

図形描画プログラミングにおける視線情報からの思考過程の類推 Analogy of Thinking Process from Gaze Information in Drawing Programming

小林 智晴[†] 島川 博光[†]
Tomoharu Kobayashi Hiromitsu Shimakawa

1. はじめに

日本では 2020 年度からプログラミング教育の必修化が進んでいる。文部科学省が公表している”プログラミングの手引き”[1]では、プログラミング的思考を育むことが重要視される。この思考力は、簡易な空欄補充問題などでは評価できない。この力を評価するならば、思考の過程を観察すべきである。手引きを踏まえると、指導者は集団学習において思考力を重要視する必要がある。しかし、学習者の思考を見極めるにはある程度の時間を要する。さらに、複数人の思考を同時に観察・評価することは困難である。よって、プログラミング教育における円滑な指導のために、学習者の思考を評価する機械的システムが不可欠である。本論文では、学習者の思考過程を状態遷移モデルにすることにより、それがどのような思考であるかを推定する。課題実験の結果について、モデル化したさいの特徴と今後の展望について考察する。

2. 関連研究

谷川ら[2]は図形描画課題を用いて、プログラミングの解答過程を記録することで学生の習得項目を断定した。間違い方にも同様のパターンがあることを発見し、この結果は学習者が同様の思考を辿ることを示唆している。また、課題の要件を視覚的に確認できるため、図形描画は初学者に適している。これらを踏まえて、本論文では検証課題に図形描画プログラミングを採用する。

指導者による観察を機械が担うとなると、学習者の何らかの行動特性をセンシングする必要がある。既存研究に、視線追尾により学生の状態を判別するものがある。Busch ら[3]や Grafsgaard ら[4]は視線情報を含めた身体動作から、プログラミング学習における学生の感情や理解度を推定した。Jaques ら[5]は視線情報から ITS(Intelligent Teaching System)を利用する学生の感情を推定した。これらの結果は、学習時の視線は課題に対する考えや感情を反映することを示唆している。ただし、これらの研究は学生の思考の過程には注目していない。

3. 思考過程の推定

3.1 視線情報と思考

本論文では、学習者の一連の視線情報に隠れマルコフモデルを適用することで、思考の過程についても特徴を捉えて分析する。2章を踏まえると、学習者の視線は各々の思考を反映すると考えられる。理解の速い者とそうでない者では、見比べる、注視するなどの頻度、長さには違いがあるだろう。また、課題について同様のパターンを辿る者たちは、同様の視線遷移を辿ることも想像できる。このような仮定のもと、学習者の視線情報をモデル化することで思考過程を推定できると考える。手法の概要を図 1 に示す。以降は図 1 の流れに沿っ

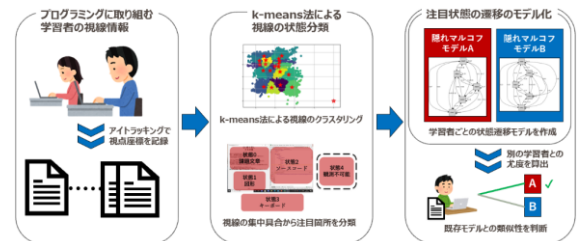


図 1 視線情報からの思考過程の推定

て課題実験の結果について言及する。

3.2 視線情報の収集

12 人の大学生を対象に課題実験を実施した。Python を用いた図形描画プログラミングである。環境による影響に配慮し、課題には同一のノート PC を使用した。視線情報の収集のために、Tobii 社製の視線追尾機器 Tobii Pro Nano を利用した。これにより、課題に取り組む数十分の間、およそ 1/60 秒ごとに、画面上の視線座標が観測された。学習者全体でデータの時系列の幅を均一にするため、観測データを平均補間により 1 秒間隔にリサンプリングした。

