

MOOC 受講生の科目選択支援のための科目内容解析

戴 憶菱[†] 浅野 泰仁[‡] 吉川 正俊[‡]

[†] 京都大学大学院情報学研究科 〒606-8501 京都市左京区吉田本町

E-mail: [†] daiyiling@db.soc.i.kyoto-u.ac.jp, [‡] {asano, yoshikawa}@i.kyoto-u.ac.jp

あらまし 近年、教育の公開化と情報化の進展を背景に、大規模オープンオンライン講座(Massive Open Online Course, 下記 MOOC)という教育サービスが生まれ、注目を集めている。これによって学習者は、身分、時間、空間や費用の制限なく多様かつ良質な教育資源にアクセスできるようになってきた。しかし、このような教育の自由化と個人化により、学習者は自ら適切な科目を選択することが困難になっている。本研究では、MOOC における学習者の科目選択を支援するため、ダイナミックな科目選択支援システムを提案する。また、システムの実現に必要な初期分析として、シラバスから科目の知識カバレッジを抽出する手法を提案する。実験では、ACM/IEEE-CS Computer Science Curricula 2013 (下記 CS 2013) の知識体系を参照コーパスとして、bag-of-words を用い、CS 2013 が提供したサンプル科目に対して解析分析を行った。また、結果について評価を行い、不足と展望に関する議論を加えた。

キーワード MOOC, 科目解析, シラバス, 知識カバレッジ, bag-of-words

1. はじめに

近年、情報通信技術の発展により、教育資源のオープン化が徐々に進んできた。専門的な知識を解説する文書から、オンラインテキストブック、オープンコースウェアのような指導者の工夫を相当に含める学習資源までが容易にアクセスできるようになってきた。その中、大規模公開オンライン講座(Massive Open Online Course, 下記 MOOC)の登場は教育の公開化と情報化の新局面を拓いている。MOOC は教育資源の公開化の推進の波で生まれ[1], 2012 年に「オンラインで公開された講義を受講し、修了要件を満たしたら認定をもらえる」という教育サービスの形で定着し、僅か数年間で世界中に広がってきた。

MOOC の主要な提供者 Edx で、2012 年秋から 2014 年夏まで一番人気があったコンピュータ科学分野の科目は全体で 60 万人以上が受講したという統計データが報告されている[2]。また、MOOC への注目が集まりつつある日本国内の調査から、1228 名の調査対象のうち、3%の MOOC 利用経験率に対し利用意向者率が 57%と高いことが分かる[3]。しかし、MOOC へのニーズが増えつつある一方、前述の Edx のコンピュータ科学分野の科目の受講者数に比べ際立つのは僅か 7%の認定(最後まで受講し、修了条件を満たし、認定をもらう)率である。MOOC は“Education should be accessible to everyone”という使命にまだほど遠いと言える。

実際に、MOOC の活用で正式な教育を代替するより、MOOC の受講で純粋な知識への好奇心を満足させたり、生涯や職業にプラスアルファ効果を目指したりす

るようなモチベーションが多い[4]。また、受講者の身分は作家、エンジニア、大学生、主婦など想像以上に多様であることが[4]の報告でうかがえる。このような MOOC 利用者が直面している困難は、自習という場面で使える時間が足りない、科目の内容は想像以上に自分の理解範囲を超えるなどが挙げられる[4]。すなわち、MOOC は、インターネットを経由することによる対面型指導の欠如などのバリアに加え、受講者の自発性への依存、多様な受講者への適応不能により、つまづきやすい学習環境となっている。

[5]が主張するとおり、大規模なオンライン科目をより広範な学習者に便宜を与えるにあたって、教育の個人化が重要である。教育の個人化は学習者の学習目的と学習能力の両者を考慮すべきであるが、先行研究では学習能力に重点を置き、学習目的への考慮が不足している。また、教育個人化を実現するための手法に関しては、概念の構造化や前提知識の抽出についての研究が盛んに行われてきたが、概念の構造化に指導者のマンパワーへの依存と前提知識の抽出に学習データへの依存は課題になっている。

本研究はこれを踏まえて、科目マテリアルを自動的に共通な知識ベースにマッチングし、それに基づき、学習者が科目検索を行う段階でシステムインタラクションデータを用いて学習目的と学習能力を推定し、またそれによって有効かつ効率的な科目内容のパスを提示するダイナミックな科目選択支援システムの提案を目的とする。

