

# 鉄道駅構内における探索歩行時の視認情報が迷いやすさに及ぼす影響 -ストリートビューを用いた探索歩行実験と視線予測モデルに基づく迷いやすさの評価-

河村優介 \*・沖拓弥 \*\*

## Effects of Visual Information on Susceptibility to Getting Lost During Wayfinding in a Railway Station -Evaluation of Susceptibility to Getting Lost Based on a Walking Experiment of Wayfinding Using Street View and a Gaze Prediction Model-

Yusuke KAWAMURA\*, Takuya OKI\*\*

For planning comfortable architectural spaces with high legibility, it is essential to understand the mechanism of getting lost. We previously conducted a virtual walking experiment using Google Street View at a large-scale terminal station. Using the eye-tracking data of subjects, we analyzed the relationships among spatial characteristics in the station, gaze behavior of subjects, and getting lost. In this paper, we first analyze the results of the previous experiment in more detail and clarify the relationship between gaze behavior and getting lost from the psychophysiological responses of subjects. Next, we construct a gaze prediction model trained by saliency maps and GSV images during the walking experiment. Finally, we discuss the possibility of using the proposed gaze prediction model to evaluate susceptibility to getting lost in architectural spaces.

**Keywords:** 迷い (getting lost) , 探索歩行 (wayfinding) , 視線行動 (gaze behavior) , Google ストリートビュー (Google Street View) , 瞳孔径 (pupil diameter) , 視線予測 (gaze prediction)

### 1. はじめに

迷いの発生メカニズムを解明し、迷いにくい空間を計画することは、快適性や移動円滑性の観点などから重要である。

筆者らは、大規模ターミナル駅である T 駅を対象に、歩行者の迷いによる立ち止まりの観測調査（以下、立ち止まり調査）を実施し、通路の構成や方向案内サイン（以下、サイン）の位置などの静的な空間特性と迷いによる立ち止まりの関係を分析した（河村・沖、2020）。また、Google ストリートビュー（以下、GSV）を用いた仮想的な探索歩行実験（以下、探索歩行実験）を実施し、そのときの被験者の視線行動を分析することで、空間特性と視線行動や迷いやすさの関係を分析した（河村・沖、2021）。

本稿では、まず、探索歩行実験の結果をより詳細に分析し、探索歩行時の視線行動の特性と迷い状態の関係を、歩行者の心理生理的反応から明らかにする。次に、実験対象以外の空間においても

同様の分析が行えるよう、探索歩行実験時の被験者の注視傾向から視線予測モデルを構築するとともに、建築空間における迷いやすさ評価への、モデルの活用可能性を検討する。

### 2. 探索歩行実験と視線行動データの概要

#### 2.1. 探索歩行実験

図 1(a) に実験の概要を示す。被験者の負担を極力抑えつつ複数経路での探索歩行実験を行うため、GSV を用いて T 駅構内の仮想的な歩行実験環境を構築した。被験者はいずれも T 駅に不慣れな学生 3 名で、立ち止まり調査で分析対象とした特定の通路の分岐点を複数経由する 7 通りの経路（図 4）を順に探索歩行してもらった。

実験は、操作の練習とアイトラッカーのキャリブレーションを行った後に行った。探索の出発地と目的地はその都度口頭で指示し、目的地に到達後、次の経路の出発地へと画面を切替えることを繰り返した。

\* 学生会員 東京工業大学環境・社会理工学院 (Tokyo Institute of Technology)  
〒152-8550 東京都目黒区大岡山 2-12-1 E-mail: kawamura.y.ai@m.titech.ac.jp

\*\* 正会員 東京工業大学環境・社会理工学院 (Tokyo Institute of Technology)

実験日時	2021年5月13日,14日
被験者	20代の学生 3名
歩行経路	T駅構内の乗り換え等を想定した7通りの経路を設定.
実験方法	経路ごとに開始地点の設定と目的地の指示を行い、被験者はキーボード操作で目的地に向かう。 ・歩行中は不安や迷いの有無を被験者に発話してもいい。その内容を録音する。
(a) 実験の概要	GSVを用いた探索歩行実験の概要

