

e-Learning システムにおける学習意欲向上の検討 ～ナイーブベイズ法を用いた出題問題の種類別分類～

小林 美緒[†] 瀬沼 航太郎[†] 宮川 裕介[†] 泉 隆[†]

日本大学[†]

1. まえがき

近年、e-Learning システムが広く利用されている。しかし、システムの利用頻度は学習者の学習意欲に依存するという問題点がある。

そこで、本研究では学習者の学習意欲向上を目的とし、「対象試験の出題問題の種類を考慮した評価」を提案する。これにより、既存の評価方法^[1]よりも詳細な評価を行うことができ、学習者の学習意欲向上に繋がると考える。

本報告では、ナイーブベイズ法を用いた対象試験問題の種類別分類について検討したので報告する。

2. 対象試験問題の特徴

2.1 種類の定義

本研究で対象とするのは基本情報技術者試験^[2]である。ここで出題される問題は、経験より「知識型」、「計算型」、「思考型」の3種類に分類できる^[1]。その種類と定義を表1に示す。

表1 種類による分類

種類	定義
知識型	知識のみで解答できる問題
計算型	数値を使った計算問題
思考型	知識に加え思考が必要な問題

2.2 経験により発見した特徴

表1に示した種類には、問題文の長さ、問題文の問い方、選択肢、分野により特徴が現れる。これらは問題を分析していく過程で経験的に発見した特徴である。

2.3 形態素解析により得た特徴

形態素解析とは、自然言語の文字列を形態素と呼ばれる意味のある最小の文字列まで分割し、それぞれの品詞を判別することである。本報告では対象試験問題に対して形態素解析を行い、得られた形態素を特徴とする。

3. ナイーブベイズ法による分類^[3]

ナイーブベイズ法は、式(1)のベイズの定理を利用している。

$$P(c|d) = \frac{P(c)P(d|c)}{P(d)} \propto P(c)P(d|c) \quad (1)$$

$P(c)$ はクラス c である確率で、訓練文書の総数に対し、クラス c に属する訓練文書数の割合を表す。

$P(d|c)$ はクラス c が与えられたときに文書 d が生成される確率を表しており、式(2)から求められる。

$$P(d|c) = \prod_{i=1}^k P(w_i|c) = \prod_{i=1}^k \frac{n_{w_i,c}}{\sum_w n_{w,c}} \quad (2)$$

$P(w_i|c)$ はクラスが c であるときに単語 w_i が選ばれる確率、 $n_{w_i,c}$ はクラス c に属する訓練文書における単語 w_i の出現回数である。

以上から、 $P(c|d)$ を各クラスについて求め、確率が最大となったクラスを分類先とする。

本報告では、文書に対象試験の問題、クラスに知識・計算・思考の種類、単語に2章で示した対象試験の特徴を対応させる。

4. 情報利得による特徴の選択^[3]

出現確率に偏りがない特徴は、分類に悪影響を及ぼすため、取り除く必要がある。そこで、情報利得を用いて取り除く特徴を決定する。

特徴 w の情報利得 $IG(w)$ は「エントロピー $H(C)$ の平均的な減少量」として式(3)のように定義される。

$$IG(w) = H(C) - (P(X_w = 1)H(C|X_w = 1) + P(X_w = 0)H(C|X_w = 0)) \quad (3)$$

$X_w = 1$ は特徴 w が出現した場合、 $X_w = 0$ は特徴 w が出現しなかった場合とする。

$IG(w)$ の値が大きいほど曖昧さがなくなり、クラスを特定できる有効な特徴になる。

5. 実験

5.1 実験項目

2章で示した特徴と3章で示したナイーブベイズ法を用いて以下の実験を行った。

(1) 特徴を変えたときの分類正解率の比較

①経験 : 経験により発見した特徴のみ

Examination of Improve Learning Motivation in e-Learning system - The Classification of Examination Questions by Three Types using Naive Bayes Method -

