

ハイパー空間の意味的特徴に基づく 探索ナビゲーションに関する研究 - ハイパー空間の特徴表現について -

香山 瑞恵 岡本 敏雄

電気通信大学大学院 情報システム学研究科

あらまし：本研究の目的は、ハイパー空間の意味的特徴と、ユーザの探索履歴の定量的、および定性的特徴とに基づき、探索活動をナビゲートする機構を実現することである。ナビゲーションは、システムからユーザに対して探索候補ノードを提示することによってなされる。探索活動が展開される世界であるハイパー空間全体の意味的特徴の類似性をサブシンボリックな手法により表現する。そして、その結果に探索履歴を写像することで探索状態を表現し、提示するノード候補の集合を絞り込み、ナビゲーションのための情報を選別するものである。本稿では、特にハイパー空間の意味的特徴を表現するための手法に関して概説する。

A Semantic Map Approach to a Navigation System for Exploratory Learning in Hyperspace (2)

Mizue KAYAMA Toshio OKAMOTO

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

e-mail: {kayama, okamoto}@ai.is.uec.ac.jp

Abstract : In this paper, we propose a framework based on a sub-symbolic approach for the support of exploratory activities in a hyper space. By using our framework, it is possible to express the semantic feature of whole hyper space and the state of the exploratory activity in topological order. This approach is applied to generate the navigation information for exploratory activity. By using our approach, the space explored is reconstituted automatically by the semantic similarities of the nodes which constitute that space. The exploratory history of the user is expressed quantitatively for evaluating the quality of exploratory activity. This quantitative state is evaluated by 5 indices based on attributions given in hyper space, nodes and links.

1 はじめに

近年、様々な分野においてハイパー構造を有する情報環境（ハイパー環境）を積極的に取り入れようとする機運が高まっている[4]。ハイパー環境では、利用者が自ら情報（知識）を収集、加工、創造し、外界に向けてその情報を発信するという主体的・能動的な活動を実践し、その一連の活動を通して利用者の主体性の増幅を期待するものである。教育の分野において、このような活動は教師から生徒への知識伝達を中心とした教育とは異なる学習形態であり、探求型（探索）学習（Exploratory Learning）と呼ばれる。

本研究は、ハイパー空間内での探求型（探索）学習を支援することを主眼としている。特に、情報収集過程に着目し、学習に行き詰まった学習者に対して、次に選択

することが望ましい情報を提供する機能（ナビゲーション）に関して検討している。これまでに、教育に関する専門家（educators）が有するナビゲーションに関する経験則を抽出し、探索活動の滞りを解消するための助言を与えるシステムを構築してきた[1]。現在、支援効果をより確かなものにするために、探索対象となる情報の意味を考慮したナビゲーション機能の設計・実装を試みている。具体的には、探索活動が展開される世界であるハイパー空間全体の意味的特徴の類似性をサブシンボリックな手法によりモデル化する試みを行っている。生成したモデルに対して探索履歴を写像することで探索状態を表現し、提示するノード候補の集合を絞り込み、ナビゲーションのための情報を選別するものである。本稿では、特にハイパー空間の意味的特徴を表現するための手法に関して概説する。




図 1: ハイパー空間の物理的特徴と意味的特徴

2 研究目的

本研究の目的は、サブシンボリックなアプローチに基づく教育支援システムのフレームワークを提案することを目指し、ハイパー空間の意味的特徴と、ユーザの探索履歴の定量的、および定性的特徴とに基づき、探索活動をナビゲートする機構を実現することである。

この研究目標を達成するためには、システムに対して 3 種の機能を具備する必要がある。

1. ハイパー教材の構成要素により作られるハイパー空間の特徴を把握するための機能
2. ハイパー教材の利用者の探索状態を把握するための機能
3. 利用者に与えるナビゲーション情報を生成するための機能

これらの内、本稿ではハイパー教材の構成要素により作られるハイパー空間の全体構造と特徴を把握するための機能について詳述する。本研究では、ハイパー空間の全体構造を物理的構造と意味的構造との 2 種の観点から捉えるものとする。特に、意味的構造を表現するために構成要素の意味的特徴に基づくハイパー空間の地図という概念を導入する。

