

Искусственный интеллект и обработка знаний

УДК 658.012.56

Л.Н. Бадёрина

Метод лингвистической обработки текстовых ответов в системах тестирования знаний

Рассмотрен метод оценки знаний обучающихся с помощью сравнительного анализа текстового ответа с заданным эталонным текстом и определение их релевантности, приведены практические расчеты. Исследована лингвистическая модель представления знаний на основе синонимии терминов предметной области.

The method is considered of estimating the students knowledge with the help of a comparison analysis of a text answer with the given standard text and the identification of their correspondence. Practical settlements are given. A linguistic model of the knowledge presentation on the basis of the synonymy of the terms of a subject domain is investigated.

Розглянуто метод оцінювання знань учнів шляхом порівняльного аналізу тексту відповіді з заданим еталонним текстом та визначення їх релевантності, наведено практичні розрахунки. Досліджено лінгвістичну модель уявлення знань на основі синонімії термінів предметної області.

Введение. В связи со стремительным развитием систем автоматизированного обучения актуализировалась проблема построения формальных моделей, описывающих те или иные аспекты этих систем. Среди них особенно выделяются модели и средства, ориентированные на проведение автоматизированного оценивания результатов учебного процесса. Следует отметить, что если построение учебных контентов и целостных систем в этом направлении разработаны достаточно полно, то автоматизация процессов оценивания пока находится на начальном этапе. Это связано прежде всего с тем обстоятельством, что результаты учебного процесса представляются как ответы на экзаменационные и прочие вопросы и поэтому имеют форму естественного текста. Итак, технология оценивания таким способом приобретает характер автоматического (автоматизированного) сравнения естественных языковых текстов или их фрагментов. Очевидно, что такая технология априори должна быть языковозависимой и строиться для каждого языка в отдельности. Тем более неизвестны даже общесистемные научные работы, посвященные этому предмету, что и обусловило необходимость постановки этой работы.

Общая структура системы оценивания ответов и средства моделирования

Учитывая естественноязыковую специфику предмета нашего исследования, основной тео-

ретической конструкцией для построения модели предметной области избираем модель лексикографической среды (или интегрированной лексикографической системы), исследованной в ряде работ.

При построении модели необходимо сконструировать формальные корреляты языковых конструкций, отражающих содержание предметной области, причем моделирование необходимо выполнять как с учетом формы, так и содержания. При этом следует учитывать, что языковая система представляет собой сложную иерархию разных уровней комплексов единиц, объектов и отношений.

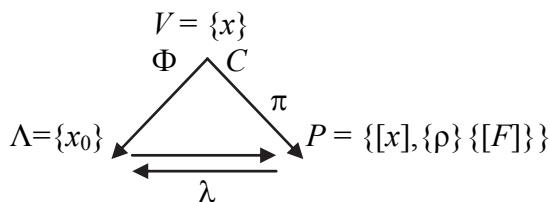
Первым шагом построения модели, по мнению автора, должно быть моделирование совокупности лексических единиц, отображающих «словарь» предметной области как объект исследования, поскольку именно лексической подсистеме принадлежит центральная роль в языковой системе вообще. Этот словарь должен содержать прежде всего «класс термов», состоящих из грамматически специфицированной совокупности лексем предметной области. Адекватной моделью для этого есть модель грамматической Л-системы (Г-системы), в структуре которой выделяются такие элементы:

- класс элементарных информационных единиц $V = \{x\}$, соответствующих классу всех слов

украинского языка (в рассматриваемом случае это класс термов предметной области);

- класс начальных форм, который для изменяемых частей речи соответствует исходным (словарным формам);
- класс разложений слов: $\pi(x) = \rho(x)*\{\omega_u(x)\}$ и соответственно множество неизменных $\{\rho\}$ и изменяющихся $[F]^k \equiv \{\omega_u(x)\}$ частей для всех слов (квазиоснов и квазифлексий соответственно);
- конечное множество словоизменяемых (парадигматических) классов: $\bigcup t_i/\pi_u$;
- оператор парадигматизации π , который ставит в соответствие каждому слову x его полную словоизменяемую парадигму $[\pi(x)]$;
- оператор лемматизации λ , ставящий в соответствие каждому $\xi \in [\pi(x)]$ его исходную форму x_0 .

Схематично структура Γ -системы представляется таким образом:



Определим на Γ оператор: $R = \pi_\rho \circ \Phi$, где π_ρ – есть ограничения π на ρ . Тогда для любого $\xi \in [x]$ справедливо:

$$R\xi = \rho(\xi).$$

Оператор R будет использован при построении системы анализа ответов.

