学習コンテンツ閲覧・視聴時における学習者の視線計測と注視データ解析手 法の開発

代表研究者 川嶋 宏彰 兵庫県立大学 社会情報科学部 教授

1 研究の目的

視線は人の注意・興味の推定やコンテンツ評価を行う上で重要な手がかりを持つ.特に、人が学習を行う際の視線は、閲覧・視聴するコンテンツに対する学習者の内的状態(知識や理解度、興味)の推定、さらには理解や集中を促すためのコンテンツ設計に有用な情報を持つことが期待できる[1,2,3]. そこで本研究では、デジタルコンテンツの閲覧やオンライン学習の映像視聴において、視線計測装置を用いて計測された視線データを基に、学習者(閲覧・視聴者)の心的状態(集中・注意・理解等)の推定やコンテンツ評価を行うための新たな手法の開発を目的とする.

LMS (Learning Management System) の普及や MOOCs (Massive Open Online Courses) をはじめとしたオープンエデュケーションの流れの中で、大学等の高等教育やオンラインコースでは、学習者の出席や課題提出だけでなく、受講中の行動を「計測」することが可能になりつつある[4]. 現在はログインや教材閲覧、ページ遷移など、主にクリック・ストリームの行動データ解析が行われており、これによって各受講者の講義への参加状況を従来よりも詳細にとらえ、早い段階で受講者への働きかけ等を行うことができるようになっている. しかし、「電子テキストや映像を実際にどのように見たのか」、「コンテンツのどの箇所・時点で特徴的な注視が行われたのか」といった学習者の詳細な行動を知ることはしばしば難しく、内容に踏み込んだ支援を行うにはページ遷移やクリック等の意図的行動の間における非意図的行動、もしくは行動の背後にある学習者の状態や状況の把握が必要となる. 本研究は、人の学習行動解析を、コンテンツに対する注視行動のレベルで行うことで、緻密な学習支援フィードバックの基盤構築を目指すものであり、本課題の1年間の研究期間では、特に講義映像視聴中の注意状態を考慮した注視行動モデルを軸に、視線データを用いた「視聴者の注意状態推定」および「注目用語ネットワークの抽出」を中心に研究を行った.

2 視聴者の注意状態推定

2-1 提案手法の目的と概要

映像講義を視聴中の学習者は、注意の状態が時々刻々と様々に変化する。たとえば、講義のスライド内容にのみ注意を向け、講師の発話や指示棒などの情報(これを「ガイド情報」と呼ぶことにする)には注意を向けない場合、逆に、講師の発するガイド情報に対して積極的に注意を向ける場合[2]、さらには、スライドが表示されたのちに、はじめはスライドを能動的に読み、途中から講師の説明に注意を向ける(ガイド情報を追従する)場合などである。実際、講義映像視聴時には注意対象の切り替わりが頻繁に見られることが予備検討でも明らかになっており、受講中の学習者の注意状態の遷移を詳細にとらえることで、視聴スタイルの違いや、理解度や成績との相関が明らかになると期待できる。そこで本研究では、この注意の切り替わりをモデル化するための確率モデルと、注意状態の推定手法を開発するとともに、視聴スタイルを特徴づけるための新たな解析手法を提案した[5]。

2-2 映像講義の視聴行動分析ための確率モデル

(1) 視線計測と注視領域系列

本研究では据え置き型の視線計測により得られた視線データを利用する。このデータは,各サンプリング時刻における視線と画面との交点を 2 次元座標で記録したものである。このとき,画面上に表示されている映像コンテンツはスライドを用いた講義映像であるとし,各スライドにおいて,文字や講師位置といった領域に分割されているものとする。視線速度等の情報も用いて時間方向でこの視線データを分節化する[6]ことにより,どの領域がどの時刻に注視されていたかの注視領域系列 $r_1, \dots, r_k, \dots, r_K$ を,各スライドにおいて得ることができる。スライドの領域が R_1, \dots, R_N に分割されているのであれば r_k はこのいずれかをとる(すなわち $r_k \in \{R_1, \dots, R_N\}$)。ここで添え字kはそのスライドの開始時刻からの注視領域の切り替わり回数に対

応し、以下ではこれを単に「時刻」と呼ぶ、また、スライド開始時点からの物理的な時刻(「メディア時刻」と呼ぶ)は t_k で表す.

