

概念学習における 事例収集のための知識循環モデルの構築

山本 匡[†] 坂間 千秋^{††}

本研究では近年 Web 上に見られるようになった「物当てゲーム」の知識循環性と概念の事例収集特性に着目し、このゲームを概念学習における事例収集のために用いる方法を提案する。本システムの特徴は、過去のゲーム結果から概念を学習し、その結果を新たな概念の学習に利用できることである。また、多くの人にプレイされることにより、獲得される概念が平均化される「集合知特性」を持つ。実験の結果、本システムではゲームを繰り返すことにより概念学習が行われ、ゲーム効率が向上することが確かめられた。

Building a knowledge circulation model for collecting cases in conceptual learning

Takumi Yamamoto[†] and Chiaki Sakama^{††}

In this research, we propose a method of using a “read your mind” game on the Web for collecting cases in conceptual learning. The game has the property of knowledge circulation which uses the results of games for future learning. It can also collect cases effectively on the Web by using the wisdom of crowds. We build an experimental system and verify that the system learns concepts by playing games and improves its performance.

1. はじめに

機械学習における概念は、概念学習により獲得される。具体的には、「リンゴ」という概念をコンピュータに理解させるためには、リンゴに関する複数の事例を与え、そこから「赤い、甘い、果物」といった性質を帰納することでリンゴという概念が学習される。一方、概念学習のために必要な事例を効率的に集めるための手法についてはこれまであまり研究が行われていない。

例えば、上原[5]らの研究では、事例を典型性に基づいて分類する手法が提案されているが、事例自体の収集方法については述べられていない。

収集方法として考えられる、人手による事例の入力は効率的とはいえず、事例を入力するユーザによって偏った概念が学習されることも考えられる。

小島[7]らの研究では、国語辞典の見出し語を元に関連度を計算することで、国語辞典を元に概念の集合体である概念ベースを構築する手法が述べられているが、どうしても説明的な意味に偏り、人の感覚に近い概念を構築するためには別の手法で事例を獲得する必要がある。

また、辻[8]らの研究では Web の検索エンジンを用いたヒット数による概念同士の関連を元に、新たな概念を構築する手法が述べられているが、これも同じく説明的な意味に近くなってしまいう上に検索のヒット数で概念を近似する以上の学習は行えない。

そこで本研究では複数のユーザから平均的な事例を効率的に収集するための方法として、近年 Web 上で人気を博している「物当てゲーム」に注目し、ユーザからゲーム感覚で事例を収集するための方法を考える。本システムの特徴は、システムが過去のゲーム結果から概念を学習し、その結果を新たな概念の学習に利用できることである。このことにより、システムはゲームを繰り返すことにより効率良く学習が行えるようになる。また、物当てゲームは Web 上に公開されている場合、多くの人にプレイされるため、学習結果は平均的な概念となり良質の知識が得られることが期待される。本研究では、「物当てゲーム」のシステムを実際に構築、事例収集を効率的に行うことができるかどうかを実験により検証した。

本稿の構成は以下の通りである。2 章では物当てゲームについて紹介し、その特徴について考察する。3 章で本研究で構築する物当てゲームシステムの概要を説明する。4 章で本システムを用いた実験結果と考察を述べ、5 章で本稿のまとめと今後の課題について述べる。

[†] 和歌山大学大学院システム工学研究科
Wakayama Univ. Graduate School of Systems Engineering

^{††} 和歌山大学システム工学部
Wakayama Univ. Faculty of Systems Engineering

2. 物当てゲーム

2.1 物当てゲームの構成

「物当てゲーム」は古くから人間の間で親しまれてきたゲームで、近年その一方をコンピュータが担当する形で Web 上に見られるようになってきている。

Web 上の物当てゲームの代表例としては物当てゲーム 20Q[1]や人物当てゲーム Akinator[2]が挙げられ、それぞれプレイヤーが想像した「物」や「人物」をコンピュータが当てるゲームとなっている。

