

Hyper 構造 CAI における適応的内容選択機構

柳沢 孝典

松居 辰則

岡本 敏雄

電気通信大学大学院情報システム学研究科

*Graduate School of Information Systems,
The University of Electro-Communications*

ハイパー・メディア教材を用いた探索学習を行なう際、学習者は自由な探索を行なうことができる反面、学習の脈絡性が失われてしまう可能性が高い。このような学習において、適応的にノードの選択を行なうことは、学習者にとって有効である。本論文では、学習の脈絡性に着目し、学習者の学習状態から適応的に学習内容を選択する手法を提案する。また、これらのシステムを実装し、その評価実験の結果について考察する。

Adaptive Contents Selection Method in the Hyper Structured CAI

Takanori Yanagisawa Tatsunori Matsui Toshio Okamoto

Recently, hypermedia has gained widespread popularity as a useful learning technology. In exploration learning in hypermedia, however, learner has probability to lost coherence in learning. So, to provide an efficient and adaptive learning environment in hypermedia, it seems important to focus on coherence in exploration learning. In this paper, we propose Adaptive Contents Selection Method in the Hyper Structured CAI. In this system each node is selected depending on learner's knowledge situation. Firstly, we describe a methods of this system, secondly, we discuss configuration of this system, the last we analyzed behavior of this system.

1 はじめに

近年、探求的学習を支援するシステムとして、ハイパー・メディアシステムが注目を浴びてきている。

ハイパー・メディアは、複数のメディアを統合しつつ柔軟で非直線的な多様な情報の結合が可能であり、これによって学習者の自由な探索が可能である。そのため、特にユーザの主体的な学習の展開を期待するような探求的活動においては、探索活動を通して得られる幅広い知識の教育的意義および教育的活用における重要性が指摘されており、ハイパー・メディアを利用した探索学習の効果が期待されている。

探索学習は、学習者は興味・関心を抱いたことがらについて学習者が自由に探索を行ない、学習を進めていく形式の学習である。学習者は関心のある学習内容に基づき探索を行なうばかりではなく、探索による新

たな発見や、学習による新たな関心、連想など、従来にない自由な学習が期待される。

例えば歴史学習では、それぞれの歴史事象にさまざまな関連事象が存在するにも関わらず、従来教科書などでは地域や年代に沿った直線的な学習が行なわれていた。これに対し、ハイパー・メディアを用いた探索学習を行なうことによって、学習者はハイパー空間を自由に探索し、関心のある情報を見つけ出して、地域、年代に関わらず学習を進めることができる。

しかし一方では、ハイパー空間上では、現在参照中のノードの位置を失う恐れがあり、選択肢過多の問題は学習者に過度の負担を強いることになる。また、探索学習においては、学習の脈絡性が重要であり、興味本位の探索は学習を阻害することになりかねない。

本研究では、適切な探索活動を行なうために学習の脈絡性に着目し、学習者に対する支援を行なう。以下

に研究の目的と理論について述べる。

2 研究の目的

ハイパー空間上での探索学習では、それぞれの学習内容が関連性のない離散的な学習が行なわれる可能性が強く、このような学習では、学習の脈絡性が失われ、学習者の学習の理解がさまたげられる可能性が生じる。そのため、適切な探索活動を行なうためには、学習者に対する支援が必要である。

そこで本研究は、Hyper構造を持つCAIにおいて、学習の脈絡性があり、学習者が興味・関心を持っているノードを学習者の学習状態から適応的に選択する手法を提案し、脈絡性のある学習の支援を行なうこととする。

具体的には、学習の脈絡性と、学習者が興味・関心を持ったノードに対する他のノードの類似度を定義し、ファジィ推論を用いてこれらを融合する手法を提案する。また、融合の際、学習者の学習状態から適応的にルールのチューニングを行なう手法について提案する。

そのためには、教師の考える学習の脈絡を持った教材空間が必要である。また、ファジィ推論を用いて脈絡性と類似度を融合するためには、システムは教師の考えを反映した推論規則を持つ必要がある。しかしながら、教師がすべての推論規則を定めるのには無理がある。