上記のシステムの実現に向けた本研究の貢献は以下のとおりになる：

- 従来の研究と異なり，マンパワーに依存せず，自動的に科目内容を知識ベースに構造化することができる。
- 学習データに依存せず，学習者の科目検索段階の行動データで学習対象を最適化することができる。

本稿は以下の様に構成される。まず，2節では関連研究を紹介する。次に，3節にて学習者に適応する科目内容のパスを提示する科目選択支援システムを提案する。4節では，科目シラバス情報を用いる科目内容解析という初期分析について述べる。最後の5節ではまとめと今後の課題について検討する。

2. 関連研究

2.1. 教育の個人化に関する研究

教育の個人化について，90年代末に Adaptive learning や Adaptive education が提唱された。その中，示唆に富んでおる Brusilovsky ら[5]の研究では，ウェブにおける学習の文脈で，学習者がそれぞれ異なる学習目的，背景知識，学習能力などを持つことを理由に，彼らの個人特徴に合わせる科目内容を提示すべきであると主張している。同様の研究として，Li ら[6]は学習者の背景知識に学習スタイルを加え，事前に定義した判断基準を参照して構造化された科目マテリアルを適応するフレームワークを提出している。

E-learning や Intelligent Tutoring 技術の発展により，オンラインシステムで行う学習が盛んになってきた。それに伴って，学習者のオンライン学習システムでの学習データを用い，科目の内容を分析して調整する研究は個人化教育に関する研究の一つ大きな流れになった[7]，[8]。例えば，Barnes[8]は学習者の学習データと科目内容を行列化したうえで，両者をつなげる潜在的なスキルモデルを構築する。そのスキルモデルは今後の学習者に対する科目内容の調整に役立つ。また，Matruda ら[7]はテスト質問に対する学習者のパフォーマンスデータを用い，学習者が科目を理解できる必要なスキルを抽出する手法を改善している。

しかし，教育個人化の目標について，以上の研究は科目内容の学習者の背景知識，学習スタイルといった学習能力への適応に止まっている。学習効果に影響を与えるもう一つの要因——学習目的に対してはあまり注意が払われていない。MOOC 受講という学習者の自発性，自由度を強調する学習環境において，科目内容を学習者の学習目的にも適応せねばなるまい。

また，教育個人化の手法について，先行研究では，どのような手法にせよ，どのようなシステムの仕組みにせよ，適応性のある科目内容をアレンジするには以

下のとおり共通なアプローチがみられる。まず，最終のタスクは学習者の特徴と科目マテリアルのマッチングすることとする。次に，これを実現するため，学習者の特徴データ（学習目的，背景知識，学習スタイルなど）を入力し，それを判断基準となる知識構造（知識概念の関係性を示すもの）を参照にし，仕立てのよい科目マテリアルのパス（望ましい学習対象の順序）を出力する仕組みである。この仕組みにおいて，急速に発展しているオンライン学習に対応するには二つの課題が生じる。第一に，学習者の特徴と科目内容を繋げる共通な知識構造は人手で作成される。つまり，一つのシステムに対し，特別な知識構造が専門家や科目の指導者により事前に定義されかねない。そうすると，人的，時間的なコストが非常に高まる一方，異種な科目に対応する柔軟性が欠ける。第二に，多くの研究は実際の学習者の科目内容に対する反応に依存する。具体的に二種類の状況が挙げられる。まず，学習データを提供する学習者にとって，そのデータは後続の学習者の科目適応に生かされるが，自身の学習は適応されない。また，学習者が提供する学習データが自身の学習適応に用いられる場合でも，学習者が当該学習システムに入ってから科目適応が行われ始める。言い換えれば，この二つのシチュエーションとも個々の学習者に最適な科目内容を作成する一番良いタイミングを損なっている。

以上が述べたように，MOOC 受講という学習環境で教育の個人化を進めるには三つのバリアを克服しなければならない：

- (1) 科目内容の適応における学習者の学習目的への考慮
- (2) 知識の構造化におけるマンパワーと非効率性の制約の突破
- (3) 学習データへの依存の回避

