

Web 調べ学習における適応的な目次構造作成支援の評価

森下 夏暉^{*1}, 柏原 昭博^{*1}, 太田 光一^{*2}, 長谷川 忍^{*2}

^{*1} 電気通信大学 ^{*2} 北陸先端科学技術大学院大学

Evaluating Adaptive Support for TOC Creation in Web-based Investigative Learning

Natsuki Morishita^{*1}, Akihiro Kashihara^{*1}, Koichi Ota^{*2}, Shinobu Hasegawa^{*2}

^{*1} The University of Electro-Communications

^{*2} Japan Advanced Institute of Science and Technology

Web 調べ学習は、課題に対してその関連項目も含めて網羅的に学習し、体系的な知識を構築することが目的である。筆者らは、これまで知識の体系化を促すために初期課題をテーマとするレポートの目次構造を作成するプロセスをモデル化し、支援ツールを作成した。一方、作成された目次構造には構造的に不十分な場合があることも分かった。そこで、本研究では不十分な点への気づきを促すために目次構造作成過程で3つの適応的な支援を提案し、支援ツールの機能として実装した。本稿では、その効果の検証ために実施したケーススタディについても報告する。実験の結果、2つの支援において有意に構造的に不十分な点が減少し、もう一つの支援でも学習者が有用な支援であったと感じたことが分かった。

キーワード: Web, 調べ学習, 主体的学習, 目次作成, 体系化, 適応的支援

1. はじめに

Web 調べ学習の目的は、与えられた課題(初期課題)について、関連する項目を網羅的、体系的に学ぶことにより、主体的に初期課題に対するより広い・深い知識を構築することである。一方、Web 空間には膨大かつ多様な情報リソースが存在するが、学習者が学ぶべき項目とその項目を学んだ順番を表す学習シナリオが与えられていない。そのため、課題に対して学んだ関連項目の中から、さらに学ぶべき項目をその課題の部分課題として展開(課題展開)することにより学習シナリオを学習者自身で作成する必要がある。また、学習者は Web 調べ学習を行うために、知識の構築と学習シナリオの作成を同時に行う必要がある。そのため、学習にかかる認知的負荷が高い⁽¹⁾。

このような問題に対して先行研究では、Web 調べ学習のプロセスモデルをデザインした⁽²⁾。また、Web 調べ学習モデル通りに学習シナリオの作成を可能とする支援ツールである interactive Learning Scenario

Builder (iLSB)⁽²⁾を開発した。加えて、ケーススタディより iLSB が学習者の課題展開を促すことを確かめた。

一方、学んだ知識をより深く理解するためには、その知識を他者に分かりやすく伝えることが有効である。それには学んだ知識を系列化して表現し、論理的に整理する必要がある。そこで先行研究⁽³⁾では、Web 調べ学習モデルを拡張し、Web 調べ学習後に学習シナリオをレポートの目次構造にまとめるプロセスを追加して、目次構造作成モデルをデザインした。また、iLSB に実装した。ケーススタディの結果、構造的に整理された目次が作られることを確認した。

同時に、作成された目次構造の中には、構造的に不十分な場合が見られた。これは、iLSB による支援が目次構造作成の場を提供するだけにとどまり、学習者が作成しようとしている目次構造に対する適応的な支援を行っていないことが要因の一つと考えられる。そこで本稿では、学習者が作成している目次構造の不十分な点への気づきを促す適応的支援を提案する。そして、その支援を iLSB の機能として提供する。

2. Web 調べ学習

本章ではまず、Web 調べ学習とその特徴について述べ、先行研究⁽²⁾⁽³⁾で提案した Web 調べ学習モデルと、Web 調べ学習モデルに沿って学習者に対して足場を提供する認知ツール interactive Learning Scenario Builder(iLSB)について述べる。加えて、先行研究で提案した属性提示手法について述べ、現在の問題点と本稿の目的について述べる。

2.1 Web 調べ学習とは

Web 調べ学習ではまず初期課題が与えられる。Web 調べ学習とは、単に初期課題を表す課題(初期課題)を検索エンジンに入力し、その意味を検索するというのではない。Web 調べ学習とは、Web 空間を探索しながら、課題に対する関連項目も含めて網羅的に学習し、初期課題に関する体系的な知識を構築する学習である。