そこで本研究では、教材空間を定義し、推論規則の自動生成手法を提案する。また、これらを統合したシステムを実装し、その評価実験を行う。

以下に、教材空間を定義し、脈絡性と類似度について述べる。次に、推論規則における自動生成法とそのチューニング法について述べ、これらを統合したシステムの構成について述べる。最後に評価実験について述べる。

3 教材空間

本研究では、学習の脈絡性を定義するため、次のような教材空間を定義する。

教材空間は、ノード間に物理的にリンクが張られたHyper空間と、意味的な有向グラフを構成するSemantic空間の2層構造をなしており、図1に示される。

各ノードはHyper空間とSemantic空間の2つの空間に所属しており、Hyper空間では学習者がリンクを辿ることによってノードを参照することが出来、Semantic空間では各ノード間の意味的なつながりを示した構造グラフを得ることが出来る。

各ノードにはそれぞれ

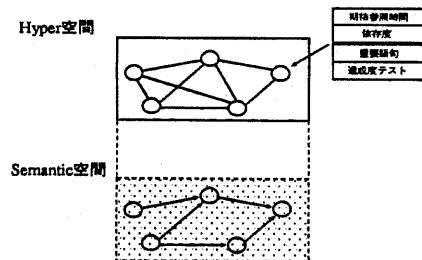


図1: 教材空間

T_t(A_t, B_t, C_t, ...)

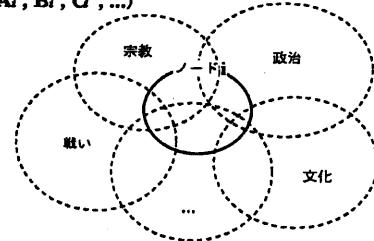


図2: 依存度

- 期待参照時間
- 依存度
- 重要語句
- 達成度テスト

が付与されている。

依存度とは、与えられた教材をいくつかのトピックに分類して考えるとき、ノードの学習内容のそれぞれのトピックへの帰属度をベクトルで表したものである。例えば図2のように表す。

ここでいうトピックとは、それぞれがある視点で捉えたときのテーマに相当し、例えば本研究のドメインである歴史学習においては、宗教、戦い（戦争）、政治、文化、などに相当する。各ノードは複数のトピックに非明示的に所属するものとし、依存度が近いノード同士は学習内容も近いものとする。

4 脈絡性と類似度

提示ノードの選択を行なう際に、学習者が興味を持ち、あるいは重要と認識した事柄に関連するノードの提示を行なうことは重要である。しかしながら、学習者の考えのみを頼りにノードの提示を行なった場合、学習の脈絡を失い、学習理解を損なう可能性がある。

本システムでは、学習者側と教材作成者側の2つの視点により提示ノードの選択を行ない、脈絡性のある学習の支援を行なう。教材作成者側の視点として脈絡性を定義し、学習者側の視点から類似度を定義する。

以下に脈絡性と類似性の定義を述べ、算出方法について述べる。

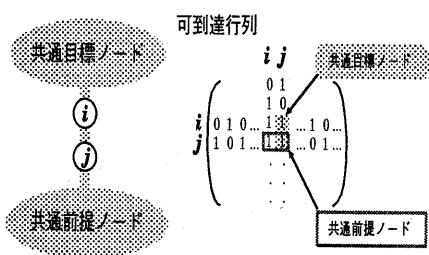


図 3: 脈絡性の定義

4.1 脈絡性の定義

教材空間の Semantic 空間ににおいて、ノード i とノード j のいずれのノードにも到達可能であるノードを i と j の共通前提ノードとし、逆にノード i とノード j のいずれのノードからも到達できるノードを共通目標ノードとして、脈絡性を次式のように定義し、この式の物理的な意味を図 3 に示す。

$$C_{ij} = \frac{\# [B_i \cap B_j] \cdot \# [F_i \cap F_j]}{\# [B_i \cup B_j] \cdot \# [F_i \cup F_j]}$$