[†]Mio Kobayashi, [†]Kotaro Senuma, [†]Yusuke Miyakawa,

[†]Takashi Izumi

[†]Nihon University

②形態素 : 形態素解析により得た特徴のみ

③組合せ : ①と②を組み合わせた特徴

の3項目の特徴を使用し分類正解率を求め、比較検討を行う。

(2) 情報利得による特徴の選択

(1)の結果で最も良好であったものについて、4章で示した情報利得を用いて特徴の選択を行い、特徴数と分類正解率の関係を調べる。

5.2 実験条件

表2に実験条件を示す。

表2 実験条件

対象問題	平成21年度 春期・秋期 基本情報技術者試験 午前問題 160問
訓練データ	平成22年度、20年度 春期・秋期 基本情報技術者試験 午前問題 320問

また、実験結果には、どの程度の精度で分類できたかを表す分類正解率を用いる。分類正解率は式(4)から求める。

$$(\text{分類正解率}) = \frac{(\text{正しく分類された問題数})}{(\text{対象問題数})} \times 100 [\%] \quad (4)$$

5.3 実験結果

(1) 特徴を変えたときの分類正解率の比較

分類正解率を表3に示す。①、②より、知識型・計算型には経験の特徴、思考型には形態素の特徴が有効であると言える。③は、①と②の良いところが反映された。全体の分類正解率としては①が最も高いが、どの種類も分類正解率が高い③を最も良好と考える。

表3 特徴を変えたときの分類正解率[%]

	知識型	計算型	思考型	全体
①経験	96.7	95.2	62.5	93.1
②形態素	87.8	81.0	81.3	86.3
③組合せ	95.1	85.7	81.3	92.5

(2) 情報利得による特徴の選択

使用した特徴数と全体の分類正解率の関係を図1に示す。図1より、 $IG(w) \geq 0.009$ としたとき最も高い分類正解率になった。 $IG(w) \geq 0.010$ や $IG(w) \geq 0.011$ とした場合に分類正解率が下がる理由は、有効な特徴が取り除かれるためである。

表4に $IG(w) \geq 0.009$ とした場合の各種類における分類正解率を示す。知識型・思考型の誤分類の原因は、使用した特徴に信頼性がないこと

が挙げられる。訓練データにおいて、各形態素の出現回数は少ないため、情報利得が高い値を取っても、信頼性がない場合がある。そのため、分類精度を向上させるためには、訓練データ数に関しても検討を行う必要がある。

計算型の誤分類の原因は、計算型と思考型の両要素を含んだ問題があることが挙げられる。計算型・思考型の両要素を含んだ問題をどう分類するか検討を行う必要がある。




図1 特徴数と全体の分類正解率の関係

表4 $IG(w) \geq 0.009$ とした場合の分類正解率

	知識型	計算型	思考型	全体
分類正解率 [%]	96.7	85.7	81.3	93.8
誤分類先	計算型 思考型	思考型	知識型	—

6. まとめ

基本情報技術者試験を対象とし、ナイーブベイズ法を用いて出題問題の種類別分類を行った。経験による特徴と形態素による特徴を使用し、情報利得を用いて特徴を選択した。その結果、分類正解率は各種類とも80[%]以上となり、全体は93.8[%]となった。

今後は分類精度向上を目指し、訓練データ数に関しての検討を行う。

参考文献

[1] 金子, 泉: 「利用者の学習意欲を維持する e-Learning システムの開発 —利用者評価に関する検討—」, 情報処理学会全国大会, 2ZD-2, 2013.
 [2] 「基本情報技術者試験 (レベル2)」シラバス (Ver 3.0): http://www.jitec.ipa.go.jp/1_13download/syllabus_fe_ver3_0.pdf (2013-9)
 [3] 奥村学, 高村大也: 「自然言語処理のための機械学習入門」, コロナ社, 2010.