

学習ログデータを用いた成績向上のための 学生別フィードバック

青木 大誠¹ 島田 敬士² 堀 磨伊也³

概要: 本研究では、電子教材の学習ログデータから学生個人の学習レベルに適した、成績向上のためのフィードバックを行う手法を提案する。従来、学習ログデータを活用し、成績予測やフィードバックを行う研究が多く存在する。しかし、効果的なフィードバックをするためには、成績向上の要因を特定する必要がある。そこで、本研究では、対象学生の予測成績よりも一つ上位の成績を収めている学生のグループの過去のログデータ群と対象学生の現状の学習ログデータとを比較し、成績向上の要因の特定を検討する。特定した要因をフィードバックとして提示する。本論文では、対象学生との比較先のグループを変更することによってフィードバック内容に差異が生じることを確認し、学習レベルに適した成績向上のためのフィードバックを試みる。

1. 序論

教育分野での講義や教材の電子化が進む中、e-learning が普及してきている。それに伴い、電子教材の学習ログデータを収集・分析し、分析結果をフィードバックする研究が進んでいる [1]。現在、多くの大学において電子教材を導入した講義が展開されると同時に電子教材の学習ログデータを活用する研究 [2][3] が行われている。また、インターネット上で講義を受講するオンライン学習も存在し、その電子教材の学習ログデータも研究 [4] に使用されている。これらの研究は、学習ログデータの収集、分析、フィードバック、評価改善を繰り返すことで、学生の成績改善だけでなく教員の指導方法や電子教材の改善といった教育効果の最大化を行っている。また、ダッシュボードと呼ばれるフィードバックを教員または学生に提示するユーザインタフェースの開発 [5] も進んでいる。ダッシュボードはフィードバックの内容をテキストだけでなく、グラフや表など直感的にわかりやすい形式で提示できる。

オンライン上での講義だけでなく、電子教材を導入した対面形式の講義においても学習ログデータを用いた成績向

上のためのフィードバックは有効であると考えられる。従来の対面形式の講義では担当教員が多数の学生に向けて同一のフィードバックを行うため、学生個人の学習レベルにあったフィードバックがし難いと考えられる。しかし、電子教材から収集した学習ログデータを分析することで、学生個人の学習レベルを特定し、その学習レベルに適したフィードバックができると考えられる。これにより学生の効率的な成績向上を促すことができると期待できる。

現在、九州大学ではオンライン学習支援システム M2B の一環である電子教材システム BookRoll [6] を用いて講義を実施している。BookRoll においても学習ログデータの収集が可能となっており、他大学同様、学習ログデータを用いた研究が行われている。本研究では、BookRoll から収集した学習ログデータを分析し、学生個人の学習レベルに適したフィードバックについての検討を行う。提案システムでは、学習レベルに適したフィードバックを行うことで学生の効率的な成績向上を目指す。

2. 関連研究

インターネット上で世界各国の大学の講義を受講できるオンライン学習システムとして広く利用されている Massive Open Online Courses (MOOCs) では、使用されている電子教材から学習ログデータを収集できる [4]。収集される学習ログデータの種類は様々であり、アクセス履歴や電子教材の操作履歴などがある。また、別の学習ログデータの収集方法としてネットワーク解析を用いた方法 [7] も開発されている。以上のようにして得られた学習ログデータの

¹ 九州大学工学部電気情報工学科
Department of Electrical Engineering and Computer Science, School of Engineering, Kyushu University

² 九州大学大学院システム情報科学研究院
Graduate School and Faculty of Information Science and Electrical Engineering, Kyushu University

³ 九州大学エネルギー研究教育機構
Platform of Inter / Transdisciplinary Energy Research, Kyushu University