(2)注意状態を考慮した受講中の注視行動モデル

本研究で提案する確率モデル[5,7]では、受講中の注視領域系列の背後に以下の3つの注意状態(以下ではこれをモードと呼ぶ)があると仮定する。それぞれをサブモデルとして、具体的には以下のコロンの右側に記載した確率でモデル化する。

(モードの)顕著領域(色, 重要語等)に注目: 各領域に対する注視確率 $P(r_k = R_i \mid m_k = 0) = a_i$ (モード1)スライドを能動的に確認: 領域間の遷移確率 $P(r_k = R_j \mid r_{k-1} = R_i, m_k = 1) = b_{ij}$ (モード2)講師ガイド(音声やポインタ)に追従: 時刻に依存した注視確率 $P(r_k = R_i \mid t_k = t, m_k = 2) = c_{it}$ 提案する確率モデルにおいては、視聴者の内部でこれら 3 モードの注意状態が時々刻々と切り替わりながら

画面内の各領域を注視する確率分布が定まり,この分布により実際の注視領域が確率的に決まると仮定する.

 $P(r_k|\cdot) = P(m_k = 0|\cdot)P(r_k|m_k = 0) + P(m_k = 1|\cdot)P(r_k|r_{k-1}, m_k = 1) + P(m_k = 2|\cdot)P(r_k|t_k, m_k = 2),$

ここで、 (\cdot) はk番目の注視よりも前の注視領域 r_{k-1}, r_{k-2}, \dots やその時刻情報 t_k, t_{k-1} であるとする.

(3) 注視行動モデルにおける注意状態

講義映像視聴中の注視領域系列を上記のようにモデル化することで、視聴者がどのような注意状態やスタイルで映像を視聴していたかを解析することが可能となる。この解析には、各時刻におけるモード確率 $P(m_k=m), m \in \{0,1,2\}$ を用いる。この確率は、時刻kにおいて視聴者がどのようなモード(注意状態)にあるかを表し、0 から 1 の間の値をとる。ただしモード確率の総和は 1 である ($\sum_{m=0}^{2} P(m_k=m)=1$).

典型的な状況として、たとえば映像中の講師の音声やポインタの動き(ガイド情報)を追っているならば、その時刻においてモード 2、すなわち $P(m_k=2)$ の値が、 $P(m_k=0)$ や $P(m_k=1)$ に比べて高くなる.一方で、もしガイド情報を追うのではなく、能動的にスライドのコンテンツを見ているならば、モード 1、すなわち $P(m_k=1)$ の値が高くなる.もしいずれでもない(他のことに注意が向くなど)の場合は、モード 0、すなわち $P(m_k=0)$ の値が高くなることになる.

(Mode 1) (Mode 2)
Follow content Follow lecturer's guide

Mode-Mixture time

図 1. 注視行動モデル:提案するモデルでは複数の注意状態(モード)が混合して映像への注視行動が行われると仮定する.(図の Mode1, Mode2 に加え本文中で説明しているように Mode0 を考慮する.)

観測された注視領域系列 r_{seq} に対するモード確率 $P(m_k = m)$ は,事後確率 $P(m_k = m \mid r_{\text{seq}}) = \gamma_k(m)$ (m = 0,1,2, k = 0,1,2,...,K)として確率推論できるため,このモード遷移確率(の事後確率)の時系列パターンを通じて注意状態の変化を調べることで,次節で述べるような視聴スタイルの解析を行うことができる.

(4) 注視行動モデルの機械学習

各領域を注視する確率分布(上記の各モードにおける確率)のパラメタ a_i,b_{ij},c_{it} は,同じ講義映像を受講した複数の受講者の視線データから機械学習によって推定することが可能である[7]. また,あらかじめ学習されたモデルを用いることで,新たに得られた視線データを解析することも可能となる.