以下では，まず，(2)と(3)を解決するための知識構造化に関する文献のレビューを行う。次に，(1)と(3)を解決するための探索型検索システムに関する研究をまとめる。

2.2. 知識構造化に関する研究

情報化された教育という文脈において，知識の構造化は主に知識を，階層的，依存的などといった知識間の関係性，知識の難易度，抽象度などの特徴により，科目で扱われる知識を視覚的に再現し，容易に取り出すことができるように編成することを指す。名称の違いはあるため，概念地図(Concept Map)[9]–[11]，前提知識(prerequisite)[12]–[14]などのテーマを取り上げる研究を知識構造化に関連する研究として捉えることができる。

その中で、知識の関係性を抽出するために用いられる資源は学習者データと指導者データの二つに分けることができる。学習データは学習者が知識を学ぶ際にその知識に対して理解できるかどうかを測るテストのスコアのようなデータである。Tseng ら[9]は学生の試験成績データを用い、機械的にある概念に対する前提概念を抽出するアルゴリズムを提出した。同じように、Vuong ら[12]は大規模な学生の評価データを活用し、カリキュラムの中のユニットの依存関係を分析した。こちらの研究は、正確に回答される概念をよく間違えられる概念の前提知識とみなしている。一方、学生データの代わりに、指導者の知恵により再現された知識そのものを利用する研究も進んでいる。例えば、Bose ら[11]はテキストブックの内容と構造を利用し、単語の共起度で概念間関係性を抽出することを試みた。Gasparetti ら[13]は Wikipedia の文書を用い、意味解析技術で学習対象の前後関係を見つけ出すための補助になる初期分析を行った。

学習者データ依存の分析手法はサンプリングとして用いられる学習者によって知識の関係性が変化してしまうと、分析の結果は分析用のデータを提供する学生と類似する学生しかに応用できないという懸念がある。本研究では、専門家や教育機関が長期間に渡って蓄積してきた経験による知識の普遍的な関係性が存在すると考える。その普遍的な知識の関係性は、各学習者の背景知識や学習能力によってそれぞれ最適な知識の系列になる。また、普遍的な知識ベースに基づいて、機械的に科目内容をそれにマッチングすることで人手と時間のコストを削減することができる。

2.3. 探索型検索システムに関する研究

情報通信技術の進展により、情報検索は日常生活のあらゆる場面に埋め込まれており、学習活動、特にオンライン学習も例外ではない。何か学ぼうとする時に学習する対象についての検索が行われると考えられる。MOOC 受講という自発的な学習環境では学習対象を決定することは困難である。学習者が学習意欲を持つものの、学習ニーズが明確ではないケースは正に情報検索の分野で心中の情報ニーズを明確なクエリに変更できない状況に当てはまる。例えば、既存の MOOC を提供するプラットフォームでは単にユーザに与えられ学習しようと思う科目に関連するキーワード、いわゆる検索システムが分かるような消極的なクエリに対し関連度の高い科目のリストを返却する仕組みを採用している。このような科目の検索システムは学習対象が明確ではない学習者の検索ニーズへの耐性は低い懸念がある。視野を情報検索の分野に広げれば、漠然とした状態から、探索を経て知識を学習することを支援す

る探索型検索システムへの需要が高まっている[15]。

以上に述べたような現状を踏まえて、本研究は学習開始前の検索プロセスも学習プロセスとして捉える。特に学習ニーズが曖昧な状態にある学習者が自分の学習目的に合う学習対象を探索するプロセスに支援するシステムを提案する。このようなシステムは以下の二点で優れる。第一に、学習者の学習目的を明確にしながらかその目的にふさわしい科目内容を推薦することができる。第二に、検索プロセスで本番の学習プロセスを模擬することで学習データを利用せずに学習効果を事前に最大にすることができる。

3. 科目選択支援システムの提案

前節では、教育の個人化を MOOC 受講で進めるにあたって解決すべき問題点をまとめてきた。本研究はそれを踏まえて、自動的に異種な科目マテリアルを普遍的な知識ベースにマッチングし、それに基づき、学習者が科目検索段階でシステムとのインタラクションデータを用い学習目的と学習能力を推定し、またそれによって有効かつ効率的な科目内容のパスを抽出するダイナミックな科目選択支援システムの提案を目的とする。次に、コンピュータ科学分野を例にして、図 1 から図 9 で示すシステム利用のシミュレーションを描くイラストを参照しながら、システムが果たす機能を詳細に説明する。

