

情報エントロピーによる事例ベースからの知識発見

○武蔵工業大学大学院 学生会員 小田切 亮
 武蔵工業大学工学部 正会員 皆川 勝
 (株)荏原製作所 正会員 上谷 丈和

1.はじめに

エキスパートシステムの開発にあたっては、知識獲得が困難であり、またあいまいさを持った情報の取り扱いが必要である。本論文では、鋼橋疲労損傷の補修方法選定を対象問題として、データベースからの知識発見(KDD)の考え方をういた平均圧縮情報エントロピーによるルール抽出アルゴリズムが、知識発見に有効であることを示す。

2.平均圧縮情報エントロピーによるデータベースからの知識発見

データベース中に存在する各事例を e_i とし、事例の総数を N とする。また、事例 e_i は、 m 個の要素 a_{im} によって構成されている。よって事例 e_i は、次のように表すことができる。

$$\{N: e_1, e_2, \dots, e_i, \dots, e_N\} \quad \{e_i: a_{i1}, a_{i2}, \dots, a_{im}, a_{in}\}$$

データベース内から、ルールを生成する際に、条件部になり得る要素 a_{ij} を y 、結論部になり得る要素 a_{im} を x とし、条件部と結論部になる要素を区別して表すことにする。なお、各要素は、条件部の要素にも結論部の要素にもなり得るものとする。次に、データベース内の各事例 e_i において、条件部の要素 y を持つ事例の数を n_y とし、結論部の要素 x を持つ事例の数を n_x とする。また、条件部の要素 y と結論部の要素 x を共に持つ、すなわち、ルール $y \rightarrow x$ を抽出することのできる事例の数を $n_{y,x}$ とする。

はじめに、結論部の要素 x の生起確率 $p(x)$ を式(1)より求め、結論部の要素が x でない場合、 $\bar{x}$ の生起確率を式(2)より求める。

次に、結論部の要素 x と条件部の要素 y の結合確率 $p(x, y)$ を式(3)より求め、また、結論部の要素が x で、条件部の要素が y の結合確率 $p(x, y)$ を式(4)より求める。

また、条件部の要素 y が起こった時に結論部の要素 x が起こる、結論部の要素 x についての条件付確率 $p(x|y)$ を式(5)より求め、条件部の要素 y が起こった時に、結論部が x である条件付確率 $p(x, y)$ を式(6)より求める。

$$p(x) = \frac{n_x}{N} \quad (1) \quad p(\bar{x}) = 1 - \frac{n_x}{N} \quad (2) \quad p(x, y) = \frac{n_{y,x}}{N} \quad (3)$$

$$p(\bar{x}, y) = 1 - \frac{n_{y,x}}{N} \quad (4) \quad p(x|y) = \frac{n_{y,x}}{n_y} \quad (5) \quad p(\bar{x}|y) = 1 - \frac{n_{y,x}}{n_y} \quad (6)$$

情報理論的には、通常、結論部の要素 x がデータベース内で持つ情報エントロピーを、 $-\log\{p(x)\}$ で示す。また、この時、結論部の要素 x を事例内の要素 $x = a_{im}$ として持つ事例が、同時に条件部の要素 y を $y = a_{ij}$ として持つ場合があった時、 $y \rightarrow x$ というルールが事例中に内在していることになる。この要素 y と要素 x を同時に持つ時の結論部の要素 x がデータベース内で持つ情報エントロピーは、 $-\log\{p(x|y)\}$ で示すことができる。 $-\log\{p(x)\}$ と $-\log\{p(x|y)\}$ との差は、ルール $y \rightarrow x$ を生成することにより、結論部の要素 x についての圧縮された情報エントロピーと言える。この圧縮情報エントロピーのすべての事例に対する平均値を平均圧縮情報エントロピー $ACE(x, y)$ と呼び、式(7)より求める。

$$\begin{aligned} ACE(x, y) &= CE(x, y) / N \\ &= p(x, y) \log \frac{p(x|y)}{p(x)} + p(\bar{x}, y) \log \frac{p(\bar{x}, y)}{p(\bar{x})} \end{aligned} \quad (7)$$

キーワード: 知識発見、エキスパートシステム、知識獲得、事例ベース、ネットワークシステム、エントロピー

武蔵工業大学・工学部・〒158-0087 東京都世田谷区玉堤 1-28-1 Tel:03-3703-3111(Ext.3252) Fax:03-5707-2226

3. 適用結果

および考察
上記の平均圧縮
情報エントロピー
に基づく知識発見
の適用例として、
図-1に示す構造
の因果関係で表さ
れる鋼橋疲労損傷
の補修方法選定問
題を選び、既存の




図-1 システム内のネットワーク構成¹⁾

推論システムで得られる事例群を生のデータベースとみなし、ここからルールを抽出した後、それをルールベースとする推論を実施して、抽出されたルールの有効性を検討する。平均圧縮情報エントロピーである式(3)を用いたルール抽出アルゴリズムを仮想事例より作成したデータベースに適用してルール抽出を試み、その結果 620 のルールがデータベースから抽出された。図-1には、横軸に抽出された 620 のルールをとり、縦軸に評価値である平均圧縮情報エントロピー(AEC値)をとった図を示す。抽出されたルールのうち、AEC 値の高いルールから順に、右に示す 3 通りの基準で結合係数を付与し、それぞれ新たなルールベースを構築して補修方法の選定を行った。その結果を図-3、図-4、図-5に横軸に補修方法項目の番号をとり、縦軸に各項目の可能性であるノード値をとって示す。a) の場合、図-1の様に、AEC 値による評価によって幅広く分布するルールを 0.7 と 0.4 の 2 段階で分類したため、ノード値による可能性の分類が十分になされていないことがわかる。これに対し、b)、c) の場合は、それぞれ 5 段階、10 段階に分類したことから、共に十分な可能性の分類を行って推論結果を提示している。

4. おわりに

知識獲得の初期における知識獲得問題解決のため、データベースからの知識発見(KDD)の手法に平均圧縮情報エントロピー(AEC 値)を用いてルール抽出を試みた。また、抽出したルールの有用性を検討するため、抽出したルールを用いて鋼橋疲労損傷の補修方法選定のためのルールベースを構築し、実際の事例を適用して補修方法選定を試みた。この結果、推論結果は、田中らによるルールベースでの推論結果と同等の結果を示していることから、知識発見におけるルール抽出に AEC 値が十分有効であると考えられる。

〈参考文献〉 1) 田中成典：橋梁工学への知識情報処理技術の応用に関する研究、関西大学学位論文、pp.25-248、1996.9. 2) Bing Leng and Bruce G Buchanan: Using Knowledge-assisted discriminant analysis to generate new comparative terms; Artificial Intelligence and Statistics IV, Springer-Verlag, pp.479-487.1993




図-2 ACE 値により抽出されたルール




図-3 a)の場合の補修方法選定結果




図-4 b)の場合の補修方法選定結果




図-5 c)の場合の補修方法選定結果

- a) 全ルールを 5 分割し、上位 40% を 0.7、次の 40% を 0.4 とした場合
b) 全ルールを 5 分割し、上位から 20% 毎に 0.8, 0.6, 0.4, 0.2 とした場合
c) 全ルールを 10 分割し、10% 毎に 0.8 から 0.1 までとした場合
なお、3 通り全てにおいて、下位 20% のルールについては切り捨てた