一方で、Web 調べ学習では学習すべき項目とその順番を表す学習シナリオが提供されていない⁽⁴⁾。そのため、学習者は初期課題に関する知識を学びながら、学習シナリオを自分自身で構築しなければならず、学習にかかる認知的負荷は高くなる。また、学習が進むにつれて自らの学習プロセスが不明瞭になりやすく、次に展開すべき部分課題の選択にも行き詰まりが生じやすくなる⁽¹⁾。そのため初期課題に対して網羅的かつ体系的な知識を構築することは容易ではない。

2.2 Web 調べ学習モデル

Web 調べ学習は認知的負荷が高いという問題に対して、先行研究⁽²⁾では Web 調べ学習プロセスをモデル化した。また、先行研究⁽³⁾では Web 調べ学習モデルを拡張し、学習者が Web 調べ学習するプロセスである「知識構築プロセス」と学習者が調べた内容をレポートにまとめるプロセスである「知識系列化プロセス」の2つのプロセスに分けた。



図 1 Web 調べ学習モデル

2.2.1 知識構築プロセス

知識構築プロセスでは、学習者が Web 調べ学習するプロセスを図 2 のように「Web リソース探索フェイズ」、「Navigational Learning フェイズ」、「課題展開フェイズ」の3つのフェイズに分けた。



図 2 知識構築プロセス

Web リソース探索フェイズでは、検索エンジンを用いて、学習に用いる Web リソースを学習リソース群として収集する。Navigational Learning フェイズでは、学習リソース群をナビゲーションしながら学習課題について学ぶ。そして、学んだ項目をキーワードとして抽出し、関係付けをすることで学習課題に関する知識構築を行う。また、課題展開フェイズでは、学習課題についてより詳細に学ぶ必要がある関連項目を部分課題として展開する。

学習者は各部分課題に対して、新たに部分課題が展開されなくなるまで3フェイズを再帰的に繰り返し、最終的に初期課題を根ノードとし、展開した課題を子ノードとする木構造の形で学習シナリオが作成される。

2.2.2 知識系列化プロセス

知識系列化プロセスは、学習者が Web 調べ学習で学んだ内容をレポートにまとめるプロセスを表し、図 3 のように「categorizing フェイズ」、「hierarchization フェイズ」および「sorting フェイズ」の3つのフェイズによって構成される。特に「categorizing フェイズ」は「chapter making」と「clustering」に分けられる。筆者らは、これらのフェイズから構成される知識系列化プロセスを、目次構造作成モデルとして提案した。

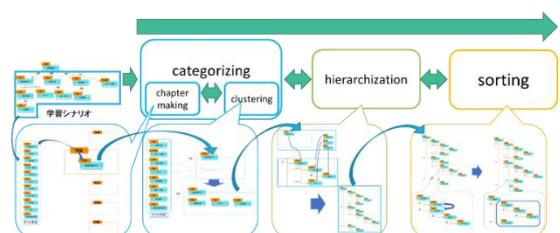


図 3 目次構造作成モデル

まず categorizing フェイズでは学習シナリオに含まれる課題を用いて、レポートにおける章と各章に対する節を構成する。このフェイズは「chapter making」と「clustering」の2つのタスクを含む。chapter making では、学習シナリオに含まれる課題からレポートの章を作成する。clustering では作成した章を構成する節を作成する。

次に、hierarchization フェイズでは、categorizing フェイズで作成した章と節を階層構造として表現する。

そして、sorting フェイズでは、hierarchization フェイズで作成した章や節の階層構造において、レポートの目次として章や節の順序が妥当でない場合に、章や節の順序を変更する。

2.3 interactive Learning Scenario Builder (iLSB)

iLSB は Web ブラウザ Firefox⁽⁶⁾のアドオンとして開発された。iLSB は以下の機能を実装している。

- ・検索エンジン機能

学習リソースを選択、収集するために、Web リソースを探索する機能

- ・キーワードリポジトリ機能

収集した学習リソース群から、学習項目を端的に表すキーワードを抽出し、キーワード間の関係付けを行うことで知識構築を行う機能

- ・課題マップ機能

キーワードリポジトリ機能で作成した知識構造を振り返り、さらに学ぶべきキーワードを部分課題として課題展開し、学習課題と部分課題の関係付けを行うことで学習シナリオを作成する機能