一般的な物当てゲームの構成を図 1 に示す。




図 1 物当てゲームの構成

プレイヤーはまず、自分の中で「答え」となる概念を 1 つ想像する。これはゲームが対象とする分野（物や人物）の中であれば何でもよい。次に、物当てゲームのシステムはプレイヤーが想像した概念が何であるかを推測するヒントを得るために質問を行う。プレイヤーがこの質問に返答する事でシステムは概念を推測するための情報を蓄えていく。最終的に十分な数の質問を行い、プレイヤーの想像する概念が推測できた段階で、システムはその結果を提示する。推測結果が的中していればそこでゲームは終了するし、もし間違っていたならば継続して質問を行い更にヒントを得ようとするか、正しい結果をプレイヤーに教えてもらい、次回以降のゲームに活かすための学習を行う。

2.2 物当てゲームの特性

物当てゲームには、その特徴からいくつかの有用な特性がある。一般的に物当てゲームにおいて、最も重要となるのは「過去のゲーム結果」からの学習である。システムはこれまでに行われたゲームの結果、主に「概念や、それに対する質問の返答」などを蓄積しておくことで、新たに行うゲームにおいて過去のデータに基づいた概念の推測を行っている。つまり、ゲームが多く繰り返されるとそれだけ学習が進み、以降のゲームにおいてプレイヤーの想像する概念の的中率が高く、行われる質問も少ない

優秀なシステムが学習により構築されていく。過去のゲームの経験を元に新たなゲームを行い、自身の能力を向上させていくシステムは、能力の向上により性能が上がる。とさらに多くの人々がゲームをプレイするようになる。これが更なる学習機会となり、その後、システムは連鎖的に性能が向上していく可能性がある。このように物当てゲームには一旦学習した概念をさらなる概念の学習に使うことができる特性があるため、一種の「知識循環システム」と考えることができる。

また、物当てゲームは Web 上に公開されている場合、多くの人々にプレイされる。このことにより、ゲームの結果獲得される概念は偏りのない平均的なものになることが期待され、母体が広い良質な知識が得られると考えられる。このことから、物当てゲームは「集合知的特性[5]」も併せ持つと考えることができる。

2.3 物当てゲームの事例収集性

物当てゲームが概念学習において用いられる事例の収集に適している理由は以下の通りである。ゲームの結果得られるのは「プレイヤーが何を想像し、それに対する質問にどのように返答したか」というデータである。本来はこれを次回以降のゲームに活かすのだが、別の側面からこのデータを捉えると、多くの概念に対する質問の返答のデータと考える事ができる。例えばプレイヤーが「リンゴ」という概念を想像しゲームに望み、「赤いものですか?」や「甘いものですか?」という質問がゲーム中で行われているのなら、最終的に得られるゲーム結果は概念の「事例」に他ならない。

さらに物当てゲームには事例収集性があるだけでなく、前述したようなシステムの知識循環性や、集合知的特性も持っているため、物当てゲームを概念学習のための事例の獲得に利用することで効率的に多くの事例が得られる可能性があると考えられる。

3. 物当てゲームシステムの構築

3.1 構築方法

インターネット上の物当てゲームはその中身がブラックボックスであるため、本研究では物当てゲームの実験システムを実際に構築し、そのシステムを使った事例収集の実験を行うことにする。本研究では以下の方法で物当てゲームシステムを構築する。

物当てゲームは現在のゲームで得られているプレイヤーの返答と、過去のゲーム結果のうち最も近いものを判断し、その際の概念の情報を元に現在のゲームを運営する。ゲーム自体にデータマイニングやデータマッチング的側面が強く見られるため、本システムでもこれらの技術を応用する。具体的には過去の事例に比重を大きく置いて現在の状況判断を行う「事例ベース推論」およびその手法である「分類木」を使ってシステム構築する。