3.3 視線の状態分類

学習者ごとに、k-means 法を用いて視線情報のクラスタリングを行った。k=20 の条件での一人の学習者のクラスタリングの結果を図 2 に示す。赤い星はクラスタの重心であり、クラスタごとの色分けで視線座標がプロットされている。x 軸と y 軸はともに PC 画面の相対座標であり、左上の隅が(0, 0)、右下が(1, -1)に相当する。PC 画面は赤枠で囲った範囲に相当する。なお、過度に画面から視線が外れているなど、視線が観測できていないときのデータは、座標の値を仮に(2, -2)とした。図 2 から、画面上の一定の箇所に星、つまり視線が集まっていることがわかる。これは課題実験における課題文章、参考用の図形、ソースコードの 3 か所であった。また、画面より下、つまりキーボードにも満遍なく視線が移っていたこと

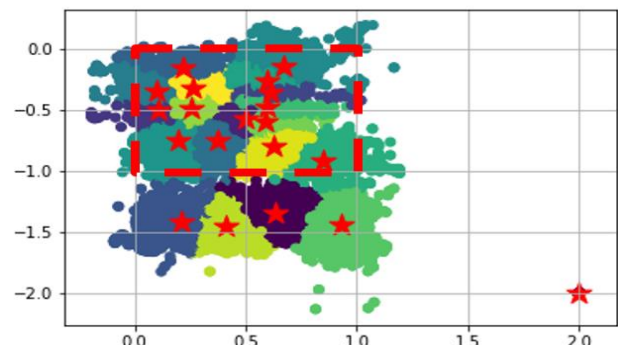


図 2 視線のクラスタリング結果

[†] 立命館大学 Ritsumeikan University

がわかる。そして、この特徴はすべての学習者のクラスタリング結果に共通であった。

クラスタリングの結果から、学習者の注目している箇所を隠れマルコフモデルにおける隠れ状態とした。これは、注目するもの、考えの及んでいるものに応じて、観測データである視線が生じることを表している。状態の割り当てを図3に示す。この状態はクラスタリング結果とPC画面の構成を加味して、課題文章、参考画像、ソースコード、キーボード、そして観測不可能の5つに分かれている。観測不可能の一つの状態とするのは、目線をそらす仕草や、目を薄める仕草を考慮するためである。



図3 5つの注目箇所

3.4 状態遷移モデル

分析に利用する隠れマルコフモデルは状態遷移モデルの1種であり、機械学習により学習者ごとの状態遷移モデルを作成した。このモデルこそ、学習者の思考過程モデルである。視線情報は座標を表す連続値であるため、ガウシアンマルコフモデルを利用した。機械学習の設定として、隠れ状態は3.3節で定義したとおり5つとする。初期確率については一律に0.2に固定した。また、各状態における平均的な座標値は構成上ある程度想定できたため、学習前に適当な値を設定した。

これらの設定をした上で、学習者ごとの状態遷移モデルのパラメータを機械学習により算出した。それらを可視化したものを図4に示す。状態間の矢印、つまり状態間の遷移確率は注目の切り替えの頻度を表している。それに対し自己遷移確率は同じ項目を注視する度合いを表す。例えば、頻繁にキーボードに目を落とす学習者であれば、状態3に連なる矢印上の確率が比較的高くなると考えられる。

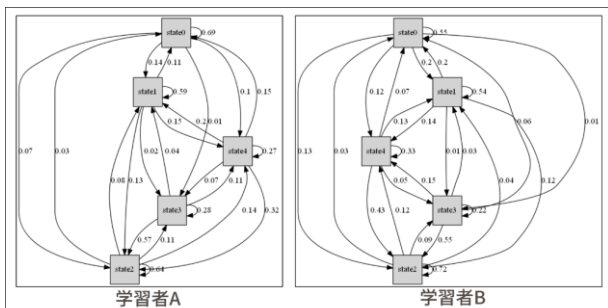


図4 2パターンの状態遷移モデル

すべての学習者のモデルについて、図4からも読み取れるように、状態間に比べて自己の遷移確率の方が大きな値をとった。これは数十分の取り組みの中で、一回ごとに数秒から数十秒は同じ項目を見つめるからだとして容易に推察できる。そのため、学習者間において一つ一つの遷移確率の大きさの違