活用例は多く、学生の学習活動の把握や成績予測や成績向上のためのフィードバックなどが挙げられる。

学習活動の把握の例としては、学習ログデータの分析による学生の学習戦略の特定 [8] や学習行動の変化検出 [9] 等が存在する。講義日程途中で学生の学習活動を把握することにより、落第もしくは芳しくない成績となりそうな学生を事前に見つけ出すことが容易となる。学習ログデータを用いた成績予測を行う研究 [2][10] も多数あり、学生の知識状態を考慮した成績の予測 [2] や時系列データでの成績の予測 [10] などがある。様々な要素を考慮した成績予測システムが開発されており、講義日程の途中においても正確に成績を予測できるようになっている。

学習ログデータをフィードバックする研究として、学生に対しては他の学生との学習ログデータを比較した学習の状況 [11] を、教員に対しては学生の予習復習状況や課題の達成度 [12] を提示するものが挙げられる。フィードバックの学習推進効果はすでに確認されており [11], 学習レベルに最適なフィードバックを学生に提示することで、より学習推進効果を増幅させることができると期待できる。学習推進効果が高まることにより学生の効率的な成績向上が見込める。

本研究では、対面形式の講義における学生の学習レベルに適した、成績向上のためのフィードバックシステムの開発をする。また、従来研究の課題である学習ログデータを分析する際の学生および教員のプライバシーの保護や学習活動の可視化など [13] についても考慮している。

本論文では、学習レベル別フィードバックの例として電子教材のページ滞在時間やページ遷移の様子を提示する。この時、対象学生との比較先グループを変更することでフィードバック内容に差異が生じることを確認する。これより学習レベルに適したフィードバックを試みる。

3. 学習レベルに適したフィードバックシステム

本研究では、電子教材システム BookRoll で収集された学生の学習ログデータをもとに、学生個人の学習レベルに適した成績向上のためのフィードバックシステムを開発する。システム全体図を図 1 に示す。講義が終わるごとに学習ログデータの分析と成績予測、予測成績に基づくクラスタリングを行うことにより、提示するフィードバックが更新されていく。学生の成績向上には学習に対するモチベーションの維持が重要であり、モチベーションが高ければ最終成績が向上する傾向にある [14]。フィードバックが講義ごとに更新されることにより学習の目標が明確になり、学生のモチベーションが維持されると考えられる。また、フィードバックする際、対象学生の学習ログデータの比較先として前年度の同じ講義における一つ上位の成績を取めた学生の学習ログデータ群を設定している。これは習熟度

別指導の考え [15] に基づくものであり、学習レベルに適したフィードバックをすることで学生の効率的な成績向上を促すと期待できる。3.1 では提案手法で用いる対象学生の学習ログデータについて述べ、3.2 では成績予測について述べる。3.3 では対象学生より一つ上位の成績であるグループを推定するためのクラスタリングについて述べる。最後に、3.4 では学習レベルに適した成績向上のためのフィードバック方法について述べる。

3.1 対象学生の学習ログデータ

現在、九州大学ではオンライン学習支援システム M2B で教員・学生による電子教材の使用、学習管理システムによる出欠管理や授業内外での課題の実施などにより学習ログデータの収集・分析・改善が進められている。図 1(i) において収集するデータとして、M2B の一環である BookRoll の学習ログデータに加え、学習管理システムで管理されている講義内課題の点数も対象としている。対象の講義は毎回講義内課題が実施される。また、BookRoll では講義内の学習ログデータだけでなく、講義時間外の学習ログデータも記録される。これにより学生の予習復習状況を把握することができる。

3.2 対象学生の成績予測

クラスタリングの際に学生の予測成績が必要なため、図 1(ii) では学習ログデータを入力として講義日程の途中において学生の最終成績を予測する。学習ログデータは、終了した講義日までのデータを用いる。このとき、前年度に実施された同じ講義を受講した学生の学習ログデータと実際の最終成績を用いて成績予測モデルを事前に構築しておく。過去の同じ講義を対象にあらかじめサポートベクター回帰 (SVR) [16] を用いたモデルを構築しておくことで、講義日程の途中でも学生の最終成績を予測することができる。