- ・目次構造作成機能

課題マップ機能で作成した学習シナリオを用いて、学んだ内容を整理するための目次構造を作成する機能

2.4 属性提示手法

先行研究⁽⁶⁾では、Web 調べ学習において学習者の興味・関心によって展開される課題が特定のものに絞られてしまうという問題点が指摘されていた。そのため、学習者が新たな課題展開の観点を獲得する機会として、属性提示手法が提案された。属性提示手法では、学習課題に対して、その課題の上位概念を表す課題タイプを学習者に付与させ、加えて課題タイプごとに展開可

能な部分課題との関係を表した属性を付与させた。また、課題タイプは36種類あり、属性は12種類定義され、それぞれの課題タイプと展開可能な属性との対応の例は表1のようになる。

表1 課題タイプと属性の対応

	属性											
	起源	原因	背景	原理	経歴	構成要素	構造	クラス	インスタンス	特徴	影響	対策
事例	○	○	○	○		○		○	○	○	○	
現象		○	○	○		○		○	○		○	○

2.5 問題点

先行研究⁽⁶⁾ではケーススタディの結果、目次構造作成モデルに沿った学習の有効性が確認された。一方で、「章の属性が偏っている」、「章の内容となる課題の数に偏りがある」、「章や節、親課題と関係の薄い課題を目次構造に用いる」といった構造的に不十分な目次構造を学習者が作成する場合があった。

目次構造の「章の属性が偏っている」場合は網羅的で広い学習ができているとは言えない。また、目次構造の「章の内容が偏っている」場合は、網羅的で深い学習ができているとは言えない。さらに、目次構造の「章や節、親課題と関係の薄い課題を目次構造に用いる」場合は、初期課題に対して体系的な学習ができているとは言えない。これらの問題が発生する原因は目次構造作成の過程において適応的な支援ができていないことが一因と考えられる。

2.6 本稿の目的

前節で述べた問題点に対して、本稿では目次構造作成の過程で3つの適応的な支援を行う。

1つ目は「章の属性が偏っている」に対して、「章立てに資する属性の提示」を行う。2つ目は「章の内容が偏っている」に対して、「各章内の課題数のバランスの可視化」を行う。3つ目は「章や節、親課題と関係の薄い課題を目次構造に用いる」に対して、「章とその節の意味的距離の計算」とともに「章の推薦」を行う。これらの支援によって、学習者が目次構造を作成する際に、構造的に不十分な点に気付きを与え、より良い目次構造の作成を支援することを目的とする。

3. 適応的な目次構造作成支援

本章では、学習者が学習シナリオから目次構造を作

成する際の支援の枠組みについて述べる。また、3つの適応的な支援について述べる。

3.1 支援の枠組み

図4に支援の枠組みを示す。まず、学習者はiLSBを使ってWeb調べ学習を行い、学習シナリオを作成する。その後、目次構造作成モデルに沿って学習者は初期課題に関するレポートの目次を作成する。このとき、chapter makingでは「章立てに資する属性を提示」、clusteringでは「各章内の課題数のバランスを可視化」、hierarchizationでは「章とその節の意味的距離の計算」と「章の推薦」の3つの適応的な支援を行う。学習者は4つのプロセスを行き来しながら、学習シナリオの系列化を行う。また、学習者が系列化の途中で学んだ項目の不足を感じた場合、Web調べ学習モデルに沿って再度iLSBを用いた調べ学習を行う。このように各操作に対して、適応的な支援を行うことによって、学習者の構造的に不十分な目次構造への気づきを促す。