3.2 分類木

分類木は決定木の一種であり、木構造状のデータを持ち、木構造中の葉ノードに位置する概念の特徴をその葉ノードまでのパスによって示すものである。

今、例として下に挙げるような4種の概念とそれに対する質問の返答の表があったとする。

表 1 概念4種のデータ

概念名	木になるか?	赤いか?	果物か?
リンゴ	YES	YES	YES
イチゴ	NO	YES	YES
レモン	YES	NO	YES
トマト	NO	YES	NO

この表を元に構成された分類木の一例は図 2 のようになる。




図 2 表 1 より作られる分類木の一例

分類木は一般的に最下層の葉ノードに位置する概念の特徴をそこに至るパスにより示し、別の概念との差異がどの部分にあるかを明確にして事例の分類を行うためのものであるが、この木構造を最上段の根ノードからたどり、現在のノードが持つ質問を問い掛ける事で得られた返答の枝をたどるように用いると、簡単な物当てゲームが行える事がわかる。また、古くから存在する「アニマル[3]」と呼ばれる動物当てゲームプログラムでも似たような手法が用いられている事からも、分類木は物当てゲームと親和性があるといえる。

実際のシステムでは、この考え方を基本に従来の構築法では円滑に処理できなかった、より多くの概念、より多くの問い掛けられる質問の候補を持ったデータでもゲームが行えるように改良していく。

3.3 ゲームの方法

本システムにおける物当てゲームは、以下のルールに従ってプレイされる。

- ・プレイヤーは概念を1つ想像し、ゲームに臨む。
- ・システムはプレイヤーに対し質問を行い、プレイヤーはそれに返答する。
- ・質問は「はい・いいえ」で返答可能な質問とする。
- ・ただし返答は「多分はい・わからない・多分いいえ」も許される。
- ・数回の質問の後、システムはプレイヤーの想像する概念を推測し提示する。
- ・プレイヤーは推測結果が的中したかどうかを答え、推測結果が間違っていた場合は継続して質問を行うか、間違いを訂正しゲームを終了する。

3.4 システムの概要

本システムでは、過去のゲーム結果を元に、ゲームを運用するための知識を構築し、ゲームの運営を行っていく。システムの概要は以下の通りである。

システムは質問に対する返答を得る中で、過去のゲーム結果を元に適合しない概念を候補から削っていく事で、最終的にプレイヤーが行った返答に最も合致する概念を候補の中から探し出し、それを提示する形で推測を行う。

また、物当てゲームシステムがゲームという娯楽性を持ってプレイヤーの興味を引き、ゲームを行う機会を増やしていることから、推測に要する質問は可能な限り少なく、その上で推測結果の的中率を高めていかなければならない。このために本システムでは質問の選択には分類木の構築手法の一つで、確率的に質問数が最も少なくなる木を作る ID3 アルゴリズム[4]をシステムに合致する形で改変し、問い掛ける質問を選択する部分を構築している。ID3 アルゴリズムにより質問ごとに推測の進みややすさを期待値で求める事ができるため、返答の状況などにより削られた概念の候補を元に、その都度最も推測が進みやすい質問を問い掛ける事ができる。

構成されたシステムは確率的手法に基づきながら、毎回のゲームで最も中する確率が高くなるように質問を選択し、推測を行っている。数多くの人々が、数多くの概念を想像しプレイする物当てゲームにおいては、このような手法が効果的であると予想される。

3.5 質問の「専門性」

前節で述べたように、システムは確率的に質問を選択し、プレイヤーの多様性をカバーしようとしている。一方、ゲームによっては、単純に確率的な手法により質問を選択することが適当ではない場合がある。

例えば、プレイヤーが想像した都道府県を当てるゲームを考える。もしプレイヤーが想像する都道府県をすべての都道府県から等確率で選ぶとするならば、最初に問い

掛ける質問は、推測すべき都道府県の候補を二分する質問、例えば「県庁所在は北緯35度線より北にあるか」といった質問が考えられる。この質問にプレイヤーが的確に答える事ができれば推測は最も大きく進むが、県庁所在地の緯度を知っているプレイヤーはごく少ないと考えられるので、ほとんどの人が「わからない」と返答すると予想される。

