

А.А.Викентьев^{1,2}, М.С.Авилов²¹Институт математики им. С.Л.Соболева СО РАН, Новосибирск, Россия;²Новосибирский государственный университет, Россия
(E-mail: vikent@math.nsc.ru)

Новые полные метрики и меры нетривиальности для формул многозначных логик в автоматической кластеризации формул из логической базы знаний. I

В статье рассмотрены следующие задачи: обобщены ранее введённые расстояния и меры нетривиальности на n -значный случай любой логики, сняв ограничения на параметры; используя новые расстояния, разработаны алгоритмы кластеризации множеств формул в n -значной логике; проведены кластеризации подмножеств формул из различных баз знаний и предложены способы сравнения результатов различных адаптированных алгоритмов кластеризации.

Ключевые слова: расстояния и меры, кластеризация множеств, логика, алгоритмы.

Введение

Задачи анализа экспертной информации и извлечения знаний из баз данных приобретают всё большую важность [1-11]. Одним из направлений этой проблематики являются информативность высказываний экспертов [8] и работа с базами знаний [9]. Определение информативности экспертного высказывания зависит от определения информативности его компонент, а также от степени различия этих компонент. Если мы сможем ввести метрику на множестве экспертных высказываний, то их, возможно, стоит подвергнуть кластерному анализу, что даст мощный инструмент для анализа имеющейся информации и изучения новых знаний.

Задача сравнения экспертных высказываний по информативности, их ранжированию и введению метрики на пространстве высказываний была поставлена Г.С. Лбовым и Н.Г. Загоруйко в середине 1990-х гг. [10], [12].

Экспертные высказывания было предложено записывать в виде логических формул исчисления. Таким образом, задача сравнения и ранжирования высказываний экспертов превращается в задачу сравнения и ранжирования логических формул между собой. Для этого надо ввести расстояние между формулами и меру нетривиальности каждой формулы.

Для 2-значной логики решением этой задачи занимались Г.С. Лбов и А. А. Викентьев [7]. Впоследствии А. А. Викентьевым был предложен более общий теоретико-модельный подход к анализу логических высказываний [13]. В качестве исчисления высказываний берётся n -значная логика L_n . С помощью развитой теории моделей для формул многозначной логики вводились разные варианты расстояний и мер нетривиальности (опровержимости, недостоверности, информативности), исследовались свойства этих величин [2]. Затем на основе введённых расстояний и мер нетривиальности стали проводить кластеризацию множеств формул n -значной логики Лукасевича [14] и решалась задача ранжирования экспертных высказываний.

Кластеризация проводилась для малых n и небольшого числа переменных в формулах, а расстояние (более полное) вводилось с логическими (жёсткими) весами [6]. Чтобы автоматизировать вычислительную работу, с необходимостью создавали программы для вычисления расстояний, мер нетривиальности и кластеризации множеств формул многозначной логики.

1 Определения и обозначения

Определим n -значную логику L_n , формулами которой представляются высказывания, а также рассмотрим применение теории моделей к формулам L_n .

1.1 Конструкция n -значной логики L_n

Определение 1.1.1. Пропозициональный язык L состоит из следующих пропозициональных символов:

- 1) x, y, z, \dots – пропозициональные переменные;
- 2) \neg, \rightarrow – пропозициональные связки (отрицание и импликация);
- 3) $(,)$ – вспомогательные символы.

Определение 1.1.2. Под формулами будем понимать следующие последовательности слов из пропозициональных символов:

- 1) x, y, z, \dots – формулы;
- 2) если φ и ψ – формулы, то $\neg\varphi, \varphi \rightarrow \psi$ – тоже формулы;
- 3) никакие другие последовательности из исходных символов, кроме построенных в силу пунктов 1-2, не являются формулами.

Теперь мы можем построить типичную n -значную логику L_n .

Определение 1.1.3. n -значная матричная логика L_n определяется через $M_n = \langle V_n, \neg, \rightarrow, \{1\} \rangle$ – логическую матрицу;

$$V_n = \left\{ 0, \frac{1}{n-1}, \dots, \frac{n-2}{n-1}, 1 \right\} \text{ – множество значений истинности;}$$

$\neg : V_n \rightarrow V_n$, – операция отрицания;

$\rightarrow : V_n \times V_n \rightarrow V_n$ – операция импликации;

$\{1\}$ – выделенное значение истины.