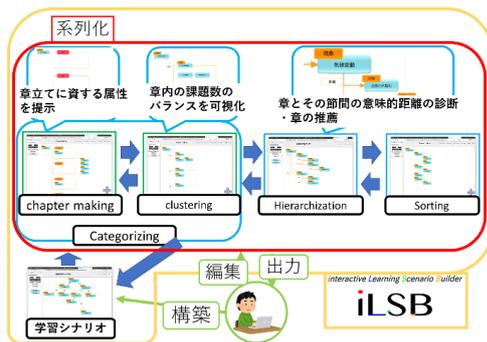


図4 支援の枠組み

3.2 chapter making 支援

「章立てに資する属性を提示」する支援は、1つ目のタスクであるchapter makingで行われる。この支援では図5の赤い枠で表すように、表1の対応表で学習者が設定した初期課題の課題タイプと対応がある属性のみを章立てに資する属性として提示する。加えて、表2のように筆者がその課題タイプの初期課題のレポートを書く際の必要性という観点で属性を2群に分け、必要性の高い群を赤色、必要性の低い群を橙色で学習者に提示する。表2ではレポートにおいて必要性の高い属性を◎、低い属性を○で表す。また、図5の青い枠のように学習シナリオの初期課題から課題展開された課題を緑色、それ以外の課題を水色で提示する。

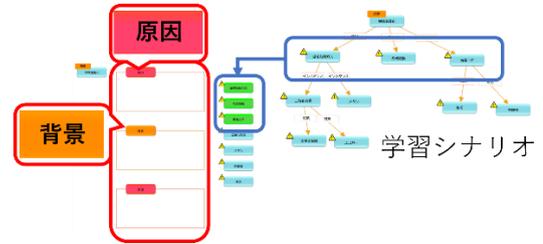


図5 章立てに資する属性を提示のUI

表2 必要性で属性を2群に分けた対応表

	属性											
	起源	原因	背景	原理	経歴	構成要素	構造	クラス	インスタンス	特徴	影響	対策
事柄	○	◎	○	○		○		◎	○	◎	◎	
現象		◎	○	◎		○		◎	○		◎	

3.3 clustering 支援

「各章内の課題数のバランスを可視化」支援は2つ目のタスクのclusteringで行われる。この支援では、図6で示すように学習者が各章に振り分けた課題数のバランスを各章の枠の色で可視化する。章の枠色の種類は赤、橙、緑の3種類である。振り分けられた課題数が0個、1個、全体の8割以上の場合には赤色に。振り分けられた課題数が2個、全体の7割以上の場合には橙色に、それ以外の場合には緑色になる。緑色、橙色、赤色の順でバランスが良い章である。

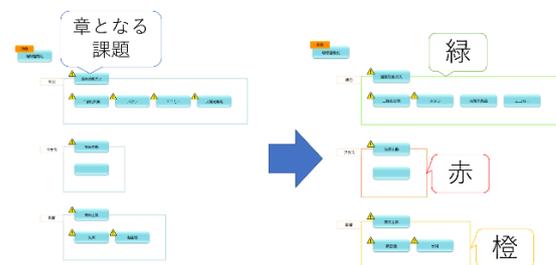


図6 各章内の課題数のバランスを可視化のUI

3.4 Hierarchization 支援

「章とその節の意味的距離の診断」と「章の推薦」支援は3つ目のタスクのhierarchizationで実施する。

この支援では図7に示すように学習者が作成した章とその章に含まれる課題がどれくらい意味的に離れているかをLODを用いたResimとWord2Vecを用いて算出する。そして、課題間をつなぐリンクの長さを用いてその意味的距離のフィードバックを行う。そして課題間の意味的距離が遠い場合は、ほかの章の中で意味的距離がより近い課題を推薦する。

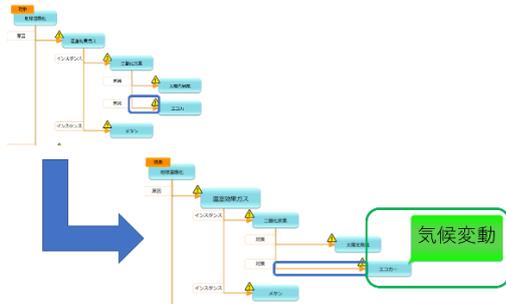


図7 章と節の意味的距离の計算と章の推薦のUI

3.4.1 Linked Open Data (LOD)

LODとはWeb上の関連データをリンク付けし、オープンデータとして公開している仕組みのことで、リンク付けしたデータの集合はネットワーク構造として表現できる⁽⁷⁾。本稿で用いるDBpedia Japanese⁽⁸⁾とは、日本語版WikipediaをリソースとするLODである。DBpedia Japaneseのデータは、図8のような主語、述語、目的語の3つの構造体で構成されるRDFと呼ばれる形式で表現される。このようなデータはSPARQLというクエリ言語を用いて取得することができる。SPARQLを用いると2つの課題間の距離や経路数、またそれぞれの課題の関連語句の取得ができる。