逆に「その県はどちらかという北にあるか?」といった、概念をあいまいに二分する質問ならば、多くの人が無回答を行ってくれるが、関東地方のように中心付近にある県についてはあやふやな返答が多くなり、全体として無回答の割合が高くなるが、推測はあまり進まないことが予想される。

このように、質問には単純な分類能力だけでなく、その「答えやすさ」という要素も重要であると考えられる。

これを本研究では質問の「専門性」と名付け、問いかける質問を選択する場面においてプレイヤーの持つ知識に合致すると考えられる質問を選ぶ事で返答を上手く引き出し、確率的な手法以上の効果を挙げると期待される。

質問を、返答が得られるかどうかと、推測が進むかどうかの二つの次元で整理したものが図3である。ここで、縦軸は返答が得られる割合の高低を、横軸は返答によって推測が進む度合いの高低を表す。




図3 質問の分類

ゲーム中で問いかけられる質問は全て、過去の返答結果によりこの枠内のどこかに位置すると考えられる。①の軸で左上に行くほど返答が得られやすく、得られた際に推測が進みやすい、つまり最も問いかけるべき質問が左上に位置し、右下には逆に問いかけるべきでない、質問機会を無駄にしてしまう質問が位置する。一方、②の軸は右上には、返答は得られやすいが、得られた際にあまり推測が進まない質問、つまり多くの人々が答えられるが、あまり問いかける価値がない「専門的でない質問」が位置し、左下には逆になかなか返答は得られないが、得られた際の推測の進み具合は大きい質問、つまり問いかける価値は高いが、中々それに答えることのできる人がいない「専門的な質問」が位置する。

①の軸はこれまでの確率的な手法で質問選択を行う際に用いていた軸で、単純に推測の進み具合とその返答が得られる確率を乗算した期待値を元にプレイヤーに質問を問いかけるための軸である。

ここに、②の軸による専門性の概念を導入することにより、基本的には①の軸を中心に考え枠内で左上に位置しながらも、プレイヤーが持つ返答のための知識があいまいだと判断した場合は、比較的右上に近い質問を問い掛けることで、プレイヤーから少しでも何らかの形で返答を引き出し、推測に活かすようにする。逆にプレイヤーの知識が豊富だと判断される場合は、答えられる人は少ないが、返答が得られた際には推測が大きく進む左下に位置する質問を問いかけ、それにプレイヤーが専門的な知識をもって答える事を期待し、結果的に推測を大きく進めようとする。

物当てゲームでは質問が一つずつ行われるため、そこからプレイヤーの持つ知識の度合いを徐々に把握し、中盤・終盤の質問選択に活かす事ができる。この特性を上手く利用することで、専門的な知識を持つプレイヤー、あいまいな知識しか持たないプレイヤー両方に対し、概念推測に要する質問数の低減や、概念的な中率を向上させる事が可能になる。

専門性を導入した質問選択手法は以下の通り。

- ・五つの異なる返答に以下のように「返答値」を定める。
はい:1.0, 多分はい:0.7, わからない:0.0, 多分いいえ:-0.7, いいえ:-1.0
肯定は正、否定は負とし、0に近いほどあいまいな返答とする。
- ・ある質問に対する過去のプレイヤーの返答値 R_i の平均を、概念ごとに計算する。
概念 c の質問 q に対する平均返答値 A_{cq} は n 回のゲーム結果があった際に

$$A_{cq} = \frac{\sum_{i=1}^n R_i}{n}$$

で求められる。これを全ての c, q について計算しておく。

- ・現在のプレイヤー k の持つ専門性の度合い P_k を以下のように求める。
 質問 q に対し R_k という返答値を持つ返答を行った際に
 R_k と A_{cq} が同符号（肯定・否定の属性が同じ）となる全ての概念 c を対象として