$\# [A]$: 集合 A の要素数
 B_i : ノード i の前提ノード
 F_i : ノード i の目標ノード

4.2 類似度の定義

類似度を、学習者が重要と認識した学習内容と各ノードの学習内容との近さと定義する。

以下に学習者が重要と認識した学習内容として予測ベクトルを定義し、次に類似度の算出方法について述べる。

4.3 予測ベクトルの定義

学習者が重要と認識した学習内容は、学習者が重要と認識し、選択した重要語句の時系列履歴から算出される。これを予測ベクトルとする。

各ノードが保持する重要語句はそれぞれ依存度を持ち、選択された重要語句の依存度の時系列履歴からマルコフ連鎖的に算出する。以下に計算式を示す。

$$\vec{y} = \sum_{i=1}^{n'} \left(\frac{1}{n'} \right) \sum_{k=1}^m W_k / \text{最大値} \quad w_i: \text{依存度}$$

4.4 類似度の算出

予測ベクトルと類似度の距離を取り、その近さを類似度とする。以下に計算式を示す。

$$\text{類似度 } r = 1 - \frac{|\vec{y} - \vec{w}_i|}{\sqrt{|\vec{w}_i|}} \quad w_i: \text{依存度}$$

5 ファジィ推論における推論規則

本システムでは、学習者の考えである類似度と教材作成者の考えである脈絡性の双方を採用し、いずれにおいても満足度の得られるノードを推論する。

そのために、推論エンジン内部に以下のように推論規則を定め、推論度の算出を行なう。

推論方法は、各規則から推論された結果をすべて足し加え、最終的な推論結果にすべての規則が寄与することから、product-sum 重心法を用いた。

5.1 基本規則の設定

推論規則は、IF-THEN 形式で記述され、次の 4 つのルールを基本規則として定める。

	類似度	脈絡性	推論度
規則 1	高い	高い	高い
規則 2	高い	低い	中庸
規則 3	低い	高い	中庸
規則 4	低い	低い	低い

基本規則とは、類似度と脈絡性から得られる推論度との関係を表した最も基本的なルールであり、あらかじめ定められるものとする。

しかしながら、わずか 4 つの推論規則では、学習者の多様な考え方や、教師の考えである脈絡性を表すことは困難であると考えられる。そこで、この問題を解決するために、ルールを教師の意図に従う形で連続的に与えることとする。

6 ルールの自動生成

基本規則に基づき、ルールを決定する方法について述べる。

6.1 教師による状態分割数の設定

基本規則ではそれぞれの指標は「高い」と「低い」の 2 つの状態のみによって表されている。これに対し、教師はそれぞれの指標に適切な状態分割数を設定し、ルールの前件部のメンバシップ関数を定めるものとする。状態分割数とは、それぞれの指標において分割される状態の数のことであり、各指標は「高い」状態から「低い」状態まで均等に状態が設定される。状態分割数が多いほど細かくルールを設定することが出来る。今、状態分割数を N として、次のように表現されているとする。

A_1 : 「極めて高い」

A_2 : 「大変高い」

...

A_{N-1} : 「大変低い」

A_N : 「極めて低い」

前件部メンバシップ関数

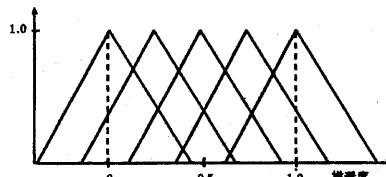


図 4: 前件部メンバシップ関数

三角形のメンバシップ関数において、頂点の x 座標の値を中央値と呼ぶことにする。新しい状態を表すメンバシップ関数の中央値の値を α_{A_i} とすると、以下のように決定される。

$$\alpha_{A_i} = \frac{1}{N-1} \cdot i \quad (i = 1, 2, 3, \dots, N)$$

三角形の底辺にあたる部分を幅 W とすると、規則 i の前件部メンバシップ関数 μ_{A_i} は以下のように決定される。

$$\mu_{A_i} = \begin{cases} \frac{2}{W}(x - \alpha_{A_i}) + 1 & (\alpha_{A_i} - \frac{W}{2} \leq x \leq \alpha_{A_i}) \\ -\frac{2}{W}(x - \alpha_{A_i}) + 1 & (\alpha_{A_i} < x \leq \alpha_{A_i} + \frac{W}{2}) \end{cases}$$