図8 RDFの構造

3.4.2 Resim

ResimはPiaoら⁽⁹⁾が提案した手法であり、DBpedia Japaneseを用いた単語間類似度の測定方法で類似度は0から1の間の数値で表現される。また、2つの数式LDSとPropertyの平均として求められる。LDSは2つのキーワード間の様々なリンクの繋がり具合からそのキーワード間の類似度を0から1で取得することができる。Propertyは2つのキーワードがそれぞれ持っているリンクの種類を比較することによって類似度を0から1取得することができる。

3.4.3 Word2Vec

Word2Vecは、Mikolovら⁽¹⁰⁾によって提唱されたニューラルネットワークを用いた単語の分散意味表現の計算手法及びそのオープンソース実装の名称である。テキスト中の各単語を周辺の単語から予測する擬似的な単語予測のタスクを設定し、このタスクを大量のテ

キストからニューラルネットワークで学習し、中間層における各単語の重みを抽出することによって、単語に対する概念ベクトルとして分散表現を獲得する。2つのキーワードの共起度を計測するためには、それら2つの概念ベクトルのコサイン類似度を求めることによって-1から1の値で得ることができる。本稿では、日本語版Wikipediaのテキストを学習させたWord2Vecの概念ベクトル辞書を用いる。

3.4.4 意味的距离の計算方法

Resimを用いた単語間類似度とWord2Vecを用いた単語間共起度を用いて、章とその節の意味的距离を「Short」、「Middle」、「Long」の3段階で取得する。意味的距离の3段階の分け方は、単語間類似度が0.15以上または単語間共起度が0.8以上であれば「Short」、単語間類似度が0.1以上または単語間共起度が0.7以上であれば「Middle」、それ以外であれば「Long」と定義する。推薦する章の決定も意味的距离を用いて判断する。意味的距离が「Middle」または「Long」であった節と学習者が作成した全ての章の意味的距离を測定し、「Short」であった章を学習者に推薦する。

4. ケーススタディ

4.1 目的・手順

本ケーススタディの目的は、提案した3つの適応的な支援が学習者の目次構造作成の際に目次の不十分な点への気づきを促すかを確認することであった。

被験者は理工系大学生・大学院生、計15名とし、実験群と統制群の2群に分けた。まず、それぞれの群の4人には初期課題として「火山」を、実験群の残り4人と統制群の残り3人には初期課題として「認知症」を与え、iLSBを用いてWeb調べ学習を行ってもらった。その後、実験群には3つの適応的な支援が実装されたiLSBを、統制群には適応的な支援が実装されていないiLSBを用いて目次構造を作成してもらった。目次作成終了後に、3つの適応的な支援に関する学習者の主観評価を調査するために事後アンケートを実施した。

4.2 評価方法

本ケーススタディは3つのデータを用いて評価を行った。1つ目は、学習者が作成した目次構造から得られるノードやリンクのデータである。2つ目は、学習

者が回答したアンケートのデータである。このアンケートは 5 件法で取得しており、1 が最も評価が良く、5 が最も評価が悪い。3 つ目は、学習者が学習シナリオ、目次構造で作成したリンクについて、初期課題を熟知した筆者（熟達者）の妥当性評価、意味的距離、診断による妥当性評価の 3 つの指標で評価したデータである。3 つはそれぞれ 1 から 3 の値で評価されており、熟達者の妥当性評価と診断による妥当性評価は 3 が最も評価が高く、意味的距離は 1 が最も評価が高い。熟達者の妥当性評価は筆者がリンクの親課題、属性、子課題をみて評価したものである。意味的距離はリンクの親課題と子課題の意味的距離を計測したものである。診断による妥当性評価は先行研究⁽¹¹⁾にて提案された課題展開の妥当性を診断する仕組みを用いる。