3 ハイパー空間の属性

3.1 ハイパー空間の表現

本研究では、ハイパー空間の特徴をより明確に捉えるためにリンクの種類毎にハイパー空間を捉えることとする。図 1 にリンクの種類毎のハイパー空間の概要を示す。

- 教材系列の構成に基づく物理的構造を示すハイパー空間
- コンテンツの意味関係に基づく意味的構造を示すハイパー空間

物理的構造はハイパー教材の設計者が定めた教材系列の構成を元に規定される。書籍等で見られる章・節・項立ての構造と同義である。すなわち、コンテンツの文書階層と閲覧順序を定めた構造と考える。各ノードは




図 2: ハイパー空間の捉え方

系列化されるまとまりであるセクションに分類される。各々のセクション内のノードに重複はないものとする。

意味的構造はハイパー教材を利用する教授者が定めた教材コンテンツの意味関係を元に規定される。コンテンツの種類と他のコンテンツとの関連との 2 種の要素の集合として表現される。各ノードはトピックと称されるカテゴリーに分類される。各々のカテゴリー内のノードには重複はないものとする。個々のノードはそのコンテンツに応じて、コンテンツの種類(事象、現象、性質、属性、機能、名称、手段、概念、設定方法、事例、適用例)が与えられる。物理的構造とは異なり、意味的構造は階層構造を取らない。本研究では意味的構造に位相概念を導入し、構造全体を地図として表現する。

3.2 ハイパー空間構造モデル

図 2 にハイパー空間¹構造モデルと各構成要素の属性を示す。ハイパー空間の属性は、educator(s)²によって定義されたトピックおよびセクションのリスト(名称と一意な ID)、空間に含まれる教材系列構成に関わるノードとリンクのデータベース(名称と一意な ID)、意味構造に関わるノードとリンクのデータベース、そして、委譲関係を表すリンクのデータベースである。

本システムでは、ハイパー空間の構造と定性的/定量的な特徴とを定義可能なモデルを提案する。提案するモデルは、ハイパー空間内のノード間の関係構造を記述するためのテンプレートである。テンプレートにはハイパー空間の構成要素であるノード、リンク、そしてハイパー空間自体の属性が含まれる。educator(s)によって具体値が与えられたテンプレートと学習者の探索履歴から求められるテンプレートの比較により学習者の探索状態が表現される。

4 ハイパー空間の意味的特徴地図

意味関係を表現するために、本研究ではハイパー空間の意味構造モデルを用いる。このモデルは個々のコンテンツの意味関係からハイパー空間の意味的特徴地図を作成する。本手法は、Kohonen の提唱した自己組

¹このハイパー空間は 3 種のリンクを全て含んだ空間である。

²ハイパードキュメントの設計者とハイパードキュメントを教材として利用する教授者を併せた概念とする。




図 3: 特徴地図を作るニューラルネットワークの構造

組織化特徴地図 [3][5] を基礎とする。入力ボタン同士の位相関係を保持したまま 2 次元 (あるいは 3 次元) 空間上にそれぞれ写像する機能を、すべてのノードの意味関係からハイパー空間の地図を作成することに適用する。この結果、個々のノードの意味的な類似性を保持したハイパー空間の地図が得られる。この地図をハイパー空間の意味的特徴地図 (Semantic Feature Map) と称する。地図が形成されるニューラルネットワークの構造を図 3 に示す。作成された意味地図は、利用者の探索活動モデルの構築、ナビゲーション情報の生成に利用される。

4.1 学習アルゴリズムの拡張

一般に近傍学習では、勝者ユニットの周辺に似た重みをもつユニットが存在するために、他のクラスタリング手法と比較し、分類性能が高くはない [2]。そこで、本研究では、全てのユニットを勝者ユニットの近傍として含める初期学習過程を設けた学習と学習後の重みの類似性に基づく出力ユニットの再構成を行うことで、意味的構造を表現する際の精度の改善 / 向上を試みる。学習則を改良した結果、入力パタンのベクトルの特徴を地図の構成により反映させることが可能になる。

