

OptWedge: 画面外の位置への誘導を目的とした 図形の認知的最適化

宮川 翔貴^{1,a)}

概要: スマートデバイスなどの小型ディスプレイは表示可能な範囲が狭いため、範囲外の情報を効率的に表示する方法が研究されている。たとえばユーザは、部分的に欠けた図形の一部を見ることで、ディスプレイ外にある興味のある地点 (POI) を知ることができる。この従来方法では、図形の一部が隠れていても全体を想像することのできるアモータル補完とよばれる認知処理を利用している。一方で、POI の定位精度はバイアスや個人差などの認知処理による影響を大きく受ける。そこで本研究では、認知処理による影響を考慮したコスト関数を設計し、図形の形状を最適化することで定位精度の向上を目指す。本研究では Wedge とよばれる図形を対象に、形状を最適化した OptWedge を検討する。具体的にはバイアスの扱い方が異なる二種類の OptWedge を検討し、従来の Wedge と比較した。実験の結果、OptWedge を用いることで近距離の範囲に対して従来よりも正確な誘導を実現できたことを確認した。

OptWedge: Cognitive Optimized Guidance toward Off-screen POIs

1. はじめに

ヒトの注意を特定の位置 (Point-of-Interest, POI) へ誘導する技術はナビゲーションやゲームなどのアプリケーションに有用である。しかし、スマートデバイスやヘッドマウントディスプレイ (HMD) のようなサイズの小さなディスプレイに対しては、POI が画面外に配置されてしまうケースが多くなる。ユーザが自ら POI を探索する方法が考えられるが、手間や時間がかかってしまう。そのため、POI が画面外にある状態でも、POI までの距離や方向といった情報をユーザに直観的に理解させる方法が必要である。

従来手法 [1], [2] では、プリミティブな図形の一部のみ表示することで POI の場所をユーザに推測させている。具体例として、Wedge [2] とよばれる二等辺三角形を図 1 に示す。Wedge の場合は、二本の等辺が共有する頂点に POI が存在し、ユーザはその頂点を想像することで POI までの距離と方向を知ることができる。これは、図形の一部から全体像を想像することのできるアモータル補完 [3] とよばれる認知処理を利用した方法である。認知処理を利用した誘導は Wedge に限らず広く用いられているが、実用上は

ヒトの推定に生じる誤差を考慮する必要がある。しかし、ヒトの推定を定量的に分析した研究はこれまでになく、従来手法の妥当性が明らかでないという問題がある。Wedge の例では、従来手法は図形の形状を決定するパラメータをアドホックに決定しており、その妥当性は明らかでない。そこで本研究では、図形の形状を定量的に評価するための指標として認知コストを導入し、最適化問題の枠組みで図形の形状を決定する。本稿では Wedge をとりあげ、形状を最適化した *OptWedge* による誘導を検討する。

提案手法の概要を述べる。我々はヒトの推定に誤差が生じる原因としてバイアスと個人差があると考え、これらを用いて認知コストを設計した。ただし、ヒトの認知処理は複雑であるため、認知科学的な観点からバイアスおよび個人差を定義するのは難しい。そのため、事前に様々な形状の Wedge に対する誤差を測定し、データに対して回帰分析をすることでこれらのモデルを作成した。我々はさらに、バイアスの取り扱いが異なる 2 種類の最適化を検討した。ひとつは、Wedge の頂点が POI と一致する前提のもと、バイアスが消えるように形状を最適化した *Unbiased OptWedge (UOW)* である。もうひとつは、Wedge の頂点が POI と一致する制約を外して形状を最適化した *Biased OptWedge (BOW)* である。これらの最適化の違いについて

¹ 三菱電機 情報技術総合研究所
Kamakura, Kanagawa 247-8501, Japan

^{a)} Miyagawa.Shoki@ds.MitsubishiElectric.co.jp

ては次節で詳しく述べる。以上の処理を、バイアスと個人差をモデル化するオフライン処理と、形状を最適化するオンライン処理に分けて実験し、従来手法である Vanilla Wedge (VW) との比較を通して提案手法の有効性を議論した。