4.3 仮説

本ケーススタディでは、次の 3 つの仮説を立てた。

H1: 「章立てに資する属性を提示」する支援によって目次構造に使われている章の属性が増加する。

H2: 「各章内の課題数のバランスを可視化」する支援によって章内に振り分けられた課題数が増加し、課題数のばらつきが減る。

H3: 「章とその節の意味的距離の計算」と「章の推薦」支援によって、目次構造で使われているリンクの各評価が上昇する。

4.4 結果

まず、被験者が作成した章の数とその種類についての分析を行う。被験者全体と初期課題が「火山」であった被験者（以下被験者（火山））、初期課題が「認知症」であった被験者（以下被験者（認知症））の 3 通りで両側 t 検定を行なった。検定した内容は、学習シナリオの初期課題の部分課題から目次構造の章の課題への課題増加数（課題増加数）と学習シナリオの初期課題から部分課題へのリンクの属性から目次構造の章の属性への増加数（属性増加数）である。それぞれの課題増加数を図 9 に、属性増加数を図 10 に示す。

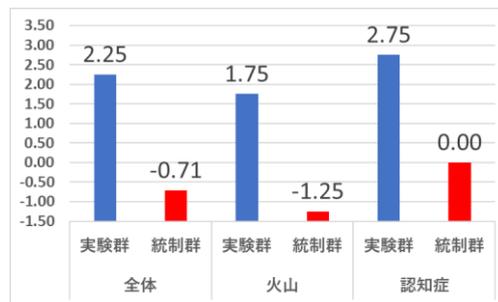


図 9 各初期課題での課題増加数

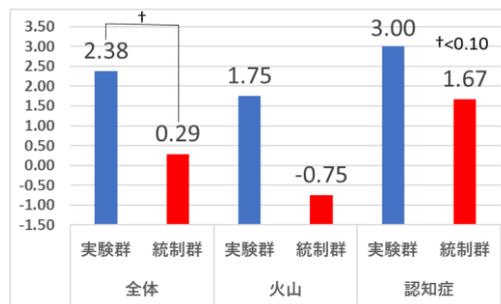


図 10 各初期課題での属性増加数

図 9 をみると、各初期課題においても全体においても課題増加数に有意差（全体： $t(8) = 1.51, p > .10$ 、火山： $t(6) = 1.39, p > .10$ 、認知症： $t(2) = 0.66, p > .10$ ）はなかったが実験群の方が大きく、また図 10 をみると全体においては属性増加数は実験群の方が有意（ $t(12) = 1.98, p < .10$ ）に大きい傾向があった。したがって H1 は成り立った。

次に章に振り分けられた課題数について分析する。被験者全体で章に振り分けられた課題数に対して両側 t 検定を行なった。各被験者の章に振り分けられた課題数の平均と標準偏差を表 3 示す。

表 3 各被験者の章に振り分けられた課題数

	被験者	Mean	SD	Mean	SD	Mean	SD	
実験群	火山	A	3.00	1.60	3.45	2.36	3.33	2.29
		B	4.50	1.50				
		C	5.67	4.11				
		D	2.17	0.69				
	認知症	E	4.86	2.85	3.23	2.24		
		F	2.80	2.23				
		G	2.50	1.26				
		H	2.63	1.32				
統制群	火山	I	2.00	1.12	3.04	1.81		
		J	4.00	1.91				
		K	4.00	1.58				
		L	2.83	1.77				
	認知症	M	1.75	0.97	3.47	2.66		
		N	4.60	3.67				
		O	4.83	1.77				

表 3 では、全体をみても、各初期課題をみても群間で平均、標準偏差の差は見られなかった。それに加えて両側 t 検定の結果においても群間に有意差（ $t(87) = 0.19, p > .10$ ）は見られなかった。したがって、

H2 は成り立たなかった。

次に被験者が作成したリンクの評価について分析する。被験者全体と初期課題ごとの3通りで、熟達者の妥当性評価、意味的距離、診断による妥当性評価について検定した。被験者が作成した学習シナリオと目次構造のリンクの熟達者の妥当性評価の差を図11に、被験者が作成した学習シナリオと目次構造のリンクの意味的距離の差を図12に、被験者が作成した学習シナリオと目次構造のリンクの診断による妥当性評価の差を図13に、目次構造の各評価を図14に示す。