$$P_k = \sum_c (|R_k| - |A_{cq}|)$$

- ・ $P_k > 0$ の時、プレイヤー k の返答値は平均返答値よりも「はい」「いいえ」の割合が高いと考えられ、この場合プレイヤー k は他のプレイヤーと比較して専門的な知識を持っていると考えられる。逆に、 $P_k < 0$ の時は、プレイヤー k の返答値は平均返答値よりも「はい」「いいえ」の割合が低いと考えられ、この場合プレイヤー k は他のプレイヤーと比較してあいまいな知識しか持っていないことが判断できる。

P_k は質問の度に加算されていくため、質問が繰り返されるにつれプレイヤー k の持つ知識の専門性が明らかになる。

この手法により得られたプレイヤーの専門性を質問選択に活かすため、問い掛けるべき質問の候補を、確率的手法であるID3アルゴリズムを返答値という数値に対して適用できるように改変した応用手法により求め、推測を進める能力の期待値が高い質問の上位数問を選定する。それらの質問ごとに過去のゲーム結果からプレイヤーが質問に対し行った返答のバラつき度合いを返答値から求めた分散という形で計算し、概念ごとに求めた分散の平均を求める事で、最終的に質問そのものの分散が判断できる。

この値は、誰もが同じ返答をする質問は小さく、人により返答がまちまちになる質問では大きくなるため、 P_k を重みとして質問ごとの分散に乗算した値を用いる事により、ある質問がプレイヤーが答えやすいものか、答えにくいものであるか、という判断を重視した、専門性をふまえた質問選択が行える。

プレイヤーが専門的な知識を持っていれば、分散に正の値が乗算されるため、より返答が人によってまちまちな、専門的な知識を返答に要する質問が選ばれる。プレイヤーがあいまいな知識しか持たない場合は、分散に負の値が乗算されるので、よりバラツキの少ない、答える事自体は比較的容易な質問が選ばれやすくなる。

4. 実験

4.1 システムの検証

構築したシステムの物当てゲーム機能を検証するために、人間プレイヤーのかわりにゲームを行うエージェントプログラムを用いて、物当てゲームのシミュレーション実験を行った。

ゲームにあたりプレイヤーが想像する物として選ばれる候補となる概念を50個と、それに対して行われる100の質問を想定し、それぞれの質問についてエージェントが行う返答も予め決定し用意しておく。

本来50程度の概念候補であれば、はい・いいえでちょうどそれらを二分する質問を用いればわずか数問で分類が行えるが、質問を多く用意することで、適切に推測が進みやすい質問を選び問いかけているかどうかを確認する事ができ、質問の専門性の違いによる多様性を持たせることにも繋がる。なお、ここでの実験に用いるシステムは3.5節で述べた専門性のアルゴリズムは導入していない。専門性に関する検証は次節で行うこととする。

また、本システムにおいてエージェントが質問に対し行う事のできる返答は「はい・多分はい・わからない・多分いいえ・いいえ」の5種類であるため、行う返答に「はい・いいえ」が多く、質問に対しはっきりとした返答が可能な、専門的な知識を持つエージェントAと、それと比較してあいまいな知識しか持たず「多分はい・わからない・多分いいえ」の返答が多いエージェントBを考える。

最初に、エージェントAは表2の上の行に示す確率でランダムに返答を生成し、ゲーム中に質問を問いかけられた際の返答を、想像する概念ごとにあらかじめ決定しておき、ゲーム中に質問が行われた際に返答するための知識を作成する。また、エージェントAの返答から、「はい」「いいえ」に該当する返答のうち半分をそれぞれ「多分はい」「多分いいえ」に、「多分はい」「多分いいえ」に該当する返答のうち半分を「わからない」に変化させることで、エージェントBの返答が結果的に表2の下の行のような確率に沿って形成される。これは概念に対する返答の共通見解を保ちつつ、返答のあいまいさを持たせる処理である。