図 1 GSV を用いた探索歩行実験の概要

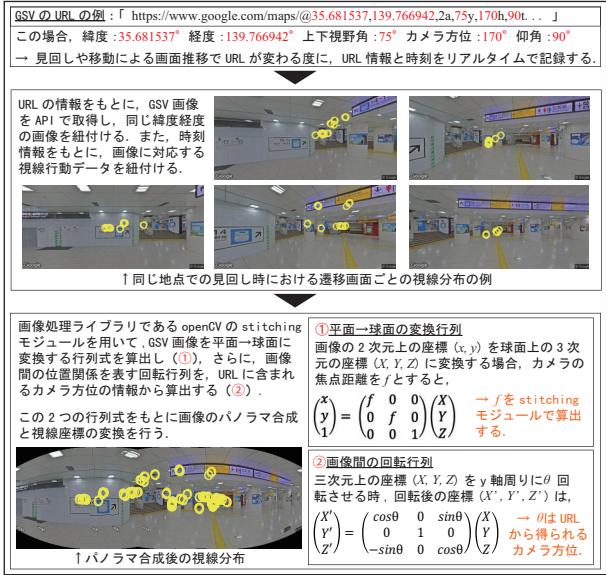


図 2 視線座標のパノラマ画像上の座標への変換方法

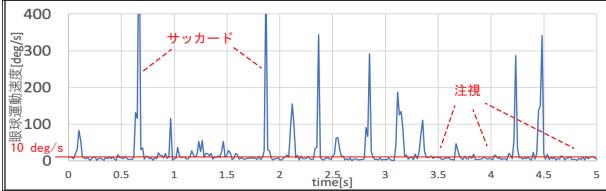


図 3 眼球運動速度の時系列変化の例（被験者 A のデータの一部）

図 1(b) に実験の環境を示す。GSV 画面は、広い視野角を確保するためスクリーンに拡大表示し、被験者は手元のキーボードの十字キーで前進・後退と水平方向の見回しを行う。また、視線の計測には、スクリーンベースの小型アイトラッカー (Tobii Pro ナノ) を使用し、1/60 s の周期で視線座標と瞳孔径を記録した。

## 2.2. 視線行動データの概要

GSV では、地点ごとの全方位画像を、指定のカメラ方位、上下視野角、仰角の画像に変換して表示している。しかし、アイトラッカーで記録する視線座標は画面上の相対座標であるため、同じ地点で多方向を見回す際、画像間の視線の位置関係は直接考慮できない。そこで、同地点における見回し時の異なる方向の複数の GSV 画像を、一