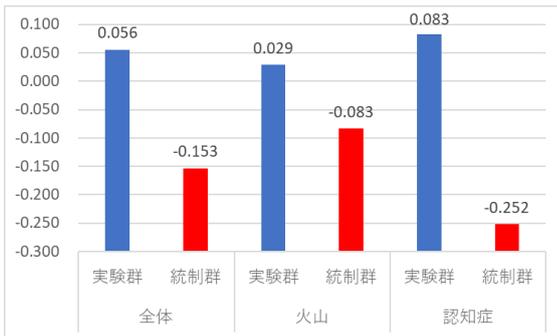


図11 リンクへの熟達者の妥当性評価の差



図12 リンクの意味的距離の差

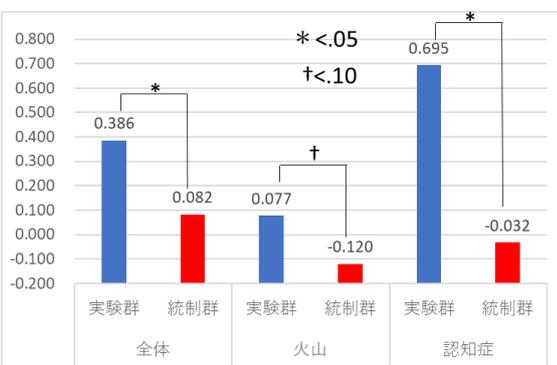


図13 リンクへの診断による妥当性評価の差

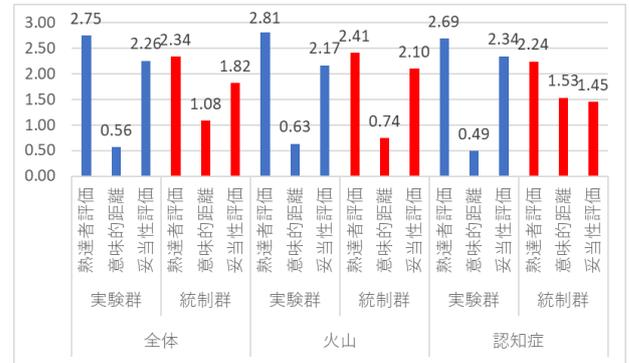


図14 目次構造のリンクの各評価

図11を見ると各初期課題とも有意差(全体: $t(13) = 1.29$, $p > .10$, 火山: $t(6) = 0.74$, $p > .10$, 認知症: $t(5) = 1.00$)はなかったが、実験群は学習シナリオから目次構造で評価の平均は上昇し、統制群は学習シナリオから目次構造では評価の平均が減少した。

図12を見ると被験者(認知症)では実験群の方が統制群も学習シナリオから目次構造で意味的距離の評価が有意 ($t(5) = -2.92$, $p < .05$) に上昇した。

図13を見ると全体と被験者(認知症)では学習シナリオから目次構造への診断による妥当性の評価は実験群の方が統制群よりも有意(全体: $t(13) = 2.83$, $p < .05$, 認知症: $t(5) = 3.22$, $p < .05$) に上昇した。また被験者(火山)では、学習シナリオから目次構造への診断による妥当性の評価は実験群の方が統制群よりも有意 ($t(6) = 2.03$, $p < .10$) に上昇する傾向にあった。これらの結果より、H3は成り立った。

最後に被験者に行ってもらったアンケートの分析を行う。両群に対して目次構造作成の主観的な評価を聞いた5つの質問に対して両側t検定を行なった。加えて実験群に行った適応的な支援への評価も示す。適応的な支援の評価を表4示す。

表4 適応的な支援への評価アンケート

質問	Mean	SD
(1)章立てに資する属性を提示することは有用だと感じましたか	1.88	0.78
(2)各章内の課題数のバランスを可視化することは有用だと感じましたか	1.75	0.66
(3)章とその節の意味的距離の計算と章の推薦することは有用だと感じましたか	1.50	0.71
(4)章とその節の意味的距離の計算は妥当だと感じましたか	1.00	0.00
(5)推薦された章は妥当だと感じましたか	1.71	0.70

表4を見ると、質問1, 2, 3から3つの適応的な支援は有用性の評価が高いことが分かった。加えて、質問4, 5より意味的距離の診断とそれによる章の推薦も妥当であると感じられていることが分かった。