2. 提案手法

2.1 認知コスト

本節では、最適化問題の目的関数として認知コストを導入する。簡単のため、Wedge が回転しない図 1 のような座標系を考える。Wedge の形状を決定するパラメータとして、従来 [2] にならって頂角 θ 、等辺長 l 、原点から頂点位置までの距離 d を定めた。ここで、パラメータの組み合わせ $p = (\theta, l, d)$ によって形状の定まる Wedge に対し、複数人が推定した位置の集合 $\{x_i\}$ の分布を考える。従来 [4] と同様に、我々は推定に誤差が生じる原因としてバイアス b と個人差 σ_x, σ_y があると考え、以下の正規分布 P で近似できると仮定した。

$$P(p) = \mathcal{N} \left(\begin{bmatrix} d + b(p) \\ 0 \end{bmatrix}, \begin{bmatrix} \sigma_x^2(p) & 0 \\ 0 & \sigma_y^2(p) \end{bmatrix} \right)$$

つぎに、正規分布 P がとりうる理想的な状態について考える。正規分布 P の理想的な状態とは、正規分布の平均位置が POI に一致し、かつ共分散行列が零行列のときである。これはヒトの推定に誤差が全く生じない状態に対応する。この状態を以下の正規分布 Q を用いて表す。ただし、原点から POI までの距離を d_{POI} とし、標準偏差 ϵ_x, ϵ_y は非常に小さな定数値とする。

$$Q(d_{POI}) = \mathcal{N} \left(\begin{bmatrix} d_{POI} \\ 0 \end{bmatrix}, \begin{bmatrix} \epsilon_x^2 & 0 \\ 0 & \epsilon_y^2 \end{bmatrix} \right)$$

認知コストとは、これらの正規分布 P, Q 間のずれを定量化したものである。認知コストは自由に設計してよいが、タスクに依存する点に注意する必要がある。たとえば、 y 軸方向の個人差よりも x 軸方向の個人差に対してペナルティを与えたい場合には、新たにハイパーパラメータを導入して値を調整する必要がある。本稿では簡単のために、ハイパーパラメータを伴わない指標としてカルバック・ライブラー情報量を認知コスト f として導入した。

$$f(\theta, l, d, d_{POI}) = D_{KL}(Q||P) = \int_x \int_y Q \log \frac{Q}{P} dx dy$$

2.2 UOW/BOW

UOW と BOW は距離 d を最適化するかどうかという点で異なる。図 4 のように、UOW では頂点位置が POI に一致するように距離 d を固定値 (= d_{POI}) に定め、バイアスがゼロに近づくように最適化する。一方で BOW では距離 d を変数とするため、頂点位置と POI は一般に一致せず、

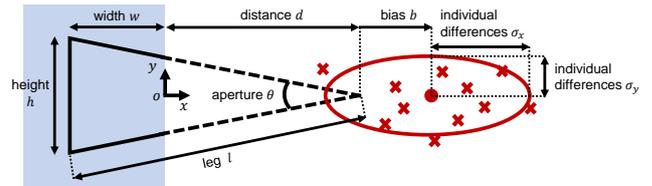


図 1: 本稿で用いるパラメータ。

表 1: 多項式回帰 (PR) とガウス過程回帰 (GR) による平均二乗誤差 [m^2] の比較。

	PR	GR
b	25.7	5.18
σ_x	8.03	4.96
σ_y	0.703	0.629

またバイアスはゼロに近づく必要もない。BOW では頂点位置と POI が同じ場所にあると思込んでいるユーザを騙すことになるが、UOW よりも正確な誘導を達成できる可能性がある。なぜなら、POI が遠くなるにつれ、バイアスをゼロに近づけるよりもバイアスを考慮して最適化の方がより効率的に認知コストを小さくできるためである。

3. 評価

3.1 実験 1: オフライン処理

3.1.1 実験内容

回帰分析に必要なデータを集めるために、実験参加者に様々な形状の Wedge を提示し POI を推定してもらう実験を行った。パイロットテストをふまえ、参加者から Wedge が表示されている平面までの距離 (10m) を基準として各パラメータがとる値を決定した。このとき、パラメータの定義域を満たす組み合わせは 375 通りである。

参加者が平面上の位置を容易に指定できるように、実環境ではなく仮想環境で実験を行った。参加者は椅子に座った状態で HTC Vive Pro を装着し、コントローラから発するレイの照準を合わせることで平面上の点を指定できる。