Рассмотрим логические операции в n -значной логике.

Определение 1.1.4. Логические операции на V_n задаются следующим образом:

$\neg x = 1 - x$ – отрицание;

$x \rightarrow y = \min\{1, 1 - x + y\}$ – импликация;

$x \vee y = (x \rightarrow y) \rightarrow y = \max\{x, y\}$ – дизъюнкция;

$x \wedge y = \neg(\neg x \vee \neg y) = \min\{x, y\}$ – конъюнкция.

1.2 Основные понятия и модели для логик

Пусть Σ – конечное множество формул L_n .

Определение 1.2.1. $S(\varphi)$ – носитель формулы φ из L_n (множество переменных, используемых при ее написании).

$S(\Sigma) = \cup_{\varphi \in \Sigma} S(\varphi)$ – носитель множества Σ .

Определение 1.2.2. Модель M – кортеж из означенных переменных, на котором вычислимо значение истинности любой формулы.

$P(S(\Sigma))$ – множество всех моделей, $|P(S(\Sigma))| = n^{|S(\Sigma)|}$ [13]. Будем использовать обозначение $\varphi_{\frac{k}{n-1}}$, когда φ принимает на модели значение $\frac{k}{n-1}, k = 0, \dots, n-1$. $M(\varphi_{\frac{k}{n-1}})$ – количество моделей, на которых φ принимает значение $\frac{k}{n-1}$. $M(\frac{k}{n-1}, \frac{l}{n-1})$ – количество моделей, на которых φ принимает значение $\frac{k}{n-1}$, а ψ принимает значение $\frac{l}{n-1}$.

2 Расстояние и мера нетривиальности формул в L_n

В определении расстояния мы учитываем разницу между любыми различными значениями двух формул на каждой модели. Таким образом, более полно используем многозначность логических формул. Мера нетривиальности служит для ответа на вопрос: насколько добавление формулы в базу знаний повышает ее информативность. Чем более формула недостоверна (а значит, информативна), тем выше мера её нетривиальности.

Покажем, как строится расстояние для формул n -значной логики L_n . Естественно предположить, что чем меньше модуль разности между значениями φ и ψ , тем ближе формулы в данной модели. Будем умножать количество моделей с одинаковыми модулями разности на коэффициент, учитывающий близость значений формул. Ранее в качестве таких коэффициентов брались n истинностных значений (для логики Лукасевича) L_n :

$$\begin{aligned} \tilde{\rho}_0(\varphi, \psi) = & 0 \cdot \left(M(0, 0) + M\left(\frac{1}{n-1}, \frac{1}{n-1}\right) + M\left(\frac{2}{n-1}, \frac{2}{n-1}\right) + \dots + M\left(\frac{n-2}{n-1}, \frac{n-2}{n-1}\right) + M(1, 1) \right) + \\ & + \frac{1}{n-1} \cdot \left(M(0, \frac{1}{n-1}) + M\left(\frac{1}{n-1}, 0\right) + M\left(\frac{1}{n-1}, \frac{2}{n-1}\right) + \dots + M\left(\frac{n-2}{n-1}, 1\right) + M\left(1, \frac{n-2}{n-1}\right) \right) + \dots \\ & \dots + \frac{n-2}{n-1} \cdot \left(M(0, \frac{n-2}{n-1}) + M\left(\frac{n-2}{n-1}, 0\right) + M\left(\frac{1}{n-1}, 1\right) + M\left(1, \frac{1}{n-1}\right) \right) + \\ & + 1 \cdot (M(0, 1) + M(1, 0)) = \sum_{k=0}^{n-1} \sum_{l=0}^{n-1} \frac{|k-l|}{n-1} \cdot M\left(\frac{k}{n-1}, \frac{l}{n-1}\right). \end{aligned}$$

