ない	路上または通りに面した壁や看板などを含む。
Q14	荒廃した建物はありますか？	1 ある 2 ない	老朽化した空き家など見た目で判断できるもの。

分な信頼性が確認されている。歩道環境に関する 4 項目 (Q1~4), 安全性に関する 6 項目 (Q5~10), 景観の審美的価値・荒廃に関する 4 項目 (Q11~14)で構成されており, それぞれは二値評価(有無など)による。この得点を単純に合計することで街路景観に対するウォーカビリティ総合得点(以下、SLW 総合得点)が算出できる。ここでは, 文京区および文京区の周辺 1km 内の交差点(n=8,537)から無作為に抽出した 854 の交差点(図-1)を起点とする道路を対象として, 2018 年 8 月から 10 月にかけて上記の評価を行ったデータを用いた。本研究では, 交差点単位での平均 SLW 総合得点を分析の対象とした。SLW 総合得点(交差点平均値)は, チェックリストの構造上 0 から 14 の値を取り得るが, 人による評価の結果では, 最小値は 6, 最大値は 12.3 であった。

2.2 Google Street View 画像

GSV 画像の取得には Google 社提供の Street View Static API を用いた。画像の取得にあたり, 評価交差点(854 地点)の経緯度と, 交差点を起点とする各道路の角度を ArcGIS 10.6.1(Esri 社)によって算出し, API のパラメータとして設定した。なお, 交差点および道路データは ArcGIS Geo Suite 道路網 2016 (ESRI ジャパン社) を用いた。API による画像のダウンロードの結果, 852 地点で正常なレスポンスがあり, 2,777 枚の画像を取得した。

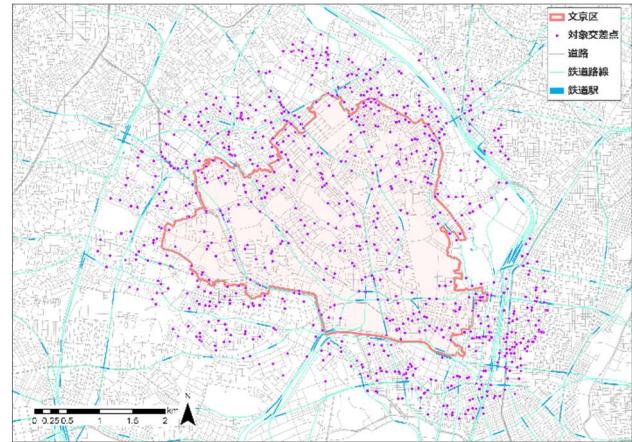


図-1 評価対象交差点の分布

2.3 景観画像のセグメンテーション

GSV 画像のセグメンテーションには, Supervise.ly (Deep Systems 社)上で公開されている都市景観を学習済みの DeepLab v3+モデル (Chen et al., 2018)を使用した。なお, 本モデルの学習には Cityscapes Dataset (Daimler 社, Max Planck Institute for Informatics, Technische Universität Darmstadt)が用いられている。このデータセットには, ドイツの諸都市で撮影された 25,000 枚の都市景観画像が収録されており, 各画像には歩道や車といったセグメント情報のアノテーションが付与されている。学習済みの本モデルを用いることで, 画像の各ピクセルを歩道や車などのセグメントに分けることが可能である。

2.4 空間回帰分析

GSV 画像のセグメンテーション結果と SLW 総合得点の関連性を, 交互作用を考慮した空間的誤差自己回帰モデル (Anselin, 2003)によって分析した。被説明変数には SLW 総合得点, 説明変数には GSV 画像から DeepLab v3+によって検出された各セグメントの画像面積割合, 道路勾配, 道路幅員の情報を用いた。道路勾配は, 評価対象の交差点を起点とする道路データの各頂点に DEM データ(5m 航空レーザ測量)の値を結合することで算出した。道路幅員は, 道路データに収録されている値をカテゴリ変数として用いた(3~5.5m, 5.5~13m, 13m 以上)。なお, 対象地域内において, 幅員 3m 以下の道路は存在しなかった。

モデル選択に際しては, 交差点平均 SLW 総合得点と関連する説明変数をステップワイズ法で選択した後に, 交互作用を考慮した最適なモデルを遺伝的アルゴリズムによって選択した。さらに, 変数・交互作用の選択の結果を利用して空間的誤差自己回帰モデルを当てはめ, 係数を推定した。

空間的誤差自己回帰モデルでは、Gabriel Graph Neighbors (Bivand ,2019)によって評価交差点間の隣接行列を定義した。一連の回帰分析はR-3.2.0を使用しており、交互作用を考慮したモデル選択と空間的誤差自己回帰分析には、それぞれ glmulti と spdep の各 R パッケージを用いた。