ただし、 W = メンバシップ関数の幅

決定されたメンバシップ関数を図 4 に示す。

6.2 後件部メンバシップ関数の決定

生成されるルールは状態を表すファジ集合 A_i, B_j を用いて次のように表される。

$$\text{規則 } R_{i,j} : A_i, B_j \rightarrow C_{i,j}$$

このとき、後件部のメンバシップ関数は、前件部の表現する状態によって決定されるものである。従って後件部メンバシップ関数は、基本規則に基づいて設定されるのが妥当であると考えられる。本研究では、後件部のメンバシップ関数の中央値 $\alpha_{C_{i,j}}$ を前件部のメンバシップ関数の中央値から以下のように決定する。

$$\alpha_{C_{i,j}} = \begin{cases} t - 4(0.5 - t)^2 & (t > 0.5) \\ t + 4(0.5 - t)^2 & (t < 0.5) \end{cases}$$

ただし、 $t = \frac{\alpha_{A_i} + \alpha_{B_j}}{2}$

前件部の 2 つの指標を表す状態の中間点 t を後件部の中央値に設定すると、基本規則を満たし、ほぼ妥当と考えられるルールが得られる。しかし、本手法ではさらに、類似度と脈絡性の双方が「高い」状態を表している場合にはより高く、双方が「低い」状態の場合にはより低い状態を示すようにルールを設定する。

後件部のメンバシップ関数は、 $\alpha_{C_{i,j}}$ を用いて全件部メンバシップ関数と同様に次式で表される。

$$\mu_{C_i} = \begin{cases} \frac{2}{W_C}(x - \alpha_{C_i}) + 1 & (\alpha_{C_i} - \frac{W_C}{2} \leq x \leq \alpha_{C_i}) \\ -\frac{2}{W_C}(x - \alpha_{C_i}) + 1 & (\alpha_{C_i} < x \leq \alpha_{C_i} + \frac{W_C}{2}) \end{cases}$$

後件部メンバシップ関数

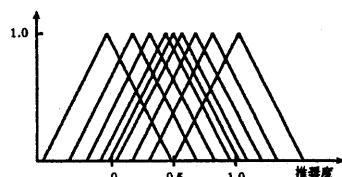


図 5: 後件部メンバシップ関数

ただし、 W_C = 後件部メンバシップ関数の幅
上記式によって決定されたメンバシップ関数を図 5 に示す。

7 推論規則のチューニング手法

チューニング機構では、達成度の値に応じて推論規則のメンバシップ関数を変更し、チューニングを行なう。

ここでは達成度が高い場合には、学習者の考えである類似度を強く採用し、達成度が低い場合には逆に教師の考えである脈絡性を強く採用するようにルールを変更することを目的とする。

7.1 達成度の算出

達成度とは、学習者の参照ノードにおける学習の達成度合を指す。各ノードがもつ期待参照時間に対する参照時間の割合と達成度テストの正答率から以下の式によって算出される。

$$\alpha \times \text{達成度テストの正答率} + (1-\alpha) \times (\text{参照時間}/\text{期待参照時間})$$

ここで α は達成度係数とし、教材作成者によって設定されるものとする。

7.2 チューニング手法

推論規則では、三角形のメンバシップ関数を採用している。この三角形のメンバシップ関数の頂点を中心値、底辺の両端を端点とする。端点間の距離を大きくし、底辺を広げることによってそのメンバシップに対する確信度を減少させ、チューニングを行なう。

この操作により、達成度が高い場合には、脈絡性のメンバシップ関数の確信度を下げて類似性を強く採用し、達成度が低い場合には、類似性の確信度を下げて脈絡性を強く採用する。

以下に脈絡性のメンバシップ関数の幅を W_m 、類似度のメンバシップ関数の値を W_r とし、変更する以前のメンバシップ関数の幅を W として関数の幅の決定式を記す。

$$\alpha_{C_{i,j}} = \begin{cases} W_m = W_1 + k(t - 0.5)^2, W_r = W & (t > 0.5) \\ W_m = W, W_r = W_1 + k(t - 0.5)^2 & (t < 0.5) \end{cases}$$