本システムが想定しているユーザは明確な学習目的を持っていない学習者を主とするため、以下ではある社会学の学生が何等かのデータマイニング手法で社会調査のデータを分析するというモチベーションでデータマイニングを学ぶシーンを仮定する。先ず、この学生は「データマイニング」というキーワードで検索をスタートする(図 1)。

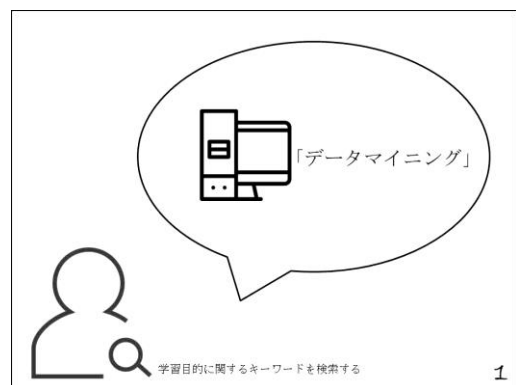


図 1 システムイラスト——最初の検索

次に、図 2 のように、システムはユーザの入力に一番関連度の高い科目を科目マップの中心としてユーザに提示する。科目マップは図 3 が示すような知識ベー

スにおける科目の位置と関係性を再現するマップで、システムにより事前に分析される。図3のイラストでは、薄い線で囲んだ各領域が知識ベースの各知識カテゴリーを表し、濃い線で囲まれた領域が科目を意味する。「データマイニング」に関する科目は、「知能システム」という知識カテゴリーの概念に集中するはずである。また、一つの科目は一つのカテゴリーの知識だけではなく、複数のカテゴリーの知識を含める可能性もあるため、図3の科目が複数の知識カテゴリーを横断している。

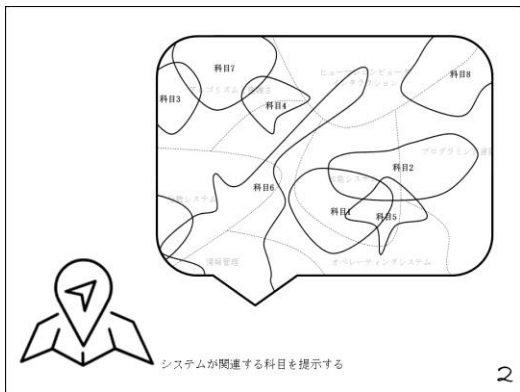


図2 システムイラスト——システムの返却




図3 システムイラスト——科目マップ

続いて、学生がシステムから提示された最初の科目マップに反応する(図4). かなり位置が近い科目の詳細を比較したい学生がいる一方、提示された知識カテゴリーの意味が分からなくもっと広い視点で全体像を見たい学生もいると想定する。もしこのユーザは図5が示すように科目マップをズームインしたら、システムの表示は図6の科目詳細図に変更する。科目詳細図は一つの科目が含まれる具体的な知識をユーザに見せるものと設計されている。その知識の表現は、ユーザの理解度により知識ベースレベル、科目表現レベル、学習結果レベル、あるいは練習問題レベルを跨いで調整で