いは個人差ともいえるだろう。しかし、状態0、状態2の自己遷移確率は他の状態よりも大きな値をとった。そして、解答時間が25分未満か、30分以上かで、すべての学習者は2つに大別できた。この2つのグループ間で、この状態0と2の自己遷移確率に共通の傾向が見られた。25分未満の比較的理解の早いグループは、状態0と2の自己遷移確率が6割以上に安定していた。それに対し30分以上の比較的時間を要したグループは、必ずどちらかの値は6割を下回っていた。

ここで、状態0は課題文章、状態2はソースコードであることに注目すると、この2つの項目は課題を解く上で絶対的に必要な項目である。学習者は課題の要件を課題文章から読み取り、考えをソースコードに書き起こして出力を確認する。加えて、時間を要したグループの方がこれらの状態の自己遷移確率が低かったことから自己遷移の違いは、単純に解答時間の長さに比例しているというわけでもない。

このことから、理解の早い学習者は、課題内容を要件ごとに正しく理解、実装できていたと推察できる。そのようなふるまいは、一度の注視を長く保つ要因となる。逆に、つまづいた学習者は理解、実装が滞ったさいに課題文章かソースコードの片方を長く注視して悩んでいた、もしくは片方の部分的な項目を何度も見返していたと推察される。このようなふるまいは対象となる状態の自己遷移確率を下げる要因となる。

以上より、理解の早い者と時間を要した者の間で状態遷移モデルのパラメータの違いが表れた。これは課題実験に取り組んだすべての学習者に共通した傾向である。よって、同様の課題設定であれば課題文章とソースコードの自己遷移確率から、学習者の課題に対する思考の良し悪しを推定できるといえる。

一方で、ビタビ法に基づき尤度から思考過程が類似した学習者の判別を試みたが、時系列長、つまり解答時間に尤度が影響を受けたため、2者間の類似性を判別するには至らなかった。

4. おわりに

本論文では、視線情報から学習者の思考過程を推定する手法を提案し、検証した結果をまとめた。思考過程の状態遷移モデル化により、思考過程の良し悪しを推定するための知見を示した。今後の展望として、学習者間の類似性まで判別するため手法を改良したい。例えば、時系列長を同一の思考内で一定の長さで切り出す操作が考えられる。その上で再度モデル化を行い、有効性を検証する。

参考文献

- [1] 文部科学省, 「小学校プログラミング教育の手引」(第三版) <https://www.mext.go.jp/content/20200218-mxt_jogai02-100003171_002.pdf> (アクセス日: 2021年6月17日)
- [2] Kohei Tanigawa, Fumiko Harada, Hiromitsu Shimakawa, "Detecting Learning Patterns during Exercise from Function Call Logs", International Journal of Advanced Computer Science, Vol.1, No.1, pp.30-35, (Jul. 2011)
- [3] Nigel Bosch, Yuxuan Chen, Sidney D'Mello, "It's Written on Your Face: Detecting Affective States from Facial Expressions while Learning Computer Programming", 12th International Conference on Intelligent Tutoring Systems-Volume 8474, pp.39-44, (2014)
- [4] Joseph F. Grafsgaard, Joseph B. Wiggins, Elizabeth Boyer, Eric N. Wiebe, James C. Lester, "Predicting Learning and Affect from Multimodal Data Streams in Task-Oriented Tutorial Dialogue", EDM, pp.122-129, (2014)
- [5] Natasha Jaques, Cristina Conati, Jason M. Harely, Roger Azevedo, "Predicting Affect from Gaze Data during Interaction with an Intelligent Tutoring System", (2014)