Таким образом, в качестве расстояния между формулами φ и ψ n -значной логики L_n при $S(\varphi) \cup S(\psi) \subseteq S(\Sigma)$ на множестве $P(S(\Sigma))$ ранее принималась нормированная величина $\tilde{\rho}_0$:

$$\rho_0(\varphi, \psi) = \frac{1}{n^{|S(\Sigma)|}} \cdot \sum_{k=0}^{n-1} \sum_{l=0}^{n-1} \frac{|k-l|}{n-1} \cdot M\left(\frac{k}{n-1}, \frac{l}{n-1}\right). \tag{1}$$

Пример. Для случая $n = 5$ $\rho_0(\varphi \wedge \psi, \varphi \vee \psi) = 0.4$, $\rho_0(\varphi \wedge \psi \wedge \chi \wedge \omega, \varphi \rightarrow \omega) = 0.2576$ [6]. Недостатком величины является взятая конструкция весов $\frac{|k-l|}{n-1}$. Она не позволяет выбирать, с каким именно коэффициентом величина $M\left(\frac{k}{n-1}, \frac{l}{n-1}\right)$ (число моделей с одинаковым модулем разности) будет входить в итоговое расстояние ρ_0 . Такая же проблема возникает для ранее использованной меры нетривиальности формул n -значной логики L_n :

$$I_0(\varphi) = \rho_0(\varphi, 1) = \sum_{i=0}^{n-2} \frac{n-1-i}{n-1} \cdot \frac{M(\varphi_{\frac{i}{n-1}})}{n^{|S(\Sigma)|}}. \tag{2}$$

Пример. Для случая $n = 5$ $I_0(\varphi \rightarrow \psi) = 0.2$, $I_0(\varphi \vee \psi \vee \chi \vee \omega) = 0.1416$ [6]. Однозначно определенным весом величины ?? является коэффициент $\frac{n-1-i}{n-1}$. Естественно, необходимо попытаться пошевелить взятые когнитивно найденные и обоснованные величины, указанные выше, и избавиться от жестких ограничений, накладываемых ранее в поиске подходящих коэффициентов.

Список литературы

- 1 Ершов Ю.Л., Палютин Е.А. Математическая логика. — М.: Наука, 1987.
- 2 Викентьев А.А., Викентьев Р.А. Расстояния и меры недостоверности на высказываниях n -значной логики // Вестн. Новосиб. гос. ун-та. Сер. матем., мех., информ. — 2011. — Т. 11. — С. 51–64.

- 3 *Викентьев А.А.* О возможных расстояниях и степенях недоуверности в многозначных высказываниях экспертов и приложении этих понятий в проблемах кластеризации и распознавания // Проблемы информатики - (Новосибирск: СО РАН) 2011. — Т. 3. — С. 33–45.
- 4 *Бериков В.Б.* Коллектив алгоритмов с весами в кластерном анализе разнородных данных // Вестн. Томск. гос. ун-та. — 2013. — № 2(23). — С. 22–31.
- 5 *Авилов М.С.* Программный комплекс вычислений расстояний, мер нетривиальности и кластеризации множеств высказываний в n -значной логике // Студент и научно-технический прогресс: материалы 52-й Междунар. науч. студ. конф.-Новосибирск, 2015.
- 6 *Викентьев А.А., Кабанова Е.С.* Расстояния между формулами пятизначной логики Лукасевича и мера недоуверности высказываний экспертов в кластеризации баз знаний // Вестн. Томск. гос. ун-та. — 2013. — № 2(23). — С. 121–129.
- 7 *Vikent'ev A.A., Lbov G.S.* Setting the metrics and informativeness on statements of experts // Pattern Recognition And Image Analysis. — 1997. — Vol. 7. — No. 2. — P. 175–183.
- 8 *Cooke R., Goossens L.* Delft expert judgment data base // Reliability Engineering and System Safety. — 2008. — No. 93(5). — P. 657–674.
- 9 *Baskerville R., Dulipovici A.* The theoretical foundations of knowledge management // Knowledge Management Research & Practice. — 2006. — Vol. 4. — P. 83–105.
- 10 *Загоруйко Н.Г.* Прикладные методы анализа данных и знаний. — Новосибирск: Изд-во Ин-та математики, 1999.
- 11 *Лбов Г.С., Бериков В.Б.* Устойчивость решающих функций в задачах распознавания образов и анализа разнотипной информации. — Новосибирск: Изд-во Ин-та математики, 2005.
- 12 *Лбов Г.С., Старцева Н.Г.* Логические решающие функции и вопросы статистической устойчивости решений. — Новосибирск: Изд-во Ин-та математики, 1999.
- 13 *Викентьев А.А.* Мера опровержимости высказываний экспертов, расстояния в многозначной логике и процессы адаптации // Knowledge-Dialogue-Solution: Proceedings of the XIII-th International Conference (June, 18-24, 2007, Varna (Bulgaria)). — 2008. — P. 179–188.
- 14 *Карпенко А.С.* Логика Лукасевича и простые числа. — М.: Наука, 2000.