3.3 予測成績に基づく学習レベル推定

学習レベルに適したフィードバックをするために、対象学生より一つ上位の成績であるグループを推定する必要がある。そのため、図 1(iii) では予測成績に基づいて学生をいくつかのグループにクラスタリングする。ここでは、前年度に実施された同じ講義を受講した学生の最終成績を用いてクラスタリングモデルを事前に構築しておく。このクラスタリングの結果により、対象学生の学習レベルがどのグループに属するかを推定できる。

3.4 学習レベルに適した成績向上のためのフィードバック

図 1(iv) では、クラスタリングの結果より推定された一つ上位の成績を取めた学生のグループの学習ログデータ群と、対象学生の学習ログデータとを比較することで、学習レベルに適したフィードバックをする。学習ログデータの

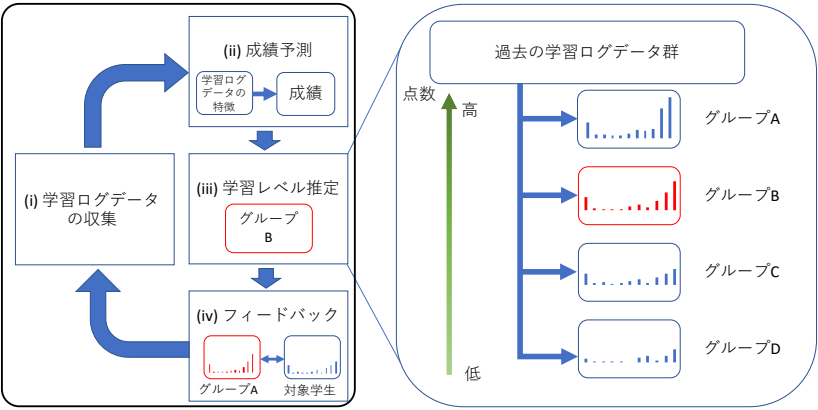


図 1 システム全体図




図 2 学習ログデータの比較のイメージ

比較のイメージを図 2 に示す。習熟度別指導の考え [15] に基づき、学習レベルに適したフィードバックをすることで学生の効率的な成績向上を図ることができると考えられる。フィードバックの内容としては、比較先のグループが重視している電子教材のページや講義内のページ遷移の様子などが挙げられる。分析データを可視化したグラフベースのフィードバックなども組み合わせることで、直感的にフィードバックされている部分がわかるように提示する。

4. 過去の学生を対象としたフィードバック実験

本実験では、対象学生との比較先のグループを一つ上位の成績グループに設定する重要性を示す。フィードバック対象は前年度の講義を受講した学生とした。フィードバックした内容は各ページの滞在時間とページ遷移を可視化したものである。また、あらかじめ構築しておく必要がある成績予測とクラスタリングのモデルの構築も行った。実験対象とした講義とその実施回数、学生の人数を表 1 に示す。対象講義である回路理論 II は専門科目であり、出席中の講義に対しての理解度が前後の回の講義に依存している。したがって学習レベルに適したフィードバックを実施することが効率的な成績向上に繋がると考えられる。4.1 では本

表 1 実験対象		
講義	講義回数	人数
回路理論 II	13	76

実験で用いた学習ログデータについて述べる。4.2 ではクラスタリングおよび成績予測モデルにより、出力された結果について述べる。4.3 ではフィードバック例とその考察について述べる。

4.1 使用した学習ログデータ

BookRoll から収集できる学習ログデータには複数のフィールドが存在する。本実験で使用したフィールドを表 2 に示す。user_id はハッシュ化により、学習ログデータの収集および分析の際に教員および学生を特定できないようにプライバシー保護がなされている。operation_name には発生したイベントの種類が記録されている。そのうち本実験で収集したイベントを表 3 に示す。レコメンデーションとは電子教材のページに表示されている学習に役立つ Web サイトのリンクである。また、GETIT ボタン／NOTGETIT ボタンとは該当ページを理解した／理解できなかったときに使用するものである。本実験ではこれらの学習ログデータに加え、学習管理システムから収集できる