3. 結果

3.1 景観画像のセグメンテーション結果

DeepLab v3+によって、GSV 画像から 19 個のセグメントが検出され (表-2)，画像ごとに各セグメントの占める割合が計算された。例えば、図-2 の画像で最も広いセグメントは樹木であり、画像の 39.63% のピクセルが樹木セグメントに分類された。また、道路や建物といったセグメントもこの画像の中の高い割合を占めている。

表-2 検出されたセグメント

セグメント	割合	セグメント	割合
建物	46.53 %	人	0.77 %
道路	23.21 %	自転車	0.54 %
樹木	9.26 %	道路標識	0.34 %
空	6.26 %	低木	0.23 %
フェンス	2.98 %	鉄道	0.11 %
壁	2.61 %	オートバイ	0.03 %
歩道	2.32 %	ライダー	0.03 %
車	2.22 %	バス	0.03 %
トラック	1.28 %	信号機	0.01 %
ポール	1.24 %		

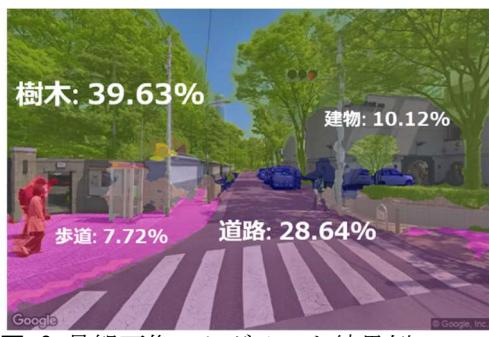


図-2 景観画像のセグメント結果例



図-3 除外画像例

このような景観画像のセグメンテーションを、API でダウンロードした 2,777 画像に適用した結果、261 画像については道路セグメントの割合が極めて低く (5%以下)，街路景観の評価に適していないため分析から除外した (図-3)。

3.2 回帰分析の結果

SLW 総合得点と DeepLab v3+によるセグメンテーション結果との関係を回帰分析により検討した。ステップワイズ法および遺伝的アルゴリズムによりモデル選択を行い、最終的に空間的誤差自己回帰モデルによって係数を推定した。この最終的なモデルの決定係数は 0.51 であり、SLW を一定の精度で評価可能な適合度と言える。図-4 は当該モデルによる SLW 総合得点の予測値と実測値の散布図である。

このモデルの推定された係数を表-3 に示した。 p 値が最小となった偏回帰係数は、道路セグメントと建物セグメントの交互作用項のものである。この係数が負の値であることから、画像内における道路と建物のセグメントの割合が同時に高くなるほど、SLW 評価が低くなると解釈できる。これらのセグメントの割合が高い画像は、建物に囲まれた路地のような暗い道路を写しているため SLW 評価が低くなることが考えられる。また、建物セグメントと幅員 5.5~13m, 幅員 3m~5.5m の交互作用も係数が負の値であり、道路および建物セグメントの交互作用と同様に、細い路地において SLW 評価が低くなっていると考えられる。

SLW 予測値の高い地点の GSV 画像 (図-5) は、見通しが良く、歩道や街路樹も整備されているため、歩行に適した街路景観を構成していることが了解できる。一方、SLW 予測値の低い地点の GSV 画像 (図-6) は、見通しが悪く、歩道も整備されていないため、評価が低くなっていると考えられる。