2-3 モード遷移パターンの定量化

各視聴者が各時刻でどの注意状態のモードにあるかは、視線データ(および視線データに対して前処理を行うことで得られる注視領域系列)から直接的には観測できないが、2-3 節で述べたように、確率推論を応用することでモード事後確率 $\gamma_k(m)$ として推定することが可能となる。すなわち、個々の視聴者の視聴スタイルは、3 モード間をどのように移り変わるかによって特徴づけられる。本研究では、この遷移確率を計算することで(音声認識等でもよく知られる)隠れマルコフモデル(hidden Markov model、HMM)と同様の扱いが可能であることに着目し、2 つのモード遷移パターン間の類似度・非類似度を定量化する方法として、(HMM 同士の非類似度の尺度としてもしばしば用いられる距離である)カルバックライブラー情報量に基づ

く疑似距離[8]を利用する手法を提案した[5]. 実験結果を含め 2-4 節で詳細を説明する.

2-4 実験参加者データによる検証

33 名の実験参加者に「統計学」の動画を視聴してもらい、そのときの視線計測データを用いて前節までで説明した提案手法の検証を行った.評価を行う上では正解となる注意状態を知る必要があるが、実際には時々刻々と変化する視聴者の注意状態を記録するのは困難であるため、あらかじめ以下の3種類の視聴条件を設定し、典型的な受講時のスタイルを模擬した.

Group1: 通常視聴 (normal) Group2: 暗算タスク (sub task) Group3: 音声無し(no guide)

たとえば暗算タスクでは、しばしば mind wondering と呼ばれる[9,10], 視聴中に別の事柄に意識が向いている状態を模擬するためのものである。また、音声無しのタスクは、講師の説明(ガイド情報)よりも講義資料に注意を向けて視聴者自身が能動的に意味内容を追っている状態を模擬するために設定した。11 人ずつをGroup1 から Group3 にランダムに割り当てて実験を行った。

視聴後に、各視線データから 2-2 節で述べたのモデルを推定するとともに、モード遷移パターン(各時刻におけるモード事後確率 $\gamma_k(m)$)を確率推論した。あるスライドを視聴した際のモード事後確率の推定結果例を図 2 に示す。このパターンは推定された注意状態の時間的変化を表すものであり、たとえば(c) は音声無しタスクであるが、(a) 通常視聴や(b) 暗算タスクとは異なり、能動的にスライドを確認する必要があるため、ほとんどの時間帯でモード 1 をとることが分かる。

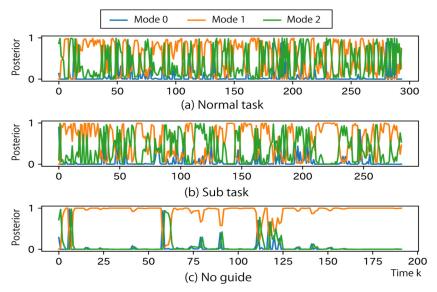


図2. 3つのタスクそれぞれにおけるモード事後確率系列の例: (a) 通常視聴 (normal task, Group 1), (b) 暗算タスク (sub task, Group 2), (c) 音声無し (no guide, Group 3)

図 2 の結果は各タスク 1 人ずつの例であるが,以下では,同じ映像を視聴した 33 人すべての実験参加者のモード遷移パターンを解析した結果について述べる.具体的には,1 枚のスライドに対応する時間区間における視線データより,各実験参加者のモード事後確率 $\gamma_k(m)$ を推定し,この系列を用いてさらにモード遷移確率を推定した.このモード遷移確率は実験参加者ごとに求まるため,その統計情報を箱ひげ図で可視化したものが図 3 である.図 3 からは,(a) 通常視聴ではモード 2 への遷移確率が高く,モード 0 への遷移確率が低いのに対し,暗算タスクを行ったグループでは,モード 2 への遷移がそれほど高くない(講師の説明などのガイド情報に追従した視聴にはなっていない)ことが分かる.一方で,音声無しの場合は,当然ながらモード 1 の遷移確率が高く,能動的にスライドを確認するような視聴パターンであることが確認できる.