表 2 使用したフィールド	
フィールド	概要
user_id	教員や学生に割り当てられたユーザ ID
event_time	イベントが発生した時刻
page_no	イベントが発生したページ番号
operation_name	イベントの種類

表 3 イベントの種類	
イベント	概要
OPEN	電子教材を開く
CLOSE	開いていた電子教材を閉じる
NEXT	次ページへ移動
PREV	前ページへ移動
PAGE_JUMP	指定したページへ移動
BOOKMARK	ページをブックマークに追加
MARKER	ページにマーカーを追加
MEMO	ページにメモを追加
RECOMMENDATION	レコメンデーションをクリック
GETIT	GETIT ボタンを押下
NOTGETIT	NOTGETIT ボタンを押下

講義内課題の点数 (score) を使用する。課題は毎講義実施された。

4.2 クラスタリングおよび成績予測モデル構築

4.2.1 クラスタリングモデル構築

クラスタリングモデル構築は、実際の最終成績をもとに k-means を用いて行った。クラスを 4 つに設定してクラスタリングを実行した結果を表 4 に示す。Group A が一番成績がよかったグループであり、B, C, D となるにつれ成績が落ちていく。このクラスタリング結果をもとに対象学生より一つ上位の成績のグループが決定される。また、この結果から各グループに所属するための閾値が決定される。

4.2.2 成績予測モデル構築

はじめに、成績予測モデルを構築するために入力データとなる学習ログデータ特徴量の作成を行った。本実験では、学習ログデータ特徴量として score を採用した。score は講義ごとにテストの難易度が異なるため、標準化を行った。標準化は式 (1) で表される。

$$y_i = \frac{x_i - \mu}{\sigma} \quad (1)$$

i をユーザ ID とすると、 y_i は標準化された学習ログデータ特徴量、 x_i は標準化前の学習ログデータ特徴量である。また、 μ, σ はそれぞれ x_i の平均、分散である。学習ログデータ特徴量は講義 13 回分の平均値を用いた。

最後に、SVR を用いて成績予測モデルを構築した。まず SVR を用いて、入力データのうち、1 人分をバリデーションデータとし、残りの 75 人分で学習することを 76 回繰り返す交差検証を行った。さらに、この交差検証の際に予測される点数を入力データとして、各グループの閾値により学生の所属グループを推定した。教師データをクラスタリングの結果のグループとした。所属グループ推定の評価は表 5 に示す混同行列で行った。表 5 の行と列は成績順 (A,B,C,D) となっている。成績が下位の学生は実際の成績よりも良い成績で予測される傾向にあった。しかし、対象学生よりも成績が低いグループと比較したフィードバックは提示されないため、誤差の影響は小さいと考えられる。

表 4 クラスタリング結果

グループ名	人数
Group A	31
Group B	25
Group C	12
Group D	8

表 5 混同行列

予測値 \ 真値	Group A	Group B	Group C	Group D
Group A	12	17	2	0
Group B	3	18	4	0
Group C	2	6	4	0
Group D	0	7	1	0




図 3 最初のイベントの種類によって異なる各ページの滞在時間の計算方法

4.3 フィードバックの比較

提示したフィードバックは電子教材の各ページの滞在時間とページ遷移の様子である。これらのフィードバックは一つの講義を対象とする。両方のフィードバックで比較先のグループを変更することでフィードバック内容に差異が生じることを確認する。