これにより、エージェントAは質問に対し「はい・いいえ」といったはっきりとした返答を多く行うため、概念の推測に要する質問数は少なくなる。一方エージェントBは「多分はい・多分いいえ」といったあいまいな返答が多く、時には「わからない」という推測のための情報が一切得られない返答が行われる事も多いため、概念の推測にはより多くの質問を要すると考えられる。

表2 エージェントA,Bそれぞれの返答の割合

	はい	多分はい	わからない	多分いいえ	いいえ
A	30%	10%	20%	10%	30%
B	15%	20%	30%	20%	15%

以上のような条件に沿ってゲーム中に行われる質問に対し、自らの想像する概念ごとに用意された返答ができる知識を持つエージェントが、全くゲーム結果を保存していない状況にあるシステムに対し物当てゲームを行う。

実験では 1000 回のゲームを通じてシステムが適切にゲーム結果から学習を行い、概念推測の的中率を高める事ができているかを確認する。

ゲーム中の推測結果を提示する質問回数については、概念数が 50 個であることから、分類に最低必要である 6 問目の質問を行った後で 1 回目の概念推測を、1 回目で推測が的中しなかった場合には 10 問目まで質問を継続し、再度概念推測を行うようにしている。なお、10 問目での推測にも失敗した場合はそこでゲームは終了する。

各エージェントは 50 個の概念のうちから毎回ランダムに自分の想像する概念を選択し、行われる質問に対し自身の持つ知識に沿った返答していくことで仮想的にゲームを行っていく。

各エージェントは全くゲーム結果が蓄積されていないシステムに対し、それぞれ 1000 回ゲームを行う、100 回の区間ごとに概念推測が的中した回数をカウントした結果は次のようになった。




図 4 ゲーム成績のグラフ

表 3 各エージェントのゲームの成績

区間	1 ~ 100	101 ~ 200	201 ~ 300	301 ~ 400	401 ~ 500	501 ~ 600	601 ~ 700	701 ~ 800	801 ~ 900	901 ~ 1000
A 的中数	55	91	98	95	97	99	100	98	96	100
B 的中数	41	64	86	85	90	92	93	94	100	100

エージェント A はゲーム中、質問に対しはっきりとした推測が進みやすい返答を多く行っているため、ゲームを繰り返し、学習が進みにつれ推測結果が的中するゲームが著しく増えている。ゲーム終了までにかかる質問回数の平均は 6.76 回と最小の質問数である 6 回に近く、システムが推測に効果的な質問を選んでいる事が伺える。

エージェント B はエージェント A に比べあいまいな返答を行うが、それでもうまく返答を汲み取る事で、ゆるやかにではあるが学習が進行しており、最終的な区間ごとの的中率はエージェント A とほぼ同じにまでなった。ゲーム終了までにかかる質問数の平均は 7.46 回と多めになっているが、推測が行われゲームが終了するのは質問数が 6 回または 10 回の時なので、ある程度早い段階で推測はできていると考えられる。

2 つの実験により、エージェントによって知識に差がある場合でも、本システムは的確に学習を行い、最終的に概念推測の的中率を高くできることが示された。

4.2 質問の専門性を考慮したケースの検証

続いて 3.5 節で述べた、質問の専門性を判断しプレイヤーの専門性に合った質問を問いつける手法について実験を行う。実験では、前節で用意したエージェント 2 体が事前に繰り返し十分なゲームを行い、質問の専門性の判断に用いるための、返答の差異に関する情報が充分蓄えられたシステムを用意しておく。このようなシステムに対し複数のエージェントがゲームを行い、質問選択に専門性に関する手法を導入した時とそうでない場合とで、「概念推測の的中数」と「的中に要する平均質問数」の 2 つを比較する。プレイヤーの専門性を的確に判定し、うまく質問を問いかけることができていれば、推測の的中率は専門性の手法を導入する前と比べ上昇し、的中に要する質問数は少なくなると考えられる。