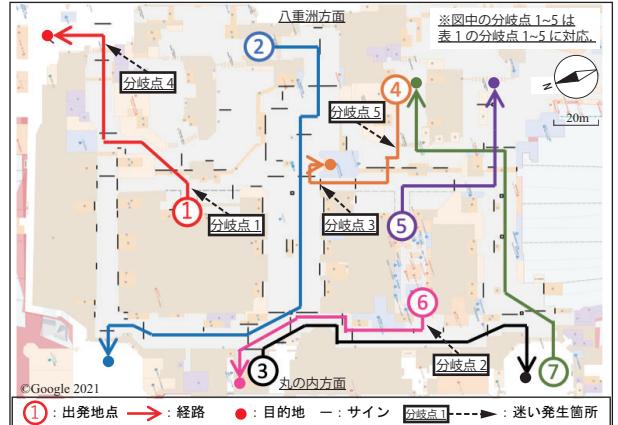


図 4 探索歩行実験の経路と迷いの発生箇所

表 1 迷いが生じた分岐点の空間特性と迷い発生時の視線行動

分岐点	立ち止まり数 ※1	通路の構成 ※2	サインの位置・状況	迷った被験者 (迷い状態)	分岐点における視線行動
1	12人	十字路	左右折り方向の通路の遠い位置。 分岐点正面にサインなし。	被験者 A, B (経路間違い)	・分岐点手前で分散的な注視。 ・分岐点で大きく見回し。
2	26人	T字路	右折方向の通路の近い位置。 歩行者に正対していない。	被験者 C (経路間違い)	・見回し後は、ひとまず見えたサインに向かって間違った経路を選択。
3	20人	十字路	右折方向の通路の近い位置。 歩行者に正対していない。	被験者 C (経路間違い)	・サインを注視せず、目的の情報に気づかないまま正しい経路を素通り。
4	4人	ト型	改札通過後、正面の遠い位置。 広告看板が视觉的に妨げに。(うろつき)	被験者 A (うろつき)	・改札手前で分散的な注視。 ・通過後は分散的な注視と大きな見回し。
5	29人	十字路	改札通過後、 通路を挟んだ右斜め前方。 (うろつき)	被験者 A (うろつき)	・改札手前で分散的な注視。 ・通過後はサインの分散的な注視。

※1 立ち止まり数は、立ち止まり調査 (河村・沖、2020) で計測した、通路の分岐点における迷いによる立ち止まり者数 (各分岐点 10 分間計測)。計測は T駅構内の 60 箇所の分岐点で行い、平均立ち止まり数は 9.3 人だった。

※2 通路の構成は、右図のよう

に分類した。

T字型

ト型

十字型

枚のパノラマ画像に合成するとともに、画面上の座標をパノラマ画像上の座標に変換し、同一地点における一連の視線分布を一枚のパノラマ画像として可視化する手法を構築した (図 2)。これにより、前進・後退と水平方向の見回しによる画面の切り替えに対応する。

また、視線行動データには、素早く視線が移動するサッカードも含まれるが、本研究では実際に対象物を見ている注視行動を分析する。具体的には、眼球運動速度の分布 (図 3) に基づき、福田ら (1996) による定義を参考に、「眼球運動速度 10 deg/s 以下の状態が 100 ms 以上継続する場合」を注視と定義し、注視点の抽出を行った。

## 3. 探索歩行実験の結果と考察

### 3.1. 迷いの発生箇所と被験者の迷い状態

探索歩行実験中の発話内容を分析した結果、経路上の分岐点のうち計 5 箇所で、いずれかの被験者に迷い (経路間違いやうろつき) が生じたことが判明した。図 4 に歩行経路と迷いが発生した分岐点の位置、表 1 に各分岐点の空間特性と迷い発生時における被験者の視線行動の概要を示す。

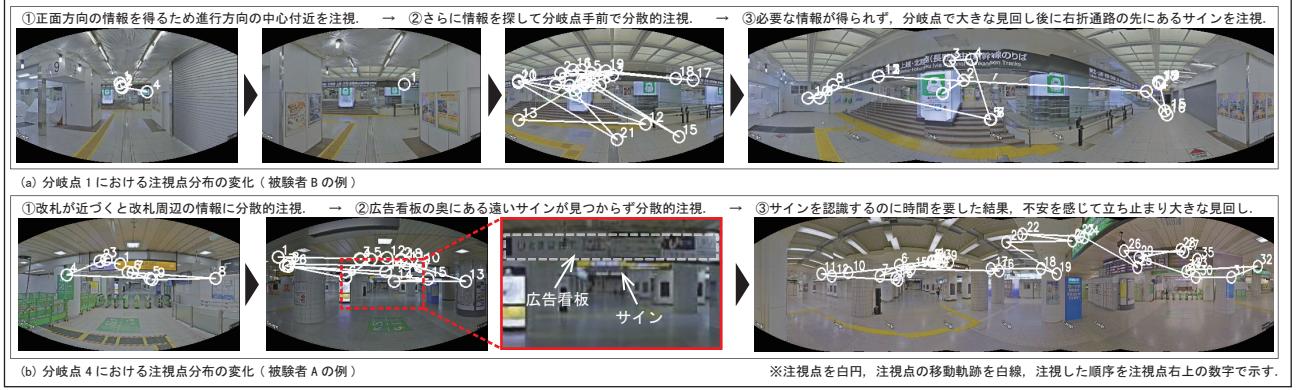


図 5 迷いが生じた分岐点における視線行動の例

### 3.2. 迷い発生時の視線行動と空間特性の関係

迷いが生じた分岐点における被験者の視線行動の例を図 5 に示す。

まず、分岐点 1・2 のようにサインが不足する場所では、被験者は分散的な注視と見回しの後に、ひとまず視認したサインの情報を得るために誤った経路を選択していた（図 5(a)）。こうした場所では、立ち止まり調査（河村・沖, 2020）における歩行者の立ち止まり数も多く、多くの歩行者が同様の視線行動を行い、迷いの発生につながっている可能性がある。