参加者に実験内容を説明したのちに、操作習熟のため 1 分程度の練習時間を設けた。その後、Wedge をランダムな順番かつランダムな回転角で表示し、100 個入力し終えるごとに 5 分の休憩を設けた。以上の手順を 20 代から 50 代までの男女 20 人の参加者に対して同様に実施した。なお、参加者は全員正常な視覚能力を有している。

3.1.2 結果

バイアス b および個人差 σ_x, σ_y の生データを図 2 に示す。この結果から以下の傾向 T1, T2 を確認できる。

T1 距離 d が大きくなるにつれてヒトは POI までの距離を過小評価する。

T2 個人差 σ_x, σ_y の間には頂角 θ に関してトレードオフがある。

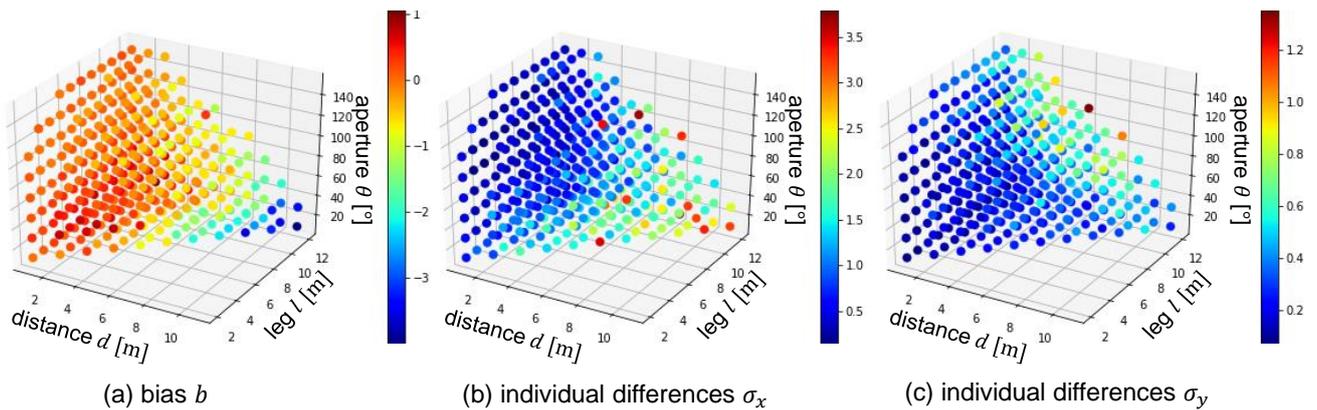


図 2: Wedge のパラメータ (θ, l, d) に対するバイアス b および個人差 σ_x, σ_y の生データ。

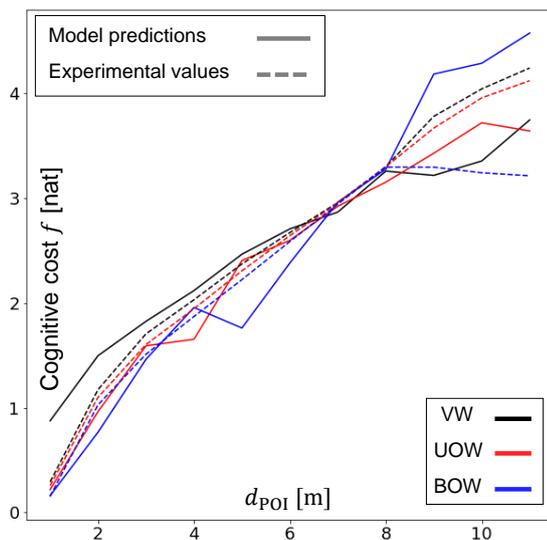


図 3: POI までの距離 d_{POI} と認知コスト f の関係。

つぎに、回帰分析を行いモデルを 3 種類作成する。ホテリングの T^2 法 [5] を用いて外れ値を除去し、多項式回帰とガウス過程回帰による回帰分析を行った。このとき、 k -分割交差検証 ($k = 5$) を用いて各モデルのハイパーパラメータを決定した。図 1 より、ガウス過程回帰の方が精度が高いため、次節のオンライン処理では認知コストの計算にガウス過程回帰モデルを使用した。