4.5 考察

H1 は成り立ったことに加えて表 4 の質問 1 の結果より、1 つ目の適応的な支援「章立てに資する属性を提示」は目次構造作成の過程で学習者が自身の目次構造の章の偏りへの気づきを促したと考える。

H2 は成り立たなかったが、統制群よりも実験群の方が章の数が多い中で各章に振り分けられた課題数が同水準になっているといえる。したがって、このことと表 4 の質問 2 の結果より、2 つ目の適応的な支援「各章内の課題数のバランスを可視化」は目次構造作成の過程で学習者が自身の目次構造の章の内容が偏っていることへの気づきを促す効果はあったが、その効果は想定よりも小さかったと考える。

H3 が成り立ったことに加えて表 4 の質問 3, 4, 5 の結果より、意味的距離の計測と章の推薦は妥当であると考えられる。したがって 3 つ目の適応的な支援「章とその節の意味的距離の計算」と「章の推薦」は目次構造作成過程で学習者が自身の目次構造の中で章や節、親課題と関係の薄い課題への気づきを促したと考える。

5. おわりに

Web 調べ学習では、学んだ内容をレポートの目次にまとめることは知識を体系的に構築するために重要である。一方で作成された目次構造に構造的に不十分な点が含まれている場合がある。この問題に対して、本稿では目次構造作成の過程で行う 3 つの適応的な支援を提案した。そして、提案した 3 つの適応的な支援が目次構造の構造的に不十分な点への気づきを促すかを検証することを目的として、ケーススタディを行った。結果として、3 つの適応的な支援は目次構造の構造的に不十分な点への気づきを促す可能性が示唆された。

今後の課題としては、実験の結果より「章の内容となる課題の数に偏りがある」という問題に対してより気づきを促す適応的な支援を行うことがあげられる。また、4 つ目のタスクである **Sorting** への適応的な支援をすることや目次構造を生かした Web 調べ学習のレポート作成の支援があげられる。

謝辞

本研究の一部は、JSPS 科研費 JP18H01053 の助

成による。

参考文献

- (1) Zumbach, J., and Mohraz, M.. Cognitive. "load in hypermedia reading comprehension: Influence of text type and linearity." *Computers in Human Behavior*, 24(3) (2008): 875-887.
- (2) Kashihara, Akihiro, and Naoto Akiyama. "Learning Scenario Creation for Promoting Investigative Learning on the Web." *The Journal of Information and Systems in Education* 15.1 (2016): 62-72.
- (3) 森下夏暉 柏原昭博 太田光一 長谷川忍 :Web 調べ学習における知識整理を伴う学習シナリオ再構築支援 教育システム情報学会 第 45 回全国大会 (2020): 267-268.
- (4) Henze, Nicola, and Wolfgang Nejdl. "Adaptation in open corpus hypermedia." *International Journal of Artificial Intelligence in Education* 12.4(2001):325-350.
- (5) Mac, PC, Linux 向け新高速ブラウザ | Firefox
- (6) 木下恵太, 柏原昭博 : Web 調べ学習における課題展開のための属性提示手法の評価, 信学技報, ET2014-99(2015): 77-82.
- (7) Bizer, Christian, Tom Heath, and Tim Berners-Lee. "Linked data: The story so far." *Semantic services, interoperability and web applications: emerging concepts*. IGI Global (2011): 205-227.
- (8) DBpedia Japanese, Available: <http://ja.dbpedia.org/>
- (9) Guangyuan Piao, Safina showkat Ara, and John G. Breslin. "Computing the Semantic Similarity of Resources in DBpedia for Recommendation Purposes" *Joint International Semantic Technology Conference 2015: Semantic Technology(2015): 185-200.*
- (10) Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado, and Jeff Dean. "Distributed representations of words and phrases and their compositionality." *In Advances in Neural Information Processing Systems* 26(2013): 3111-3119.
- (11) Yoshiki Sato, Akihiro Kashihara, Shinobu Hasegawa, Koichi Ota, Ryo Takaoka. "Promoting Reflection on Question Decomposition in Web-based Investigative Learning" *Proceedings of the 27th International Conference on Computers in Education. (ICCE) (2019), vol. I : 75-80.*