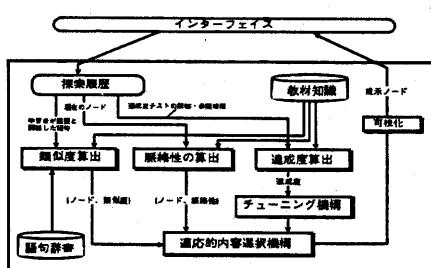


図 6: システム構成図

t : 達成度
 k : チューニング係数

8 システム構成

本システムは次のように大きく5つのモジュールから構成されている。

- 類似度の算出
 - 脈絡性の算出
 - 達成度の算出
 - チューニング機構
 - 適応的内容選択機構

システムの構成を図6に示し、以下に各モジュールについて説明する。

8.1 探索履歷

学習者の探索活動における履歴を保持する。

探索履歴には、以下のデータが時系列に記録される。

- 学習者が重要と認識した語句
 - 参照ノード
 - 参照時間

学習者がノードを参照すると、参照ノードとそのノードの参照時間が記録される。また学習者は達成度テストを行なう際に、参照ノードが持つ重要語句の中から重要と認識した語句を選択すると、これらの語句が時系列に記録される。

8.2 類似度の算出と脈絡性の算出

探索履歴を基に学習者が重要と認識した語句から予測される依存度を予測ベクトルとして算出し、各ノードがもつ依存度と予測ベクトルとの距離を類似度として算出する。教材知識からは脈絡性が参照され、各ノードに対する類似度と脈絡性のデータの組が適応的内容選択機構に送られる。

8.3 チューニング機構

チューニング機構では、達成度の値に応じて適応的内容選択機構のファジィルールのメンバシップ関数を変更する。

達成度とは、学習者の各ノードにおける学習状態を指す。参照時間と達成度テストの正答率から達成度を算出し、その値がチューニング機構に渡される。

学習者がノードを参照し、その履歴が書き込まれると、達成度が算出され、最初にルールのチューニングが行なわれる。

達成度が高い場合には、学習者の考えを強く採用し、達成度が低い場合には、教師の考えを強く採用するようルールのチューニングを行なう。

8.4 適應的內容選択機構

類似度と脈絡性の値をファジィ推論を用いて融合し、推奨度を算出する。推奨度とは、各提示ノードに対しそのノードが推奨される度合を表したもので、学習者の意見である類似度と教師の意見である脈絡性とを達成度の値によって適応的に融合したものである。

チューニング機構によりルールのチューニングが行なわれた後、各ノードに対する類似度と脈絡性を融合し、それぞれのノードに対する推奨度を算出してノードを決定し、可視化によりそのノードを提示する。

9 評価実験

システムが妥当な振舞いをしているかどうか、また、その振舞いが実際に学習者の感覚にあうものであるかを評価するため、以下に示す実験及びアンケート調査を行なった。これは、学習者の感覚に沿うかどうかをアンケートにて調査し、また、同時にそれらのシステムの振舞いが妥当であるかを定量的に測定し、アンケート調査の結果と比較・検討することを目的とする。

9.1 実験方法

探索学習において、各ノードを参照し、テストを行なうとシステムが学習者に適応的にノードを提示するが、そのたびに、

- 脈絡性があるか
 - 学習内容が期待した内容に沿うものであったかの2点について尋ねた。

学習者は各自 10 フレームの学習を行ない、それぞれのフレームにおいて、感じたことを記述する。また、検証の際には、学習者が直接記述した内容と学習者が重要と認識し、選択した重要語句から推測される内容について考察を行なう。

9.2 実験結果に対する考察

アンケート調査の結果、参照ノードと提示ノードの脈絡性の評価では、評価にばらつきがあるが、脈絡性を感じられない場合が多かった。しかしながら、被験者は比較的達成度が高く、システムは類似度を重要視して提示ノードを選択している。このことから、達成度の高い学習者の場合、脈絡性を考慮しない方法でノードを選択しても、ある程度の脈絡性があると感じていることが分かった。