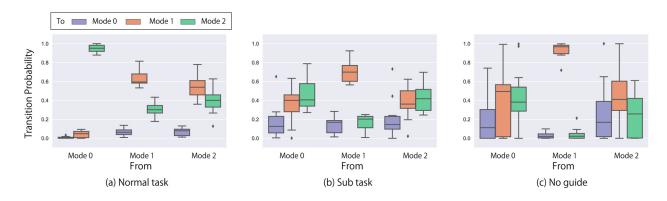


図3. 3タスクそれぞれにおいて提案モデルにより推定されたモード遷移確率の統計情報: (a) 通常視聴 (normal task, Group 1), (b) 暗算タスク (sub task, Group 2), (c) 音声無し (no guide, Group 3)

2-3節で説明したモード遷移パターンの解析法(疑似距離)を用いることで,遷移確率を(図3のような統計情報ではなく)個々に利用し,各視聴者間の類似性や非類似性を調べることができる.図4は,すべての実験参加者のペアにおいて,それらの疑似距離を計算することで,互いのモード遷移パターンがどの程度互いに離れているかを可視化したものである.実際には33人の実験参加者の全ペアにおける疑似距離が求まるが,これに多次元尺度構成法を適用することで2次元空間に埋め込んだ.(a)は通常視聴タスクを行った11人だけを取り出して,各視聴スタイルの違いを可視化した図であり,(b)は3つすべてのタスクにおける視聴スタイルの可視化である.(a)からは,たとえば18番の実験参加者はモード0の状態が長く続く傾向があるなど,同じ通常視聴のタスクであっても,人によって異なる視聴スタイルをとることがわかり,また(b)においては3つのタスクが2次元空間でも分離されている.このように,提案手法を応用することで視聴パターンを特徴づけることができるため,今後は成績との相関などを詳細に調査することを予定している.

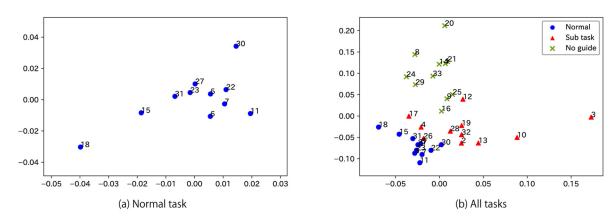


図4. 多次元尺度構成法による学習済みモデル間の非類似度の可視化結果(図中の番号は視聴者ID): (a) 通常視聴を行った11人(Group 1), (b) 3つすべてのタスクにおける計33人(Group1-3)の非類似度の構造を2次元で表した結果.マーカーの色はタスクに対応する.

3 注目用語ネットワークの抽出

3-1 提案手法の目的と概要

講義等で教授する知識は、様々な用語やそれらの関係からなる。たとえば確率・統計の科目であれば、「(ベルヌーイ分布〈用語〉) は(二項分布〈用語〉) の (n=1 の特殊な場合に相当する〈関係〉)」などである。これら用語間の関係を表現するには、(用語 1、関係、用語 2) の 3 つ組(triple)を用いる方法がひとつであり、

このような表現を用いる場合、様々な用語間の関係はネットワーク状の構造(グラフ構造)となる. 講義コースの各回において、講師が教授しようとする知識のネットワーク(以下ではこれを知識マップと呼ぶ)を、コンテンツや講師の解説から、各受講者が自らの知識として構築していけるかが、学習におけるひとつの鍵となる. そこで本課題では、映像視聴時の学習者(視聴者)の注視系列データを基に、どのような用語ペアに特に注目していたかを抽出するとともに、これらの用語ペアが、本来教授しようとする知識マップとどの程度オーバラップやずれがあるかを解析する手法を検討した. 本手法は、各受講者が講義の内容をどの程度追うことができているか(もしくはずれが生じているか)を解析するだけでなく、コンテンツそのものの分かりやすさの評価、たとえば多数の受講者のデータから、そのコンテンツがどのような意味内容を伝達できているかを解析するといった応用も考えられる.

以下ではこの後者, すなわち同じ映像コンテンツを多くの人が視聴した際に, 視聴者がよく注目した用語ペアの集合(用語ネットワーク)を抽出する手法の検討結果[11]について報告する.

3-2 注目用語ペアの自動抽出

想定する映像コンテンツは,通常の映像と音声情報の他,以下の情報が付与されているものとする.