本研究では、Kohonen の自己組織化特徴地図を作成するための学習則に対して、以下の 2 点の拡張を提案している。

- 競合の勝者ユニットからの距離に応じた重み修正をおこなう近傍学習
- 重みの類似度に基づく出力ユニットの再構成

4.1.1 初期学習期間の設定

学習の過程は次の 3 段階に整理される。1) 全てのユニットが勝者の近傍にふくまれる場合、2) 一部のユニットが近傍に含まれる場合、3) 近傍のユニットはなく勝者のみの場合。この中で 1) の過程での重みの変化は、以後の学習に対して与える影響が大きい。本研究では、重み初期値の影響をなくし、訓練パタンの特徴を反映させた分類カテゴリーを形成するために、本研究では初期学習時において、次の 2 つの拡張をおこなった。

- 重み初期値の統一化
- 全ユニットが勝者の近傍に含まれる期間の設置

この前提のもとで w_{ij} の理想解を求める。入力パターンが $\mathbf{x}^k$ であり、 i 番目の出力ユニットが勝者となる確率を $P(i|\mathbf{x}^k)$ とすると、入力パタンの各要素は次のように表される。

$$\sum_k x_j^k P(i|\mathbf{x}^k) P(\mathbf{x}^k) \quad (1)$$

$\mathbf{x} \in \{0, 1\}$ であるので、 $\mathbf{x}^k$ のうち値が 1 である要素 j のみが有効となり、式 (1) は次のように整理される。

$$\sum_k x_j^k P(i|\mathbf{x}^k) P(\mathbf{x}^k) = P(x_j^k = 1|i) \quad (2)$$

初期学習時、全てのユニットが勝者と同じ重み変化量加えられる。その結果、全てのユニットの重みは同じ値を持つ。勝者ユニットの重みの理想解を求めることは全てのユニットの重みを求めることと同値である。以下、初期学習過程における勝者ユニットの重みの変化に着目し、その変化を示す。初期学習での勝者ユニットは全ての訓練パターンに対して、常に同一のユニットであることから、重みの理想値は次のように整理される。

$$w_{ij} = \frac{\sum_k x_j^k P(i|\mathbf{x}^k) P(\mathbf{x}^k)}{\sum_k P(i|\mathbf{x}^k) P(\mathbf{x}^k)} \quad (3)$$

また、全ての訓練パターンに対してユニット i が勝者となることから式 (3) の分母の条件付き確率は 1 となる。

$$\sum_k P(i|\mathbf{x}^k) P(\mathbf{x}^k) = 1 \quad (4)$$

式 (4) を式 (3) に代入すると w_{ij} は次のように整理される。

$$w_{ij} = \sum_k x_j^k P(i|\mathbf{x}^k) P(\mathbf{x}^k) \quad (5)$$

この結果、学習後の重み値は以下のようになることが導かれる。

$$w_{ij} = P(x_j^k = 1) \quad (6)$$

これは、全ての訓練パターンにおける当該要素での “1” の出現確率である。すなわち、全てのユニットが勝者の近傍に位置する機会を設けることで、重み値に訓練パタンの特徴が反映するといえる。初期学習の期間を充分に取ることで、実際の重みが重みの理想値である式 (6) に近づくことになる。

4.1.2 出力ユニットの再構成

学習後の重み値を再構成することにより、地図を解釈する際に用いる縮尺を複数段階に設定することが可能となる。分類性能向上の為に、分類カテゴリーの境界やその周辺に位置するパターンを明確に分類する必要がある。なぜならば、近傍学習では入力データの存在しえない場所にカテゴリーが作られるからである。そのために、学習された重みの類似度に基づいて出力層内のユニットを統合する。

$$w_{ij}^2 = \begin{cases} 1 & \text{if } w_{ij}^1 \geq p(w_{ij}^1 = 1) \\ 0 & \text{if } w_{ij}^1 < p(w_{ij}^1 = 1) \end{cases} \quad (7)$$

