

場所による密度の偏りを考慮した訪問履歴データのインタラクティブ・クラスタリング

渡邊慧汰 *藤田秀之 †大森匡 †新谷隆彦 †

1 背景

地理的な点データ集合として定義される、長期間にわたる個人の場所訪問履歴データを対象に、インタラクティブにクラスタリングを行うインタフェースを提案する。日常に訪れる領域と、そうでない領域では点の密度が異なるため、そこで、効率的に距離パラメータ更新を行う OPTICS クラスタリングを利用し、クラスタリング結果を示す地図と、距離パラメータとクラスタ構造の関係の概観を示す図を提示して、後者を、地図のズームやスクロール操作に応じて適切に更新することで、インタラクティブなパラメータ調整を支援するインタフェースを提案する。

2 インタラクティブ・クラスタリング

インタラクティブ・クラスタリングは、ユーザにとって適切なクラスタリング結果を得るために、ユーザが処理過程に介入するクラスタリング手法である。Bae らは、インタラクティブ・クラスタリングに関する 105 本の論文を対象に、その目的の一部として、クラスタリング過程の理解と興味深いデータの発見を挙げている [1]。クラスタリング過程にユーザを参加させることは、クラスタリング結果の理解や解釈に有用であり、興味深いデータの特長、外れ値や関心領域の発見を支援することができる。

また、同論文では、インタラクションを行う対象や段階として、パラメータへのインタラクションを挙げている。パラメータへのインタラクションでは、結果へのインタラクションと比較し、パラメータ自体を明示的に操作する。

本研究では、ユーザがクラスタリングの過程を理解し、興味深いデータを発見することを支援するため、主にパラメータ調整の過程でインタラクションを活用する手法を提案する。

3 OPTICS

OPTICS(Ordering Points To Identify the Clustering Structure) は、密度ベースのクラスタリングである。OPTICS の入力は、点データセット D と、ふたつのパラメータ近傍距離 ϵ 、最小近傍点数 $MinPts$ である。クラスタ数は不要であり、訪問履歴データのような、事前にクラスタ数を決定することが難しい場合に適正している。

距離 ϵ 以内の点の数が $MinPts$ 以上の点 $p \in D$ をコア点と呼ぶ。また、 p からの距離 $MinPts$ 番目の点までの距離と、 $p, q \in D$ 間の距離の大きい方を、 p から q への到達性距離と呼ぶ。図 1 において、点 o がコア点、 $r(p_1)$ が p_1 への、 $r(p_2)$ が p_2 への到達性距離である。

OPTICS では、 ϵ 最大値と $MinPts$ を入力とし、まず、各点のクラスタリング順序 $order$ と到達性距離 $reachability$ を出力する。これらを用いて、最大値以下の任意の ϵ に対し、効率良く $O(N)$ の計算でクラスタリング結果を出力する。 ϵ 以下の到達性距離を持ち、クラスタリング順序の隣接する点集合がクラスタとなる。




図1 コア点と到達可能距離 [2]

横軸に $order$ 、縦軸に $reachability$ をとったグラフを到達性プロットと呼ぶ。例を図 2 に示す。階層的クラスタリングにおける樹形図に類する図であり、パラメータ ϵ と抽出されるクラスタの関係を可視化する。到達性プロットの ϵ 以下で連続する凹部と 1 つのクラスタが対応する。例えば、図 2 では、小さな ϵ で 3 つの小さなクラスタ、より大きな ϵ でそれらを囲むひとつのクラスタが生成されることが読み取れる。

* 電気通信大学情報理工学域 I 類情報数理工学プログラム 4 年

† 電気通信大学院情報理工学研究科




図2 クラスタ構造と到達性プロット [2]

4 クラスタリングインタフェースの提案

4.1 OPTICS のインタフェースと課題

OPTICS によるインタラクティブ・インタフェースでは、到達性プロット上でクラスタ構造を確認しながら、 ϵ の調整を行う。しかし、図3のような大規模データを対象としたOPTICSでは、到達性プロットの視認性が低下し、クラスタ構造の読み取りが困難である。




図3 約2万点の到達性プロット ($reachability \geq 40$ の領域省略)

関心ある領域に絞り込む方法として、データをビューポートで絞り込んでからクラスタリングを行う方法が考えられる。データを絞り込んでからクラスタリングを行う例を図4に示す。四角形の枠がビューポートであり、クラスタの領域は凸包によって示している。全てのデータがビューポートに入るとき(図4(1))と、クラスタの一部のみビューポートに入るとき(図4(2))とで、得られるクラスタが異なり、地図操作に対して、結果の一貫性を保てない。




図4 ビューポートによるクラスタリング結果の変化

4.2 ズームを考慮した到達性プロット

到達性プロットをビューポートに応じて集約化することで、関心ある領域に絞りこむ。ビューポート内の点群は、到達性プロット上で連続していると限らず、ビューポート外の点を間引くだけで、クラスタ構造が表現できない。そこで、ビューポート外の連続する点列を、仮想的な1つの点に置き換えることで、ビューポート外のクラスタ構造を表現する。仮想的な点の到達距離の値は、置き換えられる点の到達距離の最大値とする。

4.3 インタフェース構成とインタラクション手順

インタフェースの構成を図5に示す。インタフェースは大きく、上部の地図と下部の集約された到達性プロットに分けられる。地図では、スクロール・ズーム操作が可能であり、クラスタ領域を凸包で表示することで、現在の ϵ によるクラスタリング結果を可視化する。到達性プロットは、地図内のクラスタ構造を可視化する。地図を操作して関心のある領域を表示し、地図内の到達性プロットと、地図上の結果を確認しながら ϵ を調整し、クラスタリングを行う。



図5 インタフェース構成例

5 適用結果

提案手法の有効性と限界を明らかにするため、現在、ズームを考慮した到達性プロットによる視認性の改善について、前節で示したGLHデータを対象に定量評価を行っている。

参考文献

- [1] Bae et al., Interactive Clustering: A Comprehensive Review, ACM Computing Surveys 53(1), pp.1-39, 2020
- [2] Ankerst et al., OPTICS: Ordering points to identify the clustering structure. ACM Sigmod Record 28, pp.49-60, 1999