Итак, грамматическая система имеет такое строение:

$$\begin{aligned} \Gamma &= \{V = \{x\}; \Lambda = \{x_0\} = \Phi V; \\ P &= CV = \pi \Lambda = \{[x], \{\rho\}, \{[F]\}; \lambda x = x_0; R\}. \end{aligned}$$

При этом соответственно общему определению Л-системы, справедливым будет условие: $\pi^\circ \Phi = C$ и $\lambda^\circ C = \Phi$, где символом « \circ » обозначена композиция отображений.

Функционально определенная таким способом Γ -система разрешает из любого текста выделить слова (единицы лексического уровня), осуществить их грамматическую идентификацию, установить словоизменяемые классы, к которым они принадлежат, выделить для каждого слова его квазиоснову и квазифлексию,

т.е. представить в форме, адаптированной для дальнейшего анализа.

Строение тезаурусной Л-системы

Построим определенную конструкцию тезауруса Σ над Γ . По определению этот тезаурус строим как элементарную Л-систему, где классом элементарных информационных единиц есть класс Z : $\{z\} = Z$, $z \in Z$ – представители реалий (понятий) рассматриваемой предметной области Σ . Формальную часть описания класса Z – совокупность определенных цепочек элементов с $V = \{x\}$ обозначим через X :

$$X = \{x_1 \Delta_1 x_2 \Delta_2 \dots \Delta_{q-1} x_q, q = 1, 2, \dots\} \dots,$$

где $x_i \in V$; символами Δ_u , $u = 1, 2, \dots, q$, обозначен пробел (или знак пунктуации + пробел); число q – длина цепочки. Таким образом,

$$\begin{aligned} X &= \{z_q = x_1 \Delta_1 x_2 \Delta_2 \dots \Delta_{q-1} x_q, \\ &q = 1, 2, \dots, n, \dots \dots x_i \in V\} = \bigcup_{i=1}^n X_i \end{aligned}$$

и X можно представить в виде объединения:

$$X = \bigcup_{u=1}^U X_i,$$

где X_i – совокупность цепочек длины i . Класс цепочек длины 1 совпадает с классом $V = \{x\}$; класс цепочек длины 2 есть класс соединений из двух слов и т.д. Обозначим символом X^R класс $\{R z_q \equiv R x_1 \Delta_1 R x_2 \Delta_2 \dots \Delta_{q-1} R x_q, q = 1, 2, \dots \dots x_i \in V\} = \{R z_q \equiv \rho(x_1) \Delta_1 \rho(x_2) \Delta_2 \dots \Delta_{q-1} \rho(x_q), q = 1, 2, \dots \dots x_i \in V\}$, а символом R – отображения X на X^R : $R : X \rightarrow X^R$.

Тезаурус Σ над Z (обозначим $\Sigma[Z]$) определяется таким способом.

Пусть для каждого нетривиального $z \in Z$ (и соответствующей ему цепочки $z_q = x_1 \Delta_1 x_2 \Delta_2 \dots \Delta_{q-1} x_q$ с X) определено конечное множество цепочек $C^\Sigma(z)$. Содержательно это множество интерпретируется как множество определений (толкований, дефиниций, интерпретаций и др.) термина z . Это обусловлено тем, что один и тот же учебный материал конкретной предметной области может быть изложен одновременно в нескольких учебниках разными авторами (экспертами), которые дают конкретным терминам свои формулировки, а потому имеет смысл говорить об экспертом наполнении тезаурусов

как своеобразных баз знаний. Каждый эксперт дает собственное формулирование того или другого термина, и таким образом, $C^\Sigma(z)$ представляет собой вектор:

$$C^\Sigma(z) = \{C_1^\Sigma(z); C_2^\Sigma(z); \dots; C_{l(z)}^\Sigma(z)\},$$

где $C_u^\Sigma(z)$ – определения термина z i -м экспертом. Если для определенного z $C^\Sigma(z) = \emptyset$, то такие z будем исключать из $\Sigma(Z)$. С формальной точки зрения дефиниции $C_u^\Sigma(z)$, $u = 1, 2, \dots$, также есть определенными цепочками из X . Для $C^\Sigma(z)$ введем также эквивалентную активную формулировку, определив оператор:

$$C^\Sigma: z \rightarrow C^\Sigma(z),$$

что сопоставляет элементу тезауруса z вектор его толкований $C^\Sigma(z)$.