4.3.1 各ページの滞在時間

まず、フィードバックをするために講義に出席した学生ごとの講義内における電子教材の各ページの滞在時間を集計した。講義時間内に学習ログデータが存在する学生を出席として扱った。各ページの滞在時間の集計の対象となるイベントは電子教材のページ遷移に関わる NEXT, PREV, PAGE_JUMP とした。滞在時間の計算方法は図 3 のとおりである。ここで、この講義の開始時刻は 10:30 である。OPEN が最初の発生イベントの場合 (図 3 左) は OPEN の次に発生したページ遷移に関わるイベントの発生時刻から OPEN が発生した時刻を引き、それをページ遷移に関わるイベントが発生したページの滞在時間として計算した。ページ遷移に関わるイベントが最初に発生した場合 (図 3 右) は、講義開始時刻とページ遷移に関わるイベントが最初に発生した時刻との差を計算することで、ページ遷移に関わるイベントが最初に発生したページの滞在時間を求めた。その後の各ページの滞在時間の計算方法は共通で、ページ遷移に関わるイベントが発生するたびにページの滞在時間を計算した。また、継続ページ滞在時間の上限は 5 分と設定した。5 分を超えて同じページに滞在している場合は学習をしていないと判断した。

そして、クラスタリングの結果から見出されたグループと講義を受講した学生全員、最終成績が 100 点であった成績上位 8 名のグループごとの 3 種類のグループについて各ページの滞在時間の平均値を求めた。

本実験では、第 5 回目の講義を対象にフィードバックを行った。対象学生との比較グループを講義を受講した学生全員とした場合を図 4 に、最終成績が 100 点であった成績上位 8 名とした場合を図 5 に、対象学生より一つ上位の成績を収めたグループとした場合を図 6 に示す。図では対象学生は青色、比較先のグループは赤色で示した。横軸はページ番号、縦軸は滞在時間である。

比較先のグループによらず 15 ページと 21 ページにおいて対象学生との重視したページの違いが生じた。しかし、




図 4 対象学生（青色）と講義を受講した学生全員（赤色）との各ページの滞在時間の比較




図 5 対象学生（青色）と最終成績が 100 点であった成績上位 8 名（赤色）との各ページの滞在時間の比較




図 6 対象学生（青色）と対象学生より一つ上位の成績を取めたグループ（赤色）との各ページの滞在時間の比較

重視の度合いが異なっており、最終成績が 100 点であった成績上位 8 名と比較したときは 15 ページを、対象学生より一つ上位の成績を取めたグループと比較したときは 21 ページをより重視している傾向があることが確認できた。また、6 から 9 ページにおいて最終成績が 100 点であった成績上位 8 名のみがほぼこれらのページを重視しておら

ず、他のグループとは異なる傾向が見られた。

4.3.2 ページ遷移の様子

次に、ページ遷移の様子をフィードバックするために学生ごとに 1 分ごとのページ滞在判定を行った。指定した時刻内にページに滞在していれば 1、していなければ 0 と判定する。各ページについて時刻ごとの滞在判定を行うことでページ遷移の様子を集計した。

対象学生の比較先のグループは 3 種類設定した。クラスタリングの結果から見出されたグループと講義を受講した学生全員、成績上位 10 人のグループごとに、各ページについての講義開始時刻から 1 分ごとの滞在判定を足した。これにより、グループごとのある時刻における各ページの滞在人数が判明する。フィードバックはヒートマップを用いることにより、ページ遷移の様子が視覚的に理解できるようにした。

はじめに、Group C に所属する対象学生のページ遷移の様子を図 7 に示す。この対象学生は各ページの滞在時間のフィードバック実験と同じ学生である。次に、比較先のグループを講義を受講した学生全員にした場合を図 8 に、最終成績が 100 点であった成績上位 8 名にした場合を図 9 に、対象学生より一つ上位の成績を取めたグループにした場合を図 10 に示す。横軸は時刻、縦軸はページ番号である。グラフ右側のカラーバーは各ページにおける滞在人数を表しており、カラーバーの上側にある色になるほど人数が多く、下側の色になるほど人数が少なくなる。