また、期待する学習内容に対する提示ノードの評価については、後半では期待に沿わないノードの提示が多い結果となったが、アンケートの具体的回答を見ると、提示ノードにおいて評価が落ち込んでいるのは、期待する地域と提示ノードの学習内容の地域が異なっているためであることがわかった。しかし、実際に希望する内容のノードを調べてみると、同じ地域にはそのようなノードがなく、システムは、それ以外の部分から近いノードを提示していることが分かった。実際に予測ベクトルと提示ノードの類似性を見ると、達成度が高い場合には高い類似度を示しており、また、内容的見ても少なくとも同時代の同地域のノードが提示されており、定量的な部分からはほぼ妥当な振舞いであると言える。

予測ベクトルの妥当性については、後半になるにつれて、学習者の希望する学習内容が固定されるという現象が起きたが、その際、提示ノードは感覚的に非常に近いノードを提示し続けた。逆に、学習者が全く関連しないことを学習しようと考えたときに、それが直接反映しないので、学習者の期待する提示ノードに対する満足度を多少下げる結果となっているが、脈絡性の点からは評価を受けている。

これは、予測ベクトルが最近に参照したノードに重みをおいて学習者の希望する学習内容を予測しているため、学習者がある傾向を持ってノードの選択をしつづけるときにはその学習内容に非常に近いノードを提示し、そうでない場合は、その際の学習者の考えとは少しずれる部分もあるが、脈絡性があるノードの選択を行なうことを示している。よって、本手法は妥当であるといえる。

10まとめ

本研究では、Hyper構造CAIにおける適応的内容選択手法の提案を行なった。本システムでは学習者の考えと教材作成者側の考えとを融合し、学習者の学習状態から適応的にノードを選択するが、このとき、教材作成者側の考えとして脈絡性を、学習者側の考えとし

て類似性を定義し、推論規則のチューニング手法について提案をした。

また、推論規則を自動的に生成することによって、教材作成者の負担を減らすことが出来た。

さらに、本研究では歴史学習をメインとし、これらの機構を組み込んだCAIシステムを構築した。実験及びアンケート調査の結果は、システムは学習者の選択した内容に対しては適切な振舞いをしているが、学習者の感覚に合うようなノードの提示はあまり行なわれなかった。これは原因として教材作成者側の脈絡性の考え方と学習者側の脈絡性の考え方にはずれが生じたことが挙げられるが、学習者集団の特性を熟知した専門家が教材を作成することによって、学習者の感覚にも近い内容が選択されるようになると思われる。また、学習者がイメージした学習内容をシステムが保持していない場合があったが、この場合、比較的近い内容のノードを選択し、提示した。このことから本システムは比較的柔軟な処理が可能であることがわかった。

参考文献

- [1] 金子朝男:ハイパー メディアの研究動向, 情報処理, Vol.34, No.1, pp.60-71(1993).
- [2] 北垣郁雄:評価のあいまいさとファジイ評価の教育への応用, 教育システム分析(坂本鼎監修), 第7章.
- [3] 蜂谷憲一, 平嶋宗, 柏原昭博, 豊田順一:文脈情報を用いたハイパーテキストナビゲーションシステム, 人工知能学会第9回全国大会, pp.605-pp.608, 1995.
- [4] 松居辰則, 小泉直範, 山田圭一, 三国裕子:学習者の知識構造で制御する適応型学習システムの研究・開発(1)一出題最適化エキスパートシステム部の理論-, 信学技法 ET-95-1, pp.25-32, 1995.
- [5] 篠山邦夫, 長瀬久明, 正司和彦:発見を促す動的リンク・ハイパーカード教材の開発と授業の構成-小学校歴史における調べ学習の実践のもとに-, 教育工学関連学協会連合第4回全国大会, pp.391-394, 1994.
- [6] 清水誠一:ファジイ推論を応用したハイパー メディアシステム, 教育工学関連学協会連合第4回全国大会, 1994.
- [7] 竹谷誠:課題系列化のための教授方略の特性分析, 電子情報通信学会論文誌 A, Vol.J75-A, No.2, pp.371-381(1992).
- [8] 竹谷誠:戦略的課題系列化アルゴリズムと文脈・大意の構成法, 信学技報, ET90-135(1990).
- [9] 吉根勝美, 磐本征雄, 石井直宏, 木村吉男:ファジイ推論による思考錯誤型学習のCA Lモデル, 電子情報通信学会論文誌, vol.J76-A No.4 pp.663-672.