次に、サインのある分岐点 3～5 では、視線をサイン方向に向けたがその情報を見逃す例や、サイン情報を認識するのに時間を要する例などが観測された。広告看板や繁雑な案内表示による空間の情報量の多さが歩行者の注意を分散させ、円滑な情報受容を妨げている可能性がある（図 5(b)）。また、サインが分岐点正面の視認しやすい位置に無いことが歩行者の不安を煽り、分散的な注視や立ち止まりを誘発する例も見られた。

### 3.3. 迷い状態と瞳孔径の関係

迷いが生じた被験者・経路を対象に瞳孔径の時間変化を見ると（図 6），迷い発生後に瞳孔径が大きくなり、迷い解消後は瞳孔径が小さくなる傾向が見られた。瞳孔径は一般に交感神経の活性で散瞳し、副交感神経の活性で縮瞳することが知られており（田場ほか, 1996），歩行中の不安や集中などの心理状態が瞳孔径の変化に現れている可能性がある。

### 3.4. 視線の分散と滞在時間・瞳孔径の関係

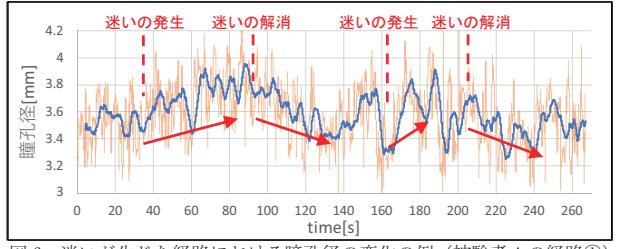


図 6 迷いが生じた経路における瞳孔径の変化の例（被験者 A の経路①）

<b>(1) 視線分散度</b> $D_i$ [pixel]: 1 地点における視線の散らばり具合 地点 $i$ のパノラマ画像上の注視点の数を $n_i$ 、注視点 $j$ ( $1 \leq j \leq n_i$ ) と 注視点 $k$ ( $1 \leq k \leq n_i$ ) のピクセル座標間の距離を $d_{jk}$ [pixel] とする。	$D_i = \frac{\sum_j^{n_i} \sum_k^{n_i} d_{jk}}{n_i(n_i - 1)}$
<b>(2) 滞在時間</b> $T_i$ [s]: 1 地点に留まった時間 地点 $i$ に移動した時刻を $t_i$ とする。 ( $t_i$ は記録した GSV の緯度・経度が更新された時刻から算出)	$T_i = t_{i+1} - t_i$
<b>(3) 平均瞳孔径</b> $P_i$ [mm]: 1 地点における瞳孔径の平均値 地点 $i$ におけるパノラマ画像上の注視点の数を $n_i$ 、 注視点 $j$ ( $1 \leq j \leq n_i$ ) の瞳孔径の大きさを $p_j$ [mm] とする。	$P_i = \frac{\sum_j^{n_i} p_j}{n_i}$

※各指標を被験者ごとに算出する。

図 7 探索歩行と視線行動に関する各指標の定義

地点（パノラマ画像）ごとの視線行動をより定量的に把握するために、(1) 視線分散度  $D_i$ 、(2) 滞在時間  $T_i$ 、(3) 平均瞳孔径  $P_i$  という 3 つの指標を定義する（図 7）。(1) 視線分散度  $D_i$  は、情報受容の容易さを表す指標である。サイン等の必要な情報が見つからない場合や、視覚情報が繁雑な場合に高くなると予想される。(2) 滞在時間  $T_i$  は、各地点における行動選択に要する時間であり、時間が長いほど行動に躊躇があると推察される。(3) 平均瞳孔径  $P_i$  は、前述した瞳孔径変化の特徴から、各地点における不安や集中などの心理状態に関係する指標である。以下では、これらの指標を被験者ごとに算出し、各指標間の関係を分析する。