比較先のグループによらず 11:34 から 11:42 において対象学生との間に大きな遷移の違いが見受けられた。しかし、対象学生より一つ上位の成績を取めたグループは他のグループと比べて 11:34 から 11:38 においてより多くのページ間を遷移している傾向が見られた。

4.3.3 比較先の変更によるフィードバック内容の差異

以上の実験から、対象学生との比較先を変更することによりフィードバック内容に差異が生じることが確認できた。このことから学習レベルに適したフィードバックが実施された可能性がある。フィードバック内容にもとづいてグラフとテキストの両方をダッシュボードに表示させるとより効果の高いフィードバックになると期待できる。改善点として、各ページの滞在時間のフィードバックについては、比較先のグループが重視したあるいはしなかったページ番号のみをフィードバックした点である。マウスカーソルをページ番号に合わせると該当する電子教材のスライドを表示するなどの追加機能を検討すべきである。ページ遷移の様子のフィードバックについては、直感的に他のグループとの遷移の違いが理解できるフィードバックの提示方法を考える必要がある。

5. 結論

本論文では、学生個人の学習レベルに適した、成績向上

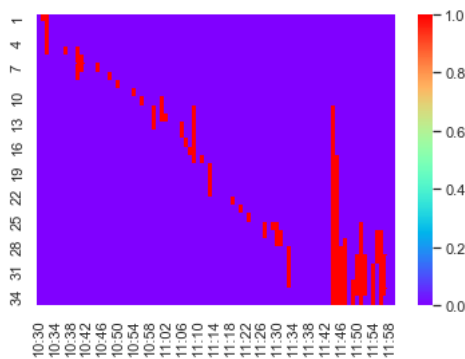


図 7 対象学生のページ遷移の様子




図 8 講義を受講した学生全員のページ遷移の様子




図 9 最終成績が 100 点であった成績上位 8 名のページ遷移の様子

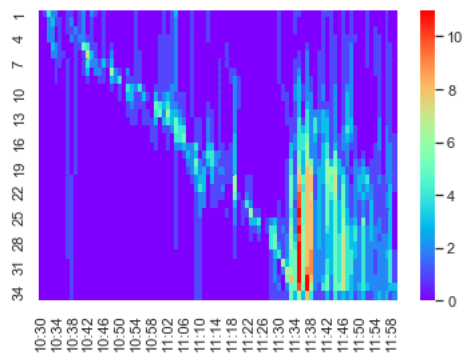


図 10 対象学生より一つ上位の成績を取めたグループのページ遷移の様子

のためのフィードバックを行う手法を提案した。実験では、過去の学生を対象として対象学生との比較先のグループを変更することでフィードバック内容に差異が生じるを示した。今後の課題として、実際に講義日程中に学生にフィードバックすることで主観的に本システムの評価を行うことが考えられる。また、成績予測の精度の向上や別の視点からのフィードバック提示などにより、より効果的なフィードバックを提示できることが期待できる。