3.2 実験 2: オンライン処理

3.2.1 実験内容

POI までの距離 $d_{POI}[m] \in \{1, 2, \dots, 10, 11\}$ を変化させたときの 3 種類の Wedge (VW, UOW および BOW) を参加者に提示し、実験 1 と同様の実験を行った。ここで、最適化には最急降下法を利用し、VW のパラメータを初期値とした。また、理想的な正規分布 Q の分散は $\epsilon_x^2 = \epsilon_y^2 = 0.1m^2$ とした。実験環境および手順についてはオフライン処理の実験と同様だが、本実験ではデータの信頼性向上のために、参加者を 22 人に増やし、同じ形状の Wedge を 2 回繰り返して提示した。

3.2.2 結果

はじめに、POI までの距離 d_{POI} を変化させたときの各 Wedge の認知コストを比較した結果を図 3 に示す。実データを用いて計算した実測値を実線で表し、オフライン処理で作成したモデルを用いて計算した予測値を点線で表した。この結果から、POI までの距離が近いほど UOW および BOW が VW よりも認知コストを低く抑える傾向があることがわかる。一方で、 $d_{POI} = 7m$ を境に POI が遠くなるにつれてその優位性が失われており、特に BOW ではモデルの予測値と実験値の乖離が大きくなっている。

また、別の指標として POI からヒトが推定した位置までの二乗平均平方根誤差を評価した。VW, UOW および BOW の三群間について Wilcoxon の符号付き順位検定を実施し、ボンフェローニの補正にもとづいて有意水準を設定した。その結果、POI までの距離が特に小さい場合 ($d_{POI} \leq 2m$) に限り VW/UOW 間および VW/BOW 間に有意な差が得られたが、それ以外の場合については有意な差を確認できなかった。

また、最適化の効果について定性的な評価をするために、パラメータ空間上の認知コストおよびパラメータ空間上の点に対応する Wedge の形状を図 4 に示す。この結果から、最適化が以下の効果 E1, E2 をもたらすことがわかった。

E1 UOW および BOW では VW よりも頂角 θ が大きくなる ($d_{POI} = 11m$ を除く)。

E2 距離 $d_{POI} = 9m, 11m$ において、BOW の頂点は POI よりも遠くに位置する。

4. 議論

近距離 ($d_{POI} \leq 2m$) において OptWedge が VW よりも優位となった理由として、前節で述べた効果 E1 の存在が挙げられる。効果 E1 は従来研究 [2] における仮説 (“larger apertures would have led to smaller orbitals”) と一致しており、この効果によってヒトの推定の精度が向上したと推測できる。遠距離ではこの効果を確認できなかったが、