最終学習時に勝者であったユニットの重みは、分類カテゴリーを表す。それぞれのユニットは、学習した全てのデータの影響を均等に受ける。入力パターンは 0, 1 の 2 値ベクトルであることから、重みを入力データ中、その要素が“1”である確率を閾値とし変換する。その結果、各ユニットが学習した（もしくはボタンが提示された際に勝者となり得る）ボタンの特徴を捉えることができる。2 値化した結果、勝者と同じ重みをもつ非勝者ユニットは勝者と結合する。これにより、1 つのカテゴリーが複数のユニットにより表現されることになる。必ずしも訓練ボタンと一致しなくとも、同じ特徴をもつボタンであれば、勝者ユニットに反応するため、入力ボタンに対する分類精度の向上が期待される。

4.2 意味的特徴地図

前述の改良を施した学習則を適用することでハイパー空間の意味的特徴地図を作成する。この特徴地図を探索学習支援、ひいてはナビゲーション情報の生成に利用した場合、次のような利点が期待される。

1 点目として、学習の結果得られる地図上の個々の（出力層の）ユニットは、類似する意味関係を有するノード（集合）に対応するようになる。すなわち、個々のノードは各意味的特徴の類似性を地図上の全方向において保ちながら配置される。これにより、ナビゲーション情報の提示を要求した利用者が現在居るノード（カレントノード）に対して、類似しているノードは地図上の近傍領域に位置することとなり、容易に探索することが可能となる。また、探索履歴を地図上に写像することで探索の洩れや冗長な箇所等が明確になる。

2 点目として、学習後の地図の重みを再構成することにより、地図上に個々のノードのみならず、educator(s) が設定したトピックが分類カテゴリーとして得られることが期待される。重みベクトルの類似性のみからシステムが自動的に再構成した後、educator(s) により確認・修正されることで特徴地図がより精巧でかつ妥当なものとなる。図 4 に出力ユニットの再構成の概略を示す。

また、地図作成後の重み値はノード（あるいはトピック）の意味的特徴（ベクトル）の類似値となる。その結果、あるノードの特徴ベクトルを学習後の地図へ写像した場合、入力ベクトルと重み値との荷重和は、当該ノードが各ユニットに写像される確率を示すことになり、容易に地図上でそのノードの意味的な特徴を特定することが可能となる。




図 4: 意味的特徴地図への複数の解釈

5 おわりに

本稿では、探索学習支援に対する本研究のアプローチを示し、ハイパー空間構造モデル、およびハイパー空間の意味的な特徴地図の作成手法と意味的特徴地図を作成する意義に関して詳述した。ハイパー空間を物理的構成の観点と意味的構成の観点からモデル化することで、1 つの教材を特徴を複数の視点から表現することが可能になる。また、意味的構造のハイパー空間モデルとしての意味的特徴地図を作成することで、educator(s) が意識し得なかったノード間の類似性、ひいてはトピック間の類似性を表現することが可能となる。これらの成果により、システムが生成するナビゲーション情報の妥当性や適切性を向上させることが期待される。

しかし、意味的特徴地図の精度は、地図を作成する際に与える訓練ボタンに影響される。訓練ボタンはハイパー空間内のノードの意味的な特徴を表現したベクトルである。すなわち、このベクトルボタンの構成の仕方は、利用者へ与えるナビゲーション情報を生成する過程までを考慮して決められねばならない。今後の詳細な検討を要する事柄である。

参考文献

- [1] 香山瑞恵, 岡本敏雄: “ニューラルネットワークを用いたハイパー空間のナビゲーションに関する研究 s”, 教育システム情報学会, Vol.15, No.2, pp.75 - 84 (1998).
- [2] Hassoum, M.H.: “Fundamentals of artificial neural networks”, MIT press, Massachusetts (1995).
- [3] Kohonen, T.: “Self Organizing Maps”, Springer-Verlag, Berlin (1995).
- [4] Nielsen, J.: “Hypertext and Hypermedia”, Academic Press, San Diego (1990).
- [5] Steven, A., H., Tariq, S., & Michael, V.: “Modeling student knowledge with self-organizing feature maps”, IEEE Trans. of system man and cybernetics, Vol.25, No.5, 1995.