きる。




図4 システムイラスト——ユーザの反応 a

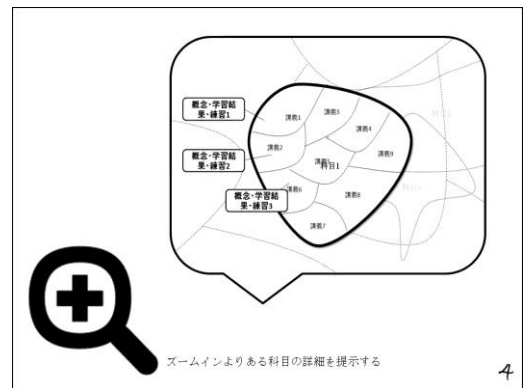


図5 システムイラスト——ユーザの反応 b

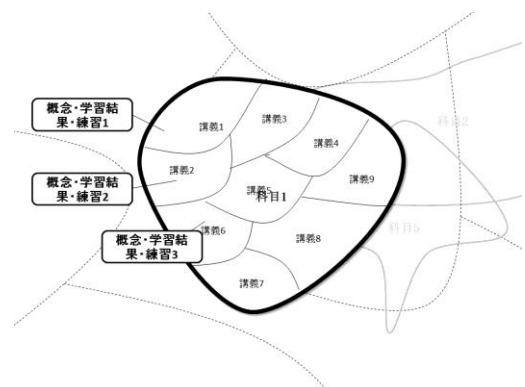


図6 システムイラスト——科目詳細図

科目詳細図を見る学生が、データマイニング手法として k-means, Apriori, Support Vector Machine などがよく利用されると分かるようになったこととしたら、次に一つか二つのデータマイニング手法に絞って学んでいこうと思うだろう。このようにユーザがシステムとインタラクションを繰り返すうちに、学習目的と学習能力も明瞭になるはずである(図7). 最終的に、システムがユーザに適切な科目の受講パスを提示する(図

8). 科目内容パスは図 9 が示すように、ユーザの学習能力から学習目的に辿り着く最短の受講経路と見なしでも良い。例えば、この学生が興味を持たないデータマイニング手法を省いたりこの学生が必要となる別の予備知識を加えたりすることで時間の浪費と注意の逸散を最小限にとどめる。




図 7 システムイラスト—インタラクション

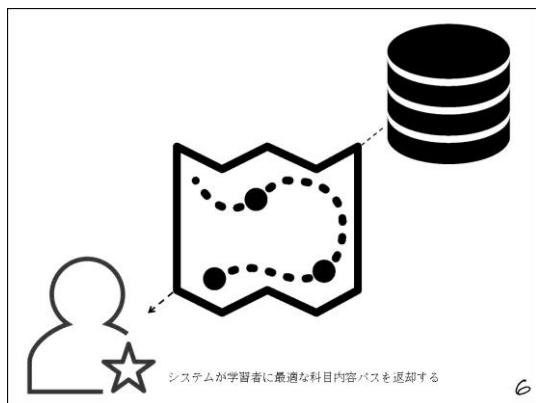


図 8 システムイラスト—システムのアウトプット




図 9 システムイラスト—最適受講パス

以上のようなダイナミック科目選択支援システムを実現するため、図 10 に示すフレームワークが考えられる。まず、学習者の学習目的、学習能力と適切な科

目内容とマッチングするために、共通な知識ベースが必要となる。これによって、異種な科目マテリアルを比較することや組み合わせることができるようになる。従って、二つのタスクが明確になる。第一に、種々な科目内容を自動的に統一な知識ベースに関連づけることである。第二に、構造化された科目内容に基づき、学習者の学習目的と学習能力を推定するソースと基準を策定し、学習者のインタラクションを駆使して最適な科目受講パスに導くことである。




図 10 本研究のフレームワーク

4. 科目内容解析

本節では、ダイナミック科目選択支援システムの実現の手始めとしての科目内容解析について説明する。

4.1. 概要

異種な科目内容を共通な知識ベースに位置付けるため、本研究はコンピュータ科学分野のカリキュラム標準の知識体系に基づき、科目のシラバス情報を用い、bag-of-words で科目内容の知識カバレッジを抽出することを試みる。

コンピュータ科学分野では、IEEE-CS と ACM が定めたカリキュラム標準があり、大学学部レベルコンピュータ科学学科が扱うべき知識を網羅している。2013 年末発表された「Computer Science Curricula 2013」[16] (下記 CS2013) では、コンピュータ科学分野の知識体系を 18 個の知識領域(Knowledge Area, 下記 KA)にカテゴリー化し、それぞれの KA に属する知識ユニット (Knowledge Unit, 下記 KU) と知識トピックを明記している。また、様々な目的を持つ教育機関に適用し、コンピュータ科学教育の幅を広めるために、教育にまだ定着していない先端な知識を包括するようにしている。このようなカリキュラム標準もよく教育機関のカリキュラム分析に用いられる[17], [18]。石畑ら[17]は設立経緯が異なる理工系情報学科で実際に教えられている内容の全体像を把握するため、収集した大学のシラバスがコンピュータ科学知識体系にどう対応するかを専門家による人手の判定を行った。Sekiya ら[18]は教師ありの LDA モデルを用い、科目がコンピュータ科