- (A) 画像領域情報 (領域の位置座標, および用語や式などの領域内情報)
- (B) 発話内容 (テキストデータ)

ここで,(A)では自動画像分割手法や文字認識等を利用することも可能であるが,本研究では分割・認識精度の問題が混在しないように人手での分割を行った.(B)は音声発話の書き起こしデータであるが,MOOCsにおいて公開されている映像講義コースでは多くの場合音声の書き起こしデータが付与されている.また,音声認識によって自動取得することも可能である.

一方で、視線データからは2-1節で述べた注視領域系列から以下の情報を取得することができる.

- (i) 連続して注視される領域ペア情報(領域間の遷移確率が一定の閾値以上)
- (ii) 近い時刻で注視される領域ペア情報(移動時間窓内で共に注視される領域)

この(i)と(ii)のいずれかを,(A)の領域内情報(用語)と組み合わせることで,視聴者の注目用語ペアを自動抽出できる.

(i)や(ii)の確率は同じコンテンツを視聴した複数の視聴者の注視領域系列から直接計算することも可能であるが、[7]の予備検討では、2節の手法によりいったん注視領域系列の背後にあるモードを推定して得られるモードごとの確率分布が、直接計算した確率分布に比べて、より疎であり有用な情報を持つ傾向がみられたため、以下では、(i)として、2-2節で導入したモード1における確率分布 $P(r_k=R_j\mid r_{k-1}=R_i,m_k=1)=b_{ii}$ を、(ii)には、モード2の確率分布 $P(r_k=R_i\mid t_k=t,m_k=2)=c_{it}$ を利用することとした。

3-3 実験参加者データによる検証

まず、KH コーダー[12]と呼ばれるテキストマイニングツールを用いて、(B)の音声書き起こしデータを解析し、重要語を抽出した。実験に用いた講義映像のトピックである統計学を教えている講師に、対象とする映像コンテンツを視聴してもらい、抽出された重要語を基に、手動で知識マップをあらかじめ作成してもらった。この作成者を講師1とする。参考のために研究者自身(以下ではこれを講師2とする)も同じ映像コンテンツより知識マップを作成した。なお、講師1,2はいずれも映像コンテンツ内の講師とは異なる。

一方、2-4 節の検証で用いたのと同じ視線計測データ(ただし通常視聴の 11 人分のデータのみ利用)に対し、2-2 節(4)の機械学習を適用し、得られたモード 1 および 2 の確率分布 b_{ij} と c_{it} のそれぞれに対し、 (i) や(i) の方法で領域ペア情報を抽出した。その後、(A) の領域情報と合わせることで、(i) と(i) のそれぞれにおいて注目用語ペアを 30 ペア抽出した。

次に、講師により作成された知識マップに、抽出された30用語ペアがそれぞれ含まれているか否かを判定した。図5は講師1の作成した知識マップ(映像コンテンツのうちスライド3枚分)である。そのうちの1つのスライドに対応する時間区間を、視聴時の視線データより切り出して対象データとし、そこから抽出された用語ペアに関して図5では赤色で示している。また図6は、対象データより抽出された30用語ペアのうちこの知識マップに実際に含まれる割合をプロットしたものである。横軸は知識マップ(グラフ構造)上で許されるパスの長さであり、パス長が2や3は、用語ペアが他の用語を介して間接的に結ばれる場合も許

容したときの割合となる. 凡例の Mode1 と Mode2 はそれぞれ(i)と(ii)に対応し,これと(A)の領域内の用語を利用した結果である. 一方で,凡例の F-Mode2 は、さらに(A)の発話内容から抽出した重要語に絞って A0 用語ペアを抽出したものである. 視線データから得られたこれらの結果より、講師の作成した知識マップに含まれる用語ペアが、実験参加者の視聴時に実際に注目されていたことが分かる.