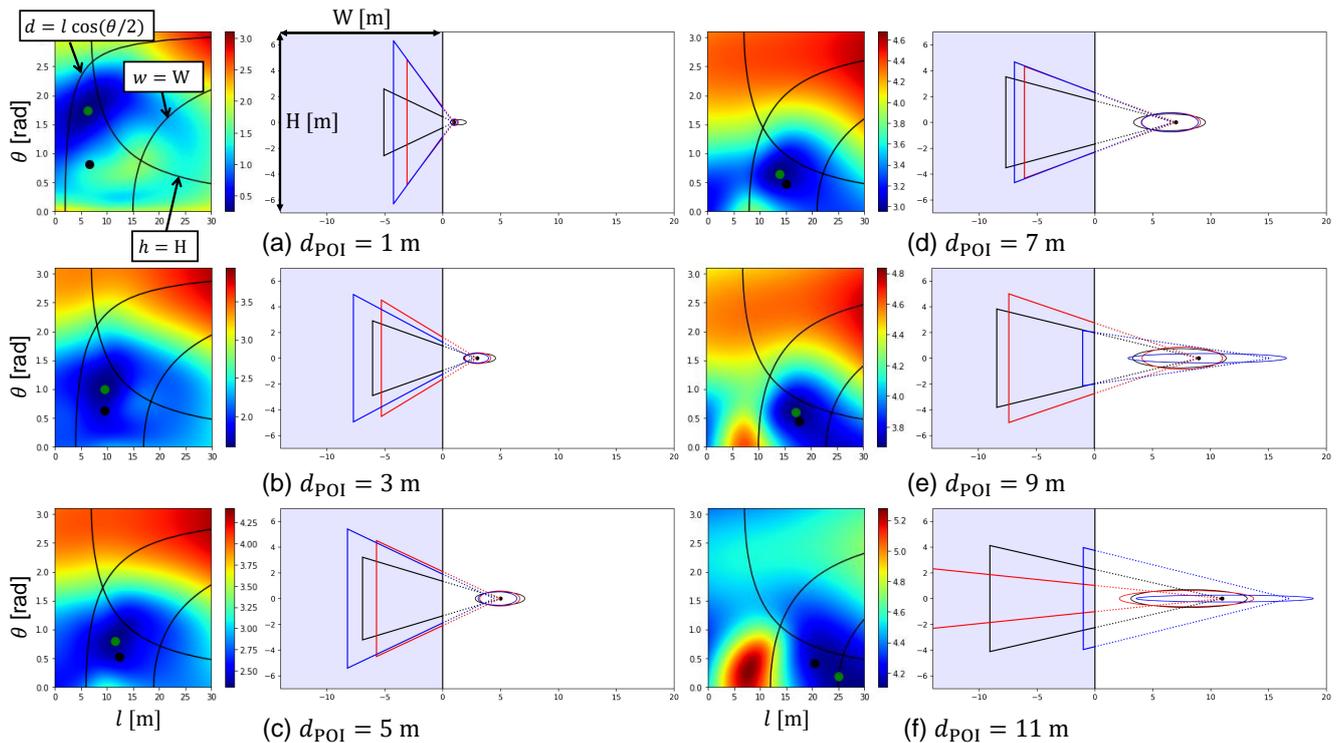


図 4: パラメータ空間における認知コストと、空間内の点に対応する Wedge (VW: 黒, UOW: 赤, BOW: 青). パラメータ空間上の曲線は制約条件を表しており、網掛けの領域に対応している。

図 3 において BOW の予測値は実測値と乖離しているため、モデルが不正確であることが原因といえる。

中距離 ($2 \text{ m} < d_{POI} < 7 \text{ m}$) において OptWedge と VW の間に有意な差が得られなかった理由として、VW の性能が十分に高いことが挙げられる。図 4 より、パラメータ空間上の初期値 (VW) と最適解 (UOW) を比較すると、距離 d_{POI} が大きくなるにつれ初期値の近くに最適解が得られていることがわかる。これは、従来 [2] におけるパラメータの決定方法は妥当性が高いことを意味する。

遠距離 ($7 \text{ m} \leq d_{POI}$) においてモデルが正確ではない理由として、過学習が挙げられる。傾向 T1 を学習したことで、BOW では効果 E2 のとおり距離 d が d_{POI} よりも大きい値となるように最適化される。しかし、図 2 のとおり、等間隔に区切ったパラメータを用いたため、距離 d が大きくなるにつれて定義域を満たすパラメータの組み合わせが少なくなってしまう。そのため、学習に用いるデータ数が少なくなり、汎化性能が低下してしまったといえる。これを回避するには、たとえば能動学習などによりユーザーに提示する Wedge のパラメータを動的に決定すればよい。

5. おわりに

本研究では、バイアスと個人差を用いた認知コストを導入し、Wedge の形状を最適化した OptWedge を提案した。また、バイアスの扱いが異なる 2 種類の最適化 (UOW, BOW) を提案し、従来手法 (VW) との比較を行った。実

験の結果、比較的距離の近い POI に対して提案手法が有効であること、また従来のアドホックな形状の決定方法が一定の妥当性があることを確認できた。一方で遠距離では、オフラインで作成したモデルの汎化性能が低いという問題が明らかとなった。今後はモデルを改善し、異なるディスプレイや Wedge 以外の誘導方法について提案手法の有効性を検証する。

参考文献

- [1] Patrick Baudisch and Ruth Rosenholtz. Halo: A technique for visualizing off-screen objects. CHI '03, p. 481–488.
- [2] Sean Gustafson, Patrick Baudisch, Carl Gutwin, and Pourang Irani. Wedge: Clutter-free visualization of off-screen locations. CHI '08, p. 787–796.
- [3] P. J. Kellman. A theory of visual interpolation in object perception. *Cognitive Psychology*, Vol. 23, pp. 141–221, 1991.
- [4] Sean Gustafson. Visualizing off-screen locations on small mobile displays. Master's thesis, Department of Computer Science, University of Manitoba, 2008.
- [5] Harold Hotelling. The generalization of student's ratio. *Ann. Math. Statist.*, Vol. 2, No. 3, pp. 360–378, 08 1931.