謝辞 本研究は、JST AIP 加速課題 JPMJCR19U1, 科研費基盤研究 (A) JP18H04125 の支援を受けた。

参考文献

- [1] Ferguson, R.: Learning analytics: drivers, developments and challenges, *International Journal of Technology Enhanced Learning*, Vol. 4, No. 5/6, pp. 304–317 (2012).
- [2] Morsy, S. and Karypis, G.: Sparse Neural Attentive Knowledge-based Models for Grade Prediction, *CoRR*, Vol. abs/1904.11858 (online), available from <http://arxiv.org/abs/1904.11858> (2019).
- [3] Matcha, W., Gašević, D., Uzir, N. A., Jovanović, J. and Pardo, A.: Analytics of Learning Strategies: Associations with Academic Performance and Feedback, *Proceedings of the 9th International Conference on Learning Analytics & Knowledge, LAK19*, New York, NY, USA, ACM, pp. 461–470 (online), DOI: 10.1145/3303772.3303787 (2019).
- [4] Crossley, S., Paquette, L., Dascalu, M., McNamara, D. S. and Baker, R. S.: Combining Click-stream Data with NLP Tools to Better Understand MOOC Completion, *Proceedings of the Sixth International Conference on Learning Analytics & Knowledge, LAK16*, New York, NY, USA, ACM, pp. 6–14 (online), DOI: 10.1145/2883851.2883931 (2016).
- [5] Bodily, R. and Verbert, K.: Review of Research on Student-Facing Learning Analytics Dashboards and Educational Recommender Systems, *IEEE Transactions on Learning Technologies*, Vol. 10, No. 4, pp. 405–418 (online), DOI: 10.1109/TLT.2017.2740172 (2017).
- [6] Shimada, A. and Konomi, S.: A lecture supporting system based on real-time learning analytics, *14th International Conference on Cognition and Exploratory Learning in the Digital Age, CELDA 2017* (Spector, J., Ifenthaler, D., Ifenthaler, D., Sampson, D., Isaias, P. and Rodrigues, L., eds.), 14th International Conference on Cognition and Exploratory Learning in the Digital Age, CELDA 2017, IADIS Press, pp. 197–204 (2017).
- [7] 大西淑雅, 山口真之介, 近藤秀樹, 西野和典: ネットワークログを用いた学習活動の把握の提案, 技術報告 1, 九州工業大学学習教育センター, 九州工業大学教養教育院 (2019).
- [8] Yin, C. and Hwang, G.-J.: Roles and strategies of learning analytics in the e-publication era, *Knowledge Management and E-Learning*, Vol. 10, pp. 455–468 (2018).
- [9] Park, J., Denaro, K., Rodriguez, F., Smyth, P. and Warschauer, M.: Detecting Changes in Student Behavior from Clickstream Data, *Proceedings of the Seventh International Learning Analytics & Knowledge Conference, LAK17*, New York, NY, USA, ACM, pp. 21–30 (online), DOI: 10.1145/3027385.3027430 (2017).
- [10] Hu, Q. and Rangwala, H.: Reliable Deep Grade Pre-

- diction with Uncertainty Estimation, *Proceedings of the 9th International Conference on Learning Analytics & Knowledge*, LAK19, New York, NY, USA, Association for Computing Machinery, p. 76–85 (online), DOI: 10.1145/3303772.3303802 (2019).
- [11] Aljohani, N. R., Daud, A., Abbasi, R. A., Alowibdi, J. S., Basher, M. and Aslam, M. A.: An integrated framework for course adapted student learning analytics dashboard, *Computers in Human Behavior*, Vol. 92, pp. 679 – 690 (online), DOI: <https://doi.org/10.1016/j.chb.2018.03.035> (2019).
 - [12] Diana, N., Eagle, M., Stamper, J., Grover, S., Bienkowski, M. and Basu, S.: An Instructor Dashboard for Real-Time Analytics in Interactive Programming Assignments, *Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, LAK17, New York, NY, USA, Association for Computing Machinery, p. 272–279 (online), DOI: 10.1145/3027385.3027441 (2017).
 - [13] Hwang, G.-J., Chu, H.-C. and Yin, C.: Objectives, methodologies and research issues of learning analytics, *Interactive Learning Environments*, Vol. 25, No. 2, pp. 143–146 (online), DOI: 10.1080/10494820.2017.1287338 (2017).
 - [14] 吉澤隆志, 松永秀俊, 藤沢しげ子: 学習意欲が定期試験成績向上に及ぼす効果について, 理学療法科学, Vol. 24, No. 3, pp. 463–466 (オンライン), DOI: 10.1589/rika.24.463 (2009).
 - [15] 文部科学省: 習熟度別・少人数指導について, 文部科学省(オンライン), 入手先 https://www.mext.go.jp/a_menu/shotou/gakuryoku-chousa/zenkoku/08020513/001/003.htm (参照 2020-02-10).
 - [16] Smola, A. J. and Schölkopf, B.: A tutorial on support vector regression (2004).