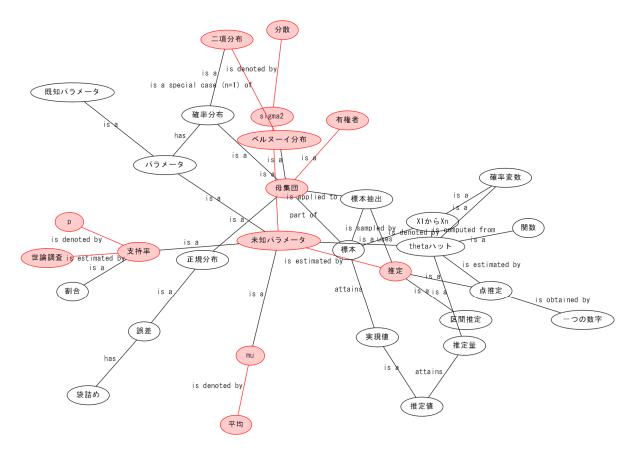


図 5. 教授内容の知識マップ(3 スライド分,講師 1 による作成)に対し,あるスライドにおける注視系列より抽出された用語ペア(赤)(図 6(a)の F-Mode1 に対応)を可視化したもの.知識マップは本来は有向グラフであるがこの図では矢印の向きを省略している.

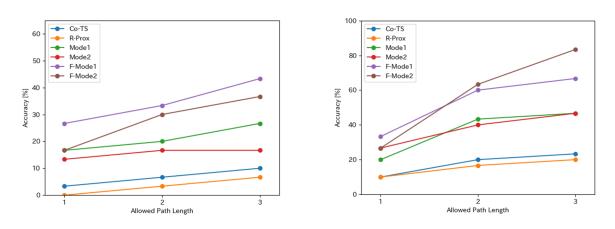


図 6. 抽出された 30 用語ペアが教授内容の知識マップに含まれる割合(横軸は用語間に許容する最大パス長): (左) 講師 1 により作成された知識マップを利用, (右) 講師 2 (研究者自身) により作成された知識マップを利用 (参考情報)

なお、図6の凡例における R-Prox は、(A)の領域情報のうち、領域の位置情報を使って単純に近い領域ペアから用語ペアを抽出した場合、Co-TS は、(B)の発話文章における共起性を利用して用語ペアを抽出した場合であり、いずれも講師が想定するような用語の関係性とは大きく異なる用語ペアを抽出する傾向がある.一方で、注視情報を利用した場合は、これらコンテンツ情報のみを使う場合に比べ、多くの重要な用語ペアが抽出されていることが分かる.したがって、ここで検討した、実際に注目された用語ペアが講師の想定する知識マップとどれだけオーバラップするかの定量化は、映像コンテンツの良さを評価するひとつの尺度となりうる.また、デジタルコンテンツからの知識マップの自動抽出はラーニングアナリティクス等の教育・学習データ分析に関する分野においても注目されており[13,14]、コンテンツおよび視線データより自動抽出された用語ペアの情報を知識マップの構築へ利用することも考えられる.さらに、個々の学習者の注目していた用語をネットワークとして抽出することは、学習者が自らの視聴を振り返り次に学習すべきトピックを確認するような可視化ツールや自動推薦といった学習支援システムの開発にもつながると期待できる.

4 研究の将来計画

本研究では、デジタルコンテンツの閲覧やオンライン学習の映像視聴において、視線計測装置を用いて計測された視線データを基に、学習者(閲覧・視聴者)の心的状態(集中・注意・理解等)の推定やコンテンツ評価を行うための新たな手法を開発した。本研究の全体構想は図7のような枠組みであり、学習者の状態や状況を、(A)学習行動計測と(B)コンテンツ解析を合わせた(C)学習行動分析から詳細に詳細にとらえ、推定された状態・状況に応じて(D)適切なフィードバックやコンテンツの最適化を行うとともに、その効果を再び学習行動分析を通じて評価する、というフィードバックループを構築することを目指している。本研究調査では、主に(A)から(C)の検討を「注意状態のモデル化」を軸に行い、今後の研究開発につながる重要な知見が得られたといえる。

今後は、(A) 学習行動計測については、学習時のページ遷移や課題解答といった他の学習行動情報も利用するとともに、視線計測では、たとえばカメラ等を用いる[15]などの、より簡易な計測方法の導入を試みる. (B) コンテンツ解析では、テキストや画像等の認識をはじめ自動解析の手法を検討する. これらの情報を基に、(C) の学習行動分析では、学習者のモデル化および知識推定手法の開発を進め、(D) のフィードバックにおいて、学習者の状態・状況の「可視化」や、それを踏まえた「質問生成・学習コンテンツ推薦」、さらには学習者が利用する講義映像やスライド等のコンテンツ改善や最適化について検討する計画である.