А.А.Викентьев, М.С.Авилов

Логикалық білім қорынан автоматтандырылған формулалар кластеризациясында көпмәнді логика формулалары үшін нольдік емес өлшемдер мен жаңа толық метрикалар. I

Мақалада келесі есептер қарастырылған: параметрлерге шектеу алынып, кез келген n -мәнді логиканың жағдайына бұрын енгізілген нольдік емес өлшемдер мен аралықтар жалпыланған; жаңа аралықтарды қолдана отырып, n -мәнді логикадағы формулалар жиындарын кластеризациялау алгоритмдері құрылған; әр түрлі білім қорынан формулалардың ішкі жиындарына кластеризация жүргізіліп, кластеризацияның әр түрлі алгоритмдерінің нәтижелерін салыстыру тәсілдері ұсынылған.

A.A.Vikent'ev , M.S. Avilov

New comprehensive metrics and nontrivial steps to formulas multi-valued logic in the automatic clustering of logical formulas Knowledge Base. I

This article describes the following tasks: summarized previously entered distances and non-triviality of the measures on the n-digit case of any logic, removing restrictions on the parameters; with the new range, developed algorithms for clustering sets of formulas in the n-valued logic; conducted clustering subsets of formulas from different knowledge bases and provides methods of comparison adapted results of various clustering algorithms.

References

- 1 Ershov Yu.L., Palyutin E.A. *Mathematical logic*, Moscow: Nauka, 1987.
- 2 Vikent'ev A.A., Vikent'ev R.A. *Bull. of Novosibirsk State University*, Ser. Mathematics, mechanics, computer science, 2011, 11, p. 51–64.
- 3 Vikent'ev A.A. *Informatics Problems*, 2011, 3, p. 33–45.
- 4 Berikov V.B. *Bull. of Tomsk State University*, 2013, 2(23), p. 22–31.
- 5 Avilov M.S. *Student and scientific - technical progress: proceedings of the 52nd International Scientific Student Conference*, Novosibirsk, 2015.
- 6 Vikent'ev A.A., Kabanova E.S. *Bull. of Tomsk State University*, 2013, 2(23), p. 121–129.
- 7 Vikent'ev A.A., Lbov G.S. *Pattern Recognition And Image Analysis*, 1997, 7, 2, p. 175–183.
- 8 Cooke R., Goossens L. *Reliability Engineering and System Safety*, 2008, 93(5), p. 657–674.
- 9 Baskerville R., Dulipovici A. *Knowledge Management Research Practice*, 2006, 4, p. 83–105.
- 10 Zagoruiko N.G. *Applied methods of data analysis and knowledge*, Novosibirsk: Publ. of the Institute of Mathematics, 1999.
- 11 Lbov G.S., Berikov V.B. *Stability crucial functions in problems of pattern recognition and analysis of heterogeneous information*, Novosibirsk: Publ. of the Institute of Mathematics, 2005.
- 12 Lbov G.S., Startseva N.G. *The logical decision functions and statistical stability issues making*, Novosibirsk: Publ. of the Institute of Mathematics, 1999.
- 13 Vikent'ev A.A. *Knowledge-Dialogue-Solution: proceedings of the XIII-th International Conference (June, 18-24, 2007, Varna (Bulgaria))*, 2008, p. 179–188.
- 14 Karpenko A.S. *Logic Lukasiewicz and prime numbers*, Moscow: Nauka, 2000.