Синонимия термов и представление в лингвистической системе

При обработке естественноязыковых объектов, а тем более при их сравнении, используется ряд лингвистических фактов и отношений, с помощью которых устанавливается близость между языковыми конструкциями A и B . Общее понятие близости (сходства) формализуется довольно сложно, поэтому в прикладных системах исходят из тех определений близости, которые наиболее адекватно соответствуют содержанию задач, стоящих перед исследователями в каждом конкретном случае. В данном случае следует установить уровень усвоения студентом материала, т.е. насколько определение терминов, подаваемых студентом, совпадают с эталонными определениями. При этом необходимо подать количественную оценку такого совпадения, т.е. иметь соответствующую формальную модель сравнения текстовых определений терминов той или иной предметной области.

Простейшей моделью, которую можно применять в данном случае, по мнению автора, есть модель лексической синонимии. Следует исходить из того предположения, что отношение синонимии между языковыми единицами x и y , которое задается условием близости их семантических состояний $|c(x) - c(y)| < \varepsilon$, xSy , можно оценить количественно, поскольку степень синонимии между членами одного синсета мо-

жет быть разной. Для удобства будем маркировать степень синонимии величиной $\delta = 1 - \varepsilon$, причем примем, что максимально возможная величина ε равняется единице, а соответственно $\delta = 0$ (когда x и y не являются синонимами), а минимальная возможная $\varepsilon = 0$, а $\delta = 1$ (когда $x = y$, или x и y есть абсолютными синонимами).

Таким образом, выполнив количественную оценку степени синонимии, в результате получим синонимическую матрицу $K(x y)$, $x, y \in W$, которая на формальном уровне определяется как функция с декартова произведения $W \times W$ на отрезок $[0, 1]$. Элементы синонимической матрицы $K(x y)$ определяются следующим способом:

$$\left. \begin{array}{l} K(x x) = 1; \\ 0 < K(x y) \leq 1; x \neq y; xSy; \\ (x y) = 0 x \neq Sy. \end{array} \right\}$$

Обозначим символом $K^R(x y)$ матрицу, которая получается из $K(x y)$ применением к x и y процедуры R . Положим по определению:

$$K^R(x y) = K(Rx Ry).$$

Это означает, что установленную экспериментальную оценку синонимической близости можно распространить, кроме самих термов, также и на их квазиосновы.

Релевантность понятий и их дефиниций

Распространим понятие синонимии отдельных термов, которые в лингвистическом смысле есть элементами лексической системы, на составные тезауруса предметной области $\Sigma(Z)$. Для этого рассмотрим два аспекта – *формальный* и *содержательный*.

С *формальной точки зрения* задача состоит в установлении семантической близости, аналогичной к свойству синонимии, но не на множестве отдельных термов, а на множестве цепочек вида $x_1\Delta_1 x_2\Delta_2 \dots \Delta_{q-1}x_q$, $q = 1, 2, \dots$, определенных формулой при условии, что элементы x_1, x_2, \dots, x_q попадают в область определения функции $K(x y)$. *Содержательный* аспект предусматривает установление отношения семантической близости, аналогичной свойству синонимии, на множестве дефиниций сроков:

$$C^\Sigma(Z) = \{C^\Sigma(z) \mid \forall z \in \Sigma(z)\} = \{\{C_1^\Sigma(z); C_2^\Sigma(z); \dots;$$

$C^{\Sigma} l(z)(z) \} \mid_{\forall z \in \Sigma(z) \dots} \}$. Поскольку понятия синонимии в лингвистике корректно определяются лишь для лексической системы, то для установления содержательной (семантической) близости элементов с $C^{\Sigma}(z)$ введем понятие *отношения релевантности*, которое обозначим символом **REL**.

С этой целью определим количественную меру релевантности двух цепочек: $A = z$ и $B = z$ (длиной M и N соответственно), которую обозначим как $\text{REL}(A, B)$.

Таким образом, определяется отображение $\text{REL}: C^{\Sigma}(Z) \times C^{\Sigma}(Z) \rightarrow \Delta$, где Δ – определенное подмножество множества неотрицательных чисел. При этом будем считать, что цепочка B релевантна цепочке A , т.е. $A \text{ REL } B$, тогда и только тогда, когда значение функции $\text{REL}(A, B)$ не меньше какого-либо определенного $\delta \in \Delta$: $\text{REL}(A, B) \geq \delta$, выбор которого зависит от специфики предметной области и конкретных задач исследования и оценивания.

Для нахождения явного вида меры релевантности используем такую аналитическую модель: $\text{REL}(A, B) = \omega \eta$, где ω – определенная функция, зависящая от числовых значений показателя синонимии термов, которые входят в A и B , т.е. определенной функцией матричных элементов матрицы синонимии $K(x, y)$; η – есть определенная функция от длин цепочек A и B (т.е. от M и N).