まず、視線分散度  $D_i$  と滞在時間  $T_i$  の変化を見ると（図 8(a)），滞在時間  $T_i$  が長い地点では視線分散度  $D_i$  も高い地点が多い。被験者ごとにその関係を見ると（図 9(a)），いずれも弱い正の相関が確認できる。見回しによる情報取得が多く必要

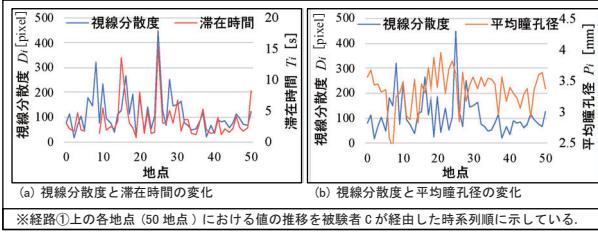


図 8 視線分散度と滞在時間・平均瞳孔径の変化（被験者 C の例）

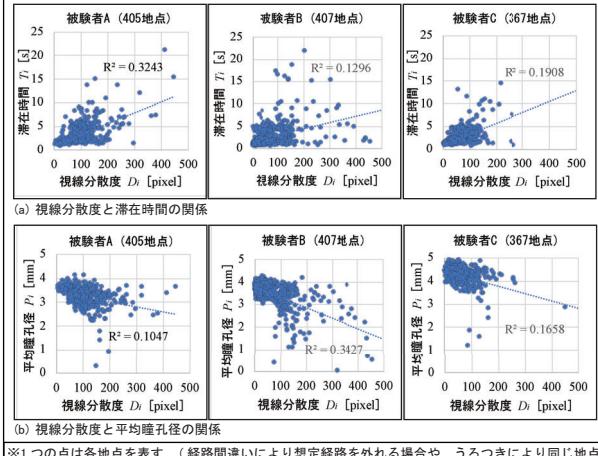


図 9 各被験者の視線分散度と滞在時間・平均瞳孔径の関係

な地点で、経路判断に時間を要していると考えられる。

次に、視線分散度  $D_i$  と平均瞳孔径  $P_i$  の変化を見ると（図 8(b)），視線分散度  $D_i$  は平均瞳孔径  $P_i$  と概ね逆位相で変化している。被験者ごとにその関係を見ると（図 9(b)），いずれも弱い負の相関が確認できる。サイン情報を注意深く見る場合などの集中的注視では散瞳、見回して様々な場所に視線を移動する分散的注視では縮瞳するなど、視線の動きと瞳孔径がある程度連動している可能性を示唆している。

#### 4. 探索歩行時における視線予測モデル

##### 4.1. 視線予測モデルの概要

第3章で示したように、探索歩行時における被験者の視線行動からは様々なことが把握できる。特に視線分布からは、歩行者の情報受容に影響する空間の特徴をある程度把握でき、迷いにくい空間の評価に活かせる可能性がある。しかし、対象の空間ごとに被験者実験を行うことは容易でない。そこで、対象空間の画像から探索歩行時の視線分布を予測する機械学習モデルを構築すること