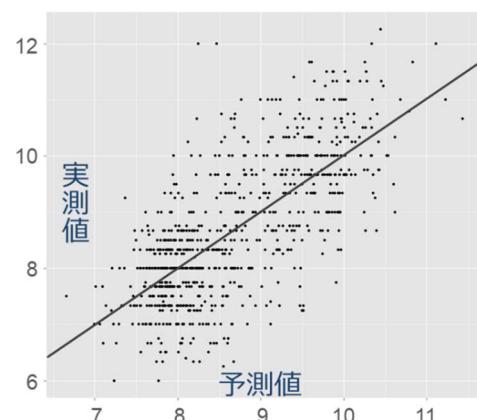


図-4 SLW 総合得点の実測値と予測値

表-3 回帰分析結果

説明変数	偏回帰係数	標準誤差	z値	p値
(切片)	8.297	0.554	14.982	< 2.2e-16
道路: 建物	-0.003	0.001	-6.337	0.000
道路	0.147	0.025	5.970	0.000
建物: 道路幅員 5.5 - 13 M	-0.033	0.006	-5.409	0.000
空	-0.153	0.029	-5.292	0.000
道路: 樹木	-0.002	0.000	-5.073	0.000
建物: 道路幅員 3 - 5.5 M	-0.030	0.006	-4.623	0.000
道路勾配: 信号機	3.740	0.813	4.601	0.000
低木: ライダー	-1.712	0.442	-3.870	0.000
建物	0.047	0.012	3.756	0.000
道路: 道路幅員 5.5 - 13 M	0.029	0.008	3.461	0.001
ポール	-0.864	0.257	-3.363	0.001
ホール: 樹木	0.013	0.004	3.124	0.002
道路勾配: ライダー	0.584	0.210	2.780	0.005
建物: ポール	0.011	0.004	2.757	0.006
ポール: 空	0.022	0.008	2.665	0.008
道路: 歩道	0.006	0.002	2.662	0.008
建物: 空	0.002	0.001	2.632	0.008
道路: 低木	0.019	0.008	2.234	0.026
道路: ライダー	-0.061	0.028	-2.184	0.029
建物: 道路勾配	0.003	0.002	2.069	0.039
ホール: ライダー	0.815	0.399	2.040	0.041
歩道: 低木	0.059	0.029	2.026	0.043
道路勾配	-0.239	0.122	-1.960	0.050
低木	-0.459	0.239	-1.919	0.055
歩道: ライダー	0.297	0.168	1.765	0.078
空: 道路勾配	0.009	0.005	1.690	0.091
道路: 道路勾配	-0.005	0.003	-1.550	0.121
ホール: 道路勾配	0.026	0.017	1.520	0.128
歩道	-0.092	0.065	-1.416	0.157
歩道: 道路幅員 5.5 - 13 M	0.045	0.042	1.067	0.286
歩道: 道路幅員 3 - 5.5 M	-0.037	0.044	-0.835	0.404
道路: 道路幅員 3 - 5.5 M	0.003	0.010	0.315	0.753

R²: 0.51, AIC: 2198, Lambda: 0.14 (LR test value: 8.381, p value: 0.004)



図-5 予測値の高い GSV 画像例



図-6 予測値の低い GSV 画像例

4. 結論

本研究では、機械学習（ディープラーニング）を用いて GSV 画像から街路景観を構成するセグメントを抽出し、この各セグメントの景観画像に占める面接比を説明変数としたウォーカビリティ評価モデルを構築した。その結果、人によって評価された街路景観に対するウォーカビリティ総合得点を一定の精度で予測しうるモデルが得られた。この結果は、街路景観を構成する複合的な事物の機械学習を通して、街路景観のウォーカビリティを客観的に評価できる可能性を示している。機械学習を用いた街路景観評価は、GSV 画像の取得に一定のコストが必要であるものの、調

査のための人的コストが必要ない。そのため、広範囲にわたるストリートレベル・ウォーカビリティの客観的評価を実施する上で、有効な手段になりうる。ただし、本研究の対象地域は文京区という限られた範囲であり、実際の歩行量ないし身体活動量との比較は行っていない。より広い範囲でのモデルの構築と、実際の身体活動量との関連性については今後の課題としたい。

参考文献

- 中谷友樹 (2011). 健康と場所—近隣環境と健康格差研究—. 人文地理, 63(4), 360-377.
- Anselin, L. (2003). Spatial externalities, spatial multipliers, and spatial econometrics. *International Regional Science Review*, 26(2), 153-166.
- Bethlehem, J.R., Mackenbach, J.D., Ben-Rebah, M., Compernolle, S., Glonti, K., Bárdos, H., Rutter, H.R., Charreire, H., Oppert, J.M., Brug, J. and Lakerveld, J. (2014). The SPOTLIGHT virtual audit tool: a valid and reliable tool to assess obesogenic characteristics of the built environment. *International Journal of Health Geographics*, 13, 52.
- Bivand, R. S. (2019). Creating Neighbours. <https://cran.r-project.org/web/packages/spdep/vignettes/nb.pdf>.
- Chen, L.C., Zhu, Y., Papandreou, G., Schroff, F., and Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. *Proceedings of the European Conference on Computer Vision*, 2018, 801-818.
- Hanibuchi, T., Nakaya, T. and Inoue, S. (submitted). Virtual audits of streetscapes by crowdworkers.
- Kim, S., Park, S., and Lee, J.S. (2014). Meso-or micro-scale? Environmental factors influencing pedestrian satisfaction. *Transportation Research Part D: Transport and Environment*, 30, 10-20.
- Ng, S.W., and Popkin, B.M. (2012). Time use and physical activity: a shift away from movement across the globe. *Obesity Reviews*, 13(8), 659-680.
- Owen, N., Healy, G.N., Matthews, C.E., and Dunstan, D.W. (2010). Too much sitting: the population-health science of sedentary behavior. *Exercise and Sport Sciences Reviews*, 38(3), 105-113.
- Wang, R., Liu, Y., Lu, Y., Yuan, Y., Zhang, J., Liu, P., and Yao, Y. (2019). The linkage between the perception of neighbourhood and physical activity in Guangzhou, China: using street view imagery with deep learning techniques. *International Journal of Health Geographics*, 18, 18.
- Yin, L., and Wang, Z. (2016). Measuring visual enclosure for street walkability: Using machine learning algorithms and Google Street View imagery. *Applied Geography*, 76, 147-153.