図 7. 研究の将来計画における本研究調査の位置づけ

【参考文献】

[1] Nguyen, C. & Liu, F. (2016). Gaze-based Notetaking for Learning from Lecture Videos. CHI Conference on Human Factors in Computing Systems, 2093–2097.

- [2] Sharma, K., Jermann, P., & Dillenbourg, P. (2014). "With-me-ness": A Gaze-Measure for Students' Attention in MOOCs. International Conference of the Learning Sciences (ICLS), 1017–1022.
- [3] Mangaroska, K., Sharma, K., Giannakos, M., Trætteberg, H. & Dillenbourg, P. (2018). Gaze Insights into Debugging Behavior Using Learner-Centred Analysis. ACM International Conference on Learning Analytics & Knowledge (LAK), 350–359.
- [4] Kim, J., Guo, P. J., Seaton, D. T., Mitros, P., Gajos, K. Z., & Miller., R. C. (2014). Understanding In-Video Dropouts and Interaction Peaks in Online Lecture Videos. International Conference on Learning @ Scale (L@S), 31–40.
- [5] Kawashima, H., Ueki, K., & Shimonishi, K. (2019). Model-Based Analysis of Gaze Data During Video Lectures. 27th International Conference on Computers in Education (ICCE 2019), 81–86.
- [6] Salvucci, D. D. & Goldberg, J. H. (2000). Identifying Fixations and Saccades in Eye-Tracking Protocols. Symposium on Eye Tracking Research & Applications (ETRA), 71–78.
- [7] Kawashima, H., Ueki, K., & Shimonishi, K. (2019). Model-Based Analysis of Gaze Data During Video Lectures. 3rd Multimodal Learning Analytics Across Spaces (CrossMMLA) Workshop, the Companion Proceedings of LAK19, 526–533.
- [8] Juang, B. H. & Rabiner. L. R. (1985). A Probabilistic Distance Measure for Hidden Markov Models. AT & T Technical Journal, 64 (2), 391–408.
- [9] Mills, C., Bixler, R., Wang, X., & D'Mello, S. K. (2016). Automatic Gaze-Based Detection of Mind Wandering during Narrative Film Comprehension. 9th International Conference on Educational Data Mining, 30–37.
- [10] Hutt, S., Hardey, J., Bixler, R., Stewart, A., Risko, E., & D'Mello, S. K. (2017). Gaze-based Detection of Mind Wandering during Lecture Viewing. 10th International Conference on Educational Data Mining, 226–231.
- [11] Kawashima, H. (2020). Finding Semantic Structure of Content from Gaze Data, the Companion Proceedings of LAK20, 442–445.
- [12] Higuchi, K. (2016). A Two-Step Approach to Qualitative Content Analysis: KH Coder Tutorial Using Anne of Green Gables (Part I). Ritsumeikan Social Science Review 52(3): 77–91.
- [13] Fillos, A. and Ochoa, X. (2019). Semi-Automatic Generation of Intelligent Curricula to Facilitate Learning Analytics. The 9th International Conference on Learning Analytics & Knowledge (LAK), 46–50.
- [14] Flanagan, B., Majumdar, R., Akcapınar, G., Wang, J., & Ogata, H. (2019). Knowledge Map Creation for Modeling Learning Behaviors in Digital Learning Environments. Predicting Performance Based on the Analysis of Reading Behavior, the Companion Proceedings of LAK19. 422-430.
- [15] Zhang, X., Sugano, Y., et al. (2015). Appearance-based Gaze Estimation in the Wild. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 4511–4520.

〈発表資料〉

題名	掲載誌・学会名等	発表年月
Finding Semantic Structure of Content from Gaze Data	Companion Proc. 10th International Conference on Learning Analytics & Knowledge (LAK20)	2020.3
Modeling Video Viewing Styles with Probabilistic Mode Switching	Proc. 27th International Conference on Computers in Education (ICCE)	2019.12