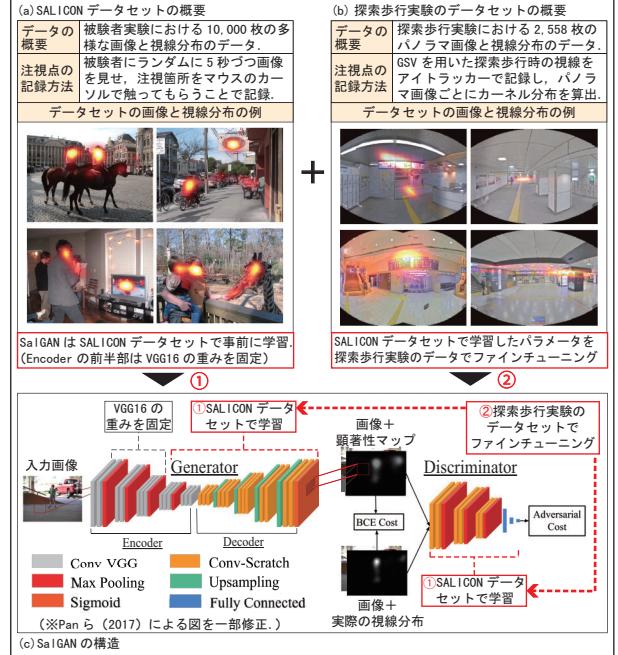


図 10 SalGAN の構造と学習データセットの概要

を試みる。

画像から視線分布を予測する機械学習モデルとして、様々なものが提案されている。しかし、その多くは汎用的なモデルであり、探索歩行時という特殊な状況の注視傾向を適切に表現できない可能性がある。そこで、既存の視線予測モデルを探索歩行実験の視線データでファインチューニングすることで、鉄道駅構内における探索歩行時の視線予測に適したモデルを構築する。

ここでは、Pan ら (2017) によるモデル (SalGAN) をベースラインとする（図 10）。SalGAN は図 10(a) に示す SALICON データセット (Jiang et al., 2015) を学習させたもので、画像のピクセル単位の注視確率（以下、頸著性マップ）として人間の視線をある程度予測できる。

SalGAN は Generator (生成器) と Discriminator (識別器) で構成されている（図 10(c)）。Generator は前半の VGG16 の構造で畳み込み、後半でアップサンプリングをして頸著性マップを生成する。Discriminator は元画像と頸著性マップを組み合わせた 4 チャンネルの入力に対し、本物か偽物かを見分ける。この 2 つを交互に競合させて学習を進めることで、Generator は実際の視線分布に近い頸著性マップを生成できるようになる。

## 4.2. 学習の方法

SALICON データセットで訓練した SalGAN のパラメータを、探索歩行実験から得たデータセット（図 10(b)）でファインチューニングする。学習データは、画像の左右反転により水増し処理を行った 2558 枚のパノラマ画像（RGB, 3 チャンネル）と、それに対応する視線分布（注視点のカーネル密度分布, 1 チャンネル）からなる。全ての画像を 256 pixel × 192 pixel にリサイズした上で、学習用とテスト用が 7 : 3 となるように分割する。

学習の最適化手法には Pan ら (2017) と同じく AdaGrad を用い、学習率の初期値を 0.0003、バッチサイズを 32 として、学習の経過を見ながら 2000 epoch まで学習させた。

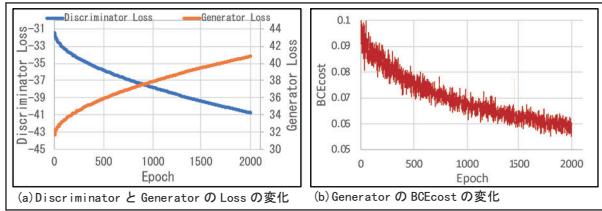


図 11 学習の経過

## 4.3. モデルの学習結果と予測精度

学習の経過を図 11 に示す。Discriminator Loss（実際の視線分布に対する Discriminator の真偽判定の誤差）は、学習が進むにつれ小さくなっている。同様に、Generator Loss（Generator が生成した顕著性マップに対する Discriminator の真偽判定の誤差）も、学習が進むにつれ大きくなっている。また、Generator が生成した顕著性マップの、実際の視線分布に対する誤差を表す BCE (Binary Cross Entropy) Cost も減少している。すなわち、学習が進むにつれ、より実際の視線分布に近い顕著性マップを生成できるようになっていることを示している。

表 2 モデルの予測精度

※テストデータに対してモデルが予測する顕著性マップごとに、以下に示す3つの指標を算出し、その平均値を各指標におけるモデルの視線予測精度とする。			
Model	AUC	CC	NSS
Baseline Model (Pan et al., 2017)	0.775	0.281	1.787
Fine-Tuning Model (Ours)	0.856	0.357	2.836