学知識体系の KA をカバーする確率を予測した。以上の議論から、カリキュラム標準が定めた知識体系を知識ベースとして活用する可能性が見られる。

4.2. データセット

CS2013 では実際の大学で開講されている 81 個のサンプル科目の調査データを公開し、各科目のシラバス情報以外に、各指導者が自分の科目がどれほどカリキ

ュラムの知識体系を含めるかというカバレッジデータも提供している。図 11 はある科目シラバス情報の抜粋である。指導者が付与したカバレッジデータが図 12 に示すように、各 KA の知識を含める程度が講義の時間数で表されている。本研究では、カバレッジデータの欠如のある科目を除いて、73 サンプル科目を科目内容解析のデータとして利用した。

What is covered in the course?	
•	The modeling process
•	Two system dynamics tool tutorials
•	System dynamics problems with rate proportional to amount: unconstrained growth and decay, constrained growth, drug dosage
•	System dynamics models with interactions: competition, predator-prey models, spread of disease models
•	Computational error
•	Simulation techniques: Euler's method, Runge-Kutta 2 method
•	Additional system dynamics projects throughout, such as modeling falling and skydiving, enzyme kinetics, the carbon cycle, economics and fishing
•	Six computational toolbox tutorials
•	Empirical models
•	Introduction to Monte Carlo simulations
•	Cellular automaton random walk simulations
•	Cellular automaton diffusion simulations: spreading of fire, formation of biofilms

図 11 シラバス情報の例

Knowledge Areas with topics and learning outcomes covered in the course	
Knowledge Area	Total Hours of Coverage
Computational Science (CN)	35.5
Intelligent Systems (IS)	3
Software Development Fundamentals (SDF)	2
Software Engineering (SE)	1
Graphics and Visualization (GV)	0.5

図 12 指導者が付与した知識カバレッジの例

4.3. 分析手順

分析の目標は、自然言語処理でよく使われる bag-of-words 手法を用い、各科目のシラバスを CS2013 の知識体系の単語空間でベクトル化することにより、シラバスの KA カバレッジを予測することである。具体的な分析手順は以下ようになる。まず、CS2013 の知識体系に出現している単語集合を $V = \{t_1, t_2, \dots, t_{|V|}\}$ で表す。そして、各 KA のドキュメントの V 空間でのベクトルを $\vec{ka}_j = (w_{1,j}, w_{2,j}, \dots, w_{|V|,j})$ ($w_{i,j}$ は i 番目の単語が j 番目の KA における重みであり、当該単語が当該 KA を代表する割合を表す) で記し、(1-a) と (1-b) と二種類の数式で $w_{i,j}$ を算出する。(1-b) は各文書における単語の重み付け手法としてよく知られる TF-IDF 手法である。

$$w_{i,j} = occ_{i,j} \quad (1-a)$$

$$w_{i,j} = tf_{i,j} \times idf_i \quad (1-b)$$

ここで：

$occ_{i,j}$: i 番目の単語が j 番目の KA で出現すれば 1, そうでなければ 0

$tf_{i,j}$: i 番目の単語の j 番目の KA での出現頻度

idf_i : i 番目の単語の逆文書頻度

また、V を参照して、用意した \vec{ka}_j を用い、科目シラバス文書の KA 空間におけるベクトル $\vec{s}_k = (v_{1,k}, v_{2,k}, \dots, v_{|KA|,k})$ を算出する ($v_{j,k}$ が k 番目のシラバスの j 番目の KA における知識カバレッジを表し、数式(2)により算出される)。

$$v_{j,k} = \sum_{i \in V} occ_{i,k} \times w_{i,j} \quad (2)$$

ここで：

$occ_{i,k}$: i 番目の単語が k 番目の科目シラバスで出現すれば 1, そうでなければ 0

得た科目-KA ベクトルの正確さを評価するため、科目-KA ベクトルの成分の大きさにより各科目の含める KA の順位を指導者が付与した KA カバレッジ順位と

比較する．比較にあたって，順位付け問題でよく用いられる評価指標 $nDCG$ (Normalized Discounted Cumulative Gain) を利用する．具体的な算出手法は数式(3)に示される．

$$\begin{cases} nG_c[i] = \frac{rel_c[i]}{m_c[k]} \\ DCnG_c[k] = nG_c[1] + \sum_{i=2}^p \frac{nG_c[i]}{\log_2 i} \\ nDCnG_c[k] = \frac{DCnG_c[k]}{IDCnG_c[k]} \end{cases} \quad (3)$$