十分に知識が蓄えられたシステムに対し、専門的な知識を持つエージェント A が 1000 回のゲームを行った結果は以下ようになった。

表 4 エージェント A による専門性の比較

	的中数	質問数
専門性なし	1000	6.80
専門性あり	1000	6.74

十分な学習が行えていたため、的中数に関しては専門性を導入しない質問選択方式でも、100%の的中率が得られた、的中に要する平均質問数に関してはわずかに減りつつはあるが低減が見られる。

続いて、エージェント A と比較してあいまいな知識しか持たないエージェント B が同じ学習状態のシステムでのゲームと同じく 1000 回臨んだ結果を以下に示す。

表 5 エージェント B による専門性の比較

	的中数	質問数
専門性なし	980	7.07
専門性あり	1000	6.84

専門性を導入しない質問選択方式の場合、的中率は 100%に満たなかったが、専門性を導入した事で、的中率を 100%まで上げる事ができた。また、的中までに要する平均質問数に関しても 0.23 問低減しており、エージェント B の知識に応じて比較的答えやすい質問を選び問い掛けることで上手く返答を引き出し、推測に要する質問数を少なくしている事が確認できる。

専門的な知識を持つエージェント A の結果によると、専門的な知識を持っているプレイヤーから、推測に役立つ知識を引き出す機能では大きい成果を上げる事はできなかったと言える。逆に、あいまいな知識しか持たないエージェント B の結果によると、あいまいな知識しか持たないプレイヤーの専門性に合わせて、答えやすい質問を選び出し問いかけることで、的中率の向上、的中に要する平均質問数の削減につながる事ができたとと言える。

5. 結論

本研究では物当てゲームシステムに基づく、事例収集の方法について述べた。本システムの特徴は、過去のゲーム結果を新たなゲームにおいて利用する知識循環性にある。物当てゲームにおける質問選択の場面では、確率的手法に基づく分類木に「質問の専門性」を考慮し、プレイヤーから最も効果的な返答を得るためのしくみを導入した。実験の結果、質問の専門性を考慮した質問選択方式では、より少ない質問数で物当ての的中率が上がることが確認できた。

今後の課題として、専門性をどれだけの比重で質問選択の際に活かすかの判断方法が挙げられる。現在は手で設定しているが、将来的には全体の専門性・質問ごとに持つ分類能力から自動的に比重を調整する手法を確立できれば、より実践的な手法が構築する事が可能だと思われる。また、本システムをオープンな環境に置いた際に、本システムの特徴である集合知特性がみられるかどうかや、実際のアプリケーションで本システムが事例収集に有効であることを確かめる必要がある。

参考文献

- 1) 20Q.net <http://www.20q.net/>
- 2) Akinator, the Web Genius <http://en.akinator.com/>
- 3) アニマル!! の巻 <http://www.bsddiary.net/d/20050602.html>
- 4) J.R. キンラン:AI によるデータ解析, トッパン, (1995)
- 5) 上原 邦昭, 谷澤 正幸, 前川 禎男:典型性に基づく概念学習アルゴリズム, 情報処理学会論文誌, Vol.35, No.10, pp.1988-1997, (1994)
- 6) 大向 一輝:Web2.0 と集合知, 情報処理, Vol.47, No.11, pp.1214-1221, (2006)
- 7) 小島 一秀, 渡部 広一, 河岡 司:常識判断のための概念ベース構成法:概念間論理関係を用いた概念属性の重み決定法, 人工知能と知識処理, Vol.100, No.709, pp.57-64, (2001)
- 8) 辻 泰希, 渡部 広一, 河岡 司:www を用いた概念ベースにない新概念およびその属性獲得手法, 人工知能学会, 第 18 回, 2D1-01, (2004)