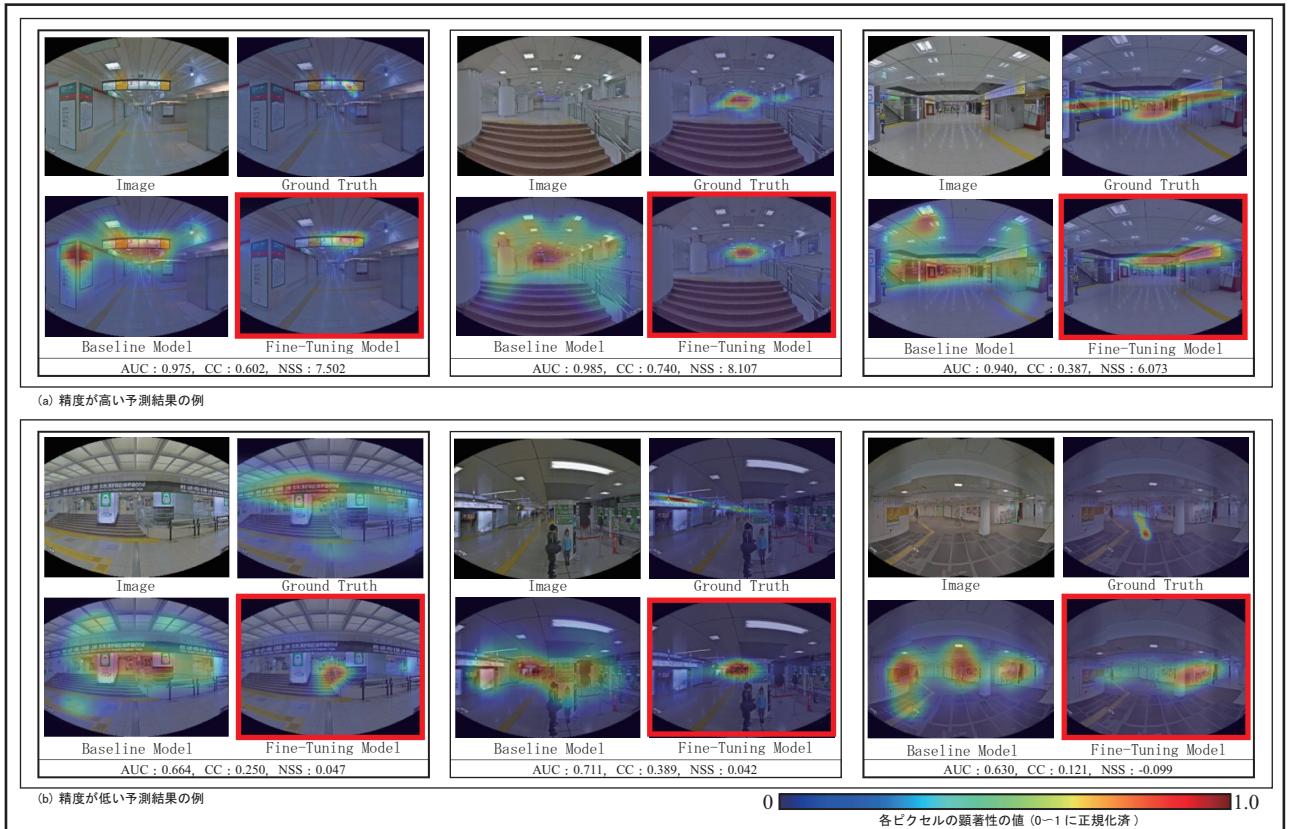


図 12 モデルによる視線予測結果の例

表2に、テストデータに対するモデルの予測精度を示す。視線予測モデルの精度評価指標には様々なものがあり、指標によってモデル間の優劣が異なる場合もある。そこで、算出方法が異なるAUC, CC, NSSという3つの指標で精度評価を行なった。いずれの指標もファインチューニングによって精度が向上しており、ファインチューニングの有効性が確認できる。

#### 4.4. モデルによる視線分布の予測結果

図12にモデルの予測結果の例を示す。まず、予測精度が比較的高い例（図12(a)）を見ると、ファインチューニング前と比較し、壁面や柱の広告物、天井の照明などが重要視されなくなっている。一方で、進行方向である通路の消失点付近への注視や、サインに対する集中的な注視など、探索歩行時に特有の注視傾向がある程度表現できている。