ここで：

c:科目

$rel_c[i]$: ある科目に対し，指導者が付与した i 番目の KA の知識を扱う講義時間数

$m_c[k]$: 上位 k 個に着目する際の rel_c の最大値

$nG_c[i]$: 標準化されたゲイン値

$DCnG_c[k]$: 上位 k 個に着目する際のディスカウント累積ゲイン値

$IDCnG_c[k]$: 上位 k 個の KA に着目する際の理想的な順位で得られるディスカウント累積ゲイン

KU は KA の下位カテゴリーで，科目-KU ベクトルの算出と評価は同様な手順で施す．

4.4. 結果と考察

上記の分析手順を Python のライブラリ `scikit learn` で実装して，以下の結果を得た．

表 1 科目-KA の $nDCnG$ 値

k	1	2	3	4	5	6	7	8	9
nDCnG[1]	0.863	0.874	0.866	0.866	0.877	0.880	0.880	0.875	0.875
nDCnG[2]	0.959	0.914	0.917	0.917	0.920	0.928	0.930	0.932	0.934
k	10	11	12	13	14	15	16	17	18
nDCnG[1]	0.878	0.882	0.884	0.885	0.887	0.888	0.889	0.889	0.889
nDCnG[2]	0.936	0.938	0.939	0.940	0.941	0.942	0.942	0.942	0.942
nDCnG 平均値[1]	0.880								
nDCnG 平均値[2]	0.934								

(注：[1]は数式 (1-a)で計算した結果であり， [2]は数式 (1-b)で計算した結果である．)




図 13 科目-KA の $nDCnG$ 値の折れ線図

表 1 と図 13 が示すように，単語が各 KA での重みを 0-1 変数で計算する場合，本研究が提案する手法で予測した KA 単位での科目の知識カバレッジは指導者が付与した知識カバレッジと 0.880 水準で一致していたことが分かる．また，単語の重みとして `tfidf` 値を利用する場合，0.934 水準で一致していた．特に，一つの KA に着目する場合，95.9%の正確率で予測することができた．

一方，KU レベルでの予測は更に細かい粒度で計算するため，精度は KA より落ちていた．単語の重みを 0-1 変数で計算する場合， $nDCnG$ 平均値は 0.577 水準に留まっていた．単語の重みの計算に `tfidf` 値を利用する場合は， $nDCnG$ 平均値は 0.697 水準であった． $nDCnG$

値がどの水準であったら正確に科目の知識カバレッジを反映できるかは議論する余地があるが，KU レベルでの予測精度は理想的ではないと言える．原因としては，各 KU の特徴単語が重複すぎる可能性，科目のシラバスの語彙とカリキュラム標準の語彙との相違などが挙げられる．

5. まとめと今後の課題

教育の公開化を背景に，MOOC 受講という自由化と個人化を強調する学習を支援するため，本研究では，自動的に科目マテリアルを共通な知識ベースにマッチングし，それに基づき，学習者が科目検索段階でシステムとのインタラクションデータを用い学習目的と学習能力を推定し，またそれによって有効かつ効率的な科目内容の受講パスを抽出するダイナミックな科目選択支援システムを提案した．また，このようなシステムを実現させるため，初期分析としての科目内容解析を行った．その結果，本研究が提案する手法は科目の知識カバレッジを予測する可能性を示した．

今後の課題は次の二点に分けることができる．

- 科目の知識構造を自動的に抽出する手法を改善する．
- 学習者の学習目的と学習能力に適応する科目内容を見つけ出すプロセスに不可欠な学習者データの推定する手法を策定する．