次に、予測精度が比較的低い例（図12(b)）を見ると、サインがあるにも関わらず、中心付近のみに分布が集中する例が見られた。他の地点にはない特殊なサインは学習が困難であることや、色覚的に目立たないサインは、モデルでは広告物や照明と同様に認識されていることなどが原因として考えられる。

また、予測精度が低い画像の中には、正解データの視線分布がまばらで予測が難しいものも多く見られた。SALICONデータセットのように、被験者に画像を一定時間ずつ見せる場合とは異なり、探索歩行実験では短時間で通過してしまう地点もある。注視点が少ない地点と多い地点で二極化してしまうことも、予測精度の低下につながる要因であると考えられる。

#### 4.5. 迷いやすさ評価への応用可能性

筆者らは、立ち止まり調査の結果に基づき、通路の構成やサインの位置などの空間特性を説明変数として、通路の分岐点における迷いによる立ち止まり数を推定する重回帰モデルを構築した（河村・沖、2020）。これと、視線予測モデルを用いた視認情報を組み合わせれば、静的な空間特性だけでなく、視覚的な分かりやすさも考慮した、よ

り多角的な空間の迷いやすさ評価を行える可能性がある。

### 5. まとめ

#### 5.1. 本稿の結論

本稿では、まず、GSVを用いた探索歩行実験で得られた視線行動データを分析し、空間の情報量の多さや不適切なサインの配置が、視線行動や迷いの発生に及ぼす影響を示した。また、線分散度 $D_i$ 、滞在時間 $T_i$ 、平均瞳孔径 $P_i$ という3つの指標を定義し、これを用いて、探索歩行時の視線行動の特徴をより定量的に把握した。

次に、汎用的な視線予測モデルを探索歩行実験のデータでファインチューニングし、探索歩行時の視線行動の特性を考慮した、より高い精度の視線予測モデルを構築した。さらに、モデルの予測結果をもとに、モデルの迷いやすさ評価への応用可能性を検討した。

#### 5.2. 今後の課題と展望

視線予測モデルの学習に用いたデータセットは、被験者が3名のみであり、データ数が少なく偏りも大きい。モデルの安定性を高めるために、追加実験によりデータ数を増やすとともに、ノイズとなり得るデータを前処理において除外するなど、モデルの改良を試みる予定である。

また、筆者らがこれまでに取り組んできた、静的な空間特性による迷いやすさ評価と、視線予測モデルを組み合わせた、建築空間の新たな迷いややすさ評価手法についても、引き続き検討していく予定である。

### 謝辞

実験に協力いただいた方々に謝意を表します。

### 参考文献

- 河村優介・沖拓弥（2020）鉄道駅構内における歩行環境や個人属性が迷いやすさに及ぼす影響.  
「地理情報システム学会講演論文集」, Vol.29  
河村優介・沖拓弥（2021）大規模ターミナル駅構内の空間特性が探索歩行時の視線行動や迷

いやすさに及ぼす影響 —Google ストリート  
ビューを用いた探索歩行実験を例に—. 人間・  
環境学会第 28 回大会

田場信裕・高良富夫・星野聖 (1996) ストレス負  
荷時の心拍数と瞳孔反応. 「テレビジョン学会  
技術報告」, 20, 75-79

福田亮子・佐久間美能留・中村悦夫・福田 忠彦  
(1996) 注視点の定義に関する実験的検討. 「人  
間工学」, 32, 197-204

Borji, A., Tavakoli, H.R., Sihite, D.N., Itti, L. (2013)  
Analysis of Scores, Datasets, and Models in Visual  
Saliency Prediction. 2013 IEEE International  
Conference on Computer Vision, 921-928

Jiang, M., Huang, S., Duan, J. and Zhao, Q. (2015)  
SALICON: Saliency in Context. 2015 IEEE  
Conference on Computer Vision and Pattern  
Recognition, 1072-1080

Pan, J., Canton, C., McGuinness, K., O'Connor, N.E.,  
Torres, J., Sayrol, E. and Giro-I-Nieto, X.A. (2017)  
SalGAN: Visual Saliency Prediction with Generative  
Adversarial Networks, arXiv:1701.01081