参 考 文 献

- [1] L. Yuan, S. Powell, and J. CETIS, "MOOCs and open education: Implications for higher education," 2013. [Online]. Available: <http://publications.cetis.org.uk/wp-content/uploads/2013/03/MOOCs-and-Open-Education.pdf>. [Accessed: 11-Jan-2016].
- [2] A. D. Ho, I. Chuang, J. Reich, C. A. Coleman, J. Whitehill, C. G. Northcutt, J. J. Williams, J. D. Hansen, G. Lopez, and R. Petersen, "HarvardX and MITx: Two Years of Open Online Courses Fall 2012-Summer 2014," Social Science Research Network, SSRN Scholarly Paper ID 2586847, 2015.
- [3] "大学のオープン化に関する調査結果 (2015) : NTTコム リサーチ," *NTTコム リサーチ 調査結果 - IT 動向や消費行動などトレンドなリサーチ結果レポートを公開*. [Online]. Available: <http://research.nttcoms.com/database/data/002002/>. [Accessed: 06-Jan-2016].
- [4] Y. Belanger and J. Thornton, "Bioelectricity: A Quantitative Approach Duke University's First MOOC," Report, 2013.
- [5] P. Brusilovsky, J. Eklund, and E. Schwarz, "Web-based education for all: a tool for development adaptive courseware," *Computer Networks and ISDN Systems*, vol. 30, no. 1-7, pp. 291-300, 1998.
- [6] F. W. B. Li, R. W. H. Lau, and P. Dharmendran, "An Adaptive Course Generation Framework," *Int. J. Distance Educ. Technol.*, vol. 8, no. 3, pp. 47-64, 2010.
- [7] N. Matsuda, T. Furukawa, N. Bier, and C. Faloutsos, "Machine beats experts: Automatic discovery of skill models for data-driven online course refinement," in *Proceedings of the 8th International Conference on Educational Data Mining*, 2015.
- [8] T. Barnes, "Q-matrix Method: Mining Student Response Data for Knowledge," in *Technical Report (WS-05-02) of the AAAI-05 Workshop on Educational Data Mining*, 2005.
- [9] S.-S. Tseng, P.-C. Sue, J.-M. Su, J.-F. Weng, and W.-N. Tsai, "A new approach for constructing the concept map," *Computers & Education*, vol. 49, no. 3, pp. 691-707, 2007.
- [10] J. J. Villalon and R. A. Calvo, "Concept Map Mining: A Definition and a Framework for Its Evaluation," in *Proceedings of the 2008 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology - Volume 03*, pp. 357-360, 2008.
- [11] R. J. C. Bose, O. Deshmukh, and B. Ravindra, "Discovering Concept Maps from Textual Sources," in *Proceedings of the 8th International Conference on Educational Data Mining*, 2015.
- [12] A. Vuong, T. Nixon, and B. Towle, "A method for finding prerequisites within a curriculum," in *Proceedings of the 4th International Conference on Educational Data Mining*, 2011.
- [13] F. Gasparetti, C. Limongelli, and F. Sciarrone, "Exploiting wikipedia for discovering prerequisite relationships among learning objects," in *Proceedings of the International Conference on Information Technology Based Higher Education and Training*, pp. 1-6, 2015.
- [14] J. Řihák, R. Pelánek, and J. Nižnan, "Student Models for Prior Knowledge Estimation," in *Proceedings of the 8th International Conference on Educational Data Mining*, 2015.
- [15] 三輪眞木子, "検索のゆくえ (<特集> 『検索』のゆくえ)," *情報の科学と技術*, vol. 63, no. 1, pp. 2-8, 2013.
- [16] A. for C. M. (ACM) Joint Task Force on Computing Curricula and I. C. Society, "Computer Science Curricula 2013: Curriculum Guidelines for Undergraduate Degree Programs in Computer Science," Technical report, ACM, 2013.
- [17] 石畑清, 大岩元, 角田博保, 清水謙多郎, 玉井哲雄, 長崎, 中里秀則, 中谷多哉子, 疋田輝雄, 三浦孝夫他, "理工系情報学科の授業内容分布のシラバスによる調査 (中間報告)," *情報教育シンポジウム*, 2010.
- [18] T. Sekiya, Y. Matsuda, and K. Yamaguchi, "Curriculum analysis of CS departments based on CS2013 by simplified, supervised LDA," in *Proceedings of the Fifth International Conference on Learning Analytics And Knowledge*, pp. 330-339, 2015.