Функция η задает зависимость меры релевантности $\text{REL}(A, B)$ от количества термов в цепочках A и B , т.е. от целых чисел M и N . Очевидно, что только при совпадении цепочек, они максимально релевантны и следовательно тогда $\text{REL}(A, B)$ достигает максимального значения. Из этого следует первое свойство η :

1. $\eta = \eta_{\max}$ тогда и только тогда, когда $M = N$.

Также очевидно, что функция η симметрична по переменным M и N , следовательно, она симметрична относительно своего максимального значения. Из этого следует второе свойство η :

2. $\eta(M, N) = \eta(N, M)$ и η симметрична относительно значения η_{\max} .

Простейшей функцией с такими свойствами есть функция от $|M - N|$.

Следующее свойство функции η связано с ее поведением при относительно больших различиях $|M - N|$. Очевидно, что если цепочки A и B сильно отличаются по длине (количество значимых термов), то они не могут быть релевантными, поскольку каждый терм, отсутствующий в одной цепочке, вносит свой вклад в семантику второй цепочки, и с учетом каждого такого терма различие в семантике цепочек усиливается, а их взаимная релевантность – снижается. Из приведенных соображений вытекает третье свойство функции η :

3. Если $|M - N| \rightarrow \infty$ (или $M - N \rightarrow \pm \infty$), то $\eta \rightarrow 0$.

Условия 1–3 задают определенное функциональное уравнение, одним из решений которого есть функция $\eta(M, N)$, которая имеет вид

$$\eta(M, N) = l(h) e^{-h|M-N|^2}, h > 0.$$

Параметр h и функцию $l(h)$ подбирают экспериментально, и они могут варьироваться по условиям пользователя; они также могут определяться путем наложения определенных условий нормирования.

Функция ω зависит от трех сменных: коэффициента синонимии термов $K(A, B)$ в цепочках A и B , количества значащих термов в цепочке A (т.е. от N) и количества значащих термов в цепочке B (т.е. от M): $\omega = \omega(K(A, B); N; M)$.

Количество термов в цепочке A , очевидно, равняется мощности множества \hat{A} . Количество термов в цепочке \hat{B} равняется мощности множества \hat{A} до обработки:

$$N = \|A\|, M = \|B\|.$$

Если $N = \text{const}$, то функция ω имеет такие свойства:

1. При увеличении $K(A, B)$ значение ω возрастает.

2. С увеличением количества термов ответа значение ω снижается.

$$\sum k_t$$

3. Если $\frac{\sum k_t}{M} = 1$, то $\omega = \omega_{\max}$. В этой формуле величины k_t – определенные элементы матрицы синонимичности для так называемых

нормализованных цепочек, определению которых будет посвящена отдельная работа.

Обобщенный параметр $K(A, B)$ равняется сумме максимальных коэффициентов соответствия термов цепочек A и B : $K(A, B) = \sum_{e \in B} k_e$.

На основании приведенных свойств получена формула для представления ω :

$$\omega = \frac{\sum k_t}{M}$$

Заключение. Мера релевантности цепочек A и B как произведение функций ω и η , фигурирующих в формуле, определяется так:

$$REL(A, B) = \omega\eta = \frac{\sum k_t}{M} \cdot l(h)e^{-h|M-N|^2}, \quad h > 0.$$

Эта формула на самом деле учитывает определенные эффекты семантической близости информационно-языковых объектов, поэтому ее можно применять как инструмент при анализе

При учете всех накладных временных расходов на выделение памяти видеоадаптера, копирование данных на и от него, создание миллионов потоков, синхронизацию потоков на k -й итерации центральным процессором, предложенная параллельная реализация на видеоадаптере минимум в два раза быстрее последовательной реализации на центральном процессоре.

Использование разделяемой памяти графического процессора не дает преимуществ без снижения количества обращений к глобальной памяти видеоадаптера, в которую копируется матрица весов графа.

Для дальнейшего сокращения времени выполнения алгоритма на видеоадаптере необходимо использовать иные подходы к выделению информационных зависимостей, которые, возможно, теоретически дадут больше время выполнения алгоритма, чем $O(N)$, однако, при реализации, используя программно-аппаратную платформу *CUDA*, будут использовать разделяемую память и снизят число обращений в глобальную память видеоадаптера.

1. Кормен Т., Лейзерсон Ч., Ривест Р. Алгоритмы, построение и анализ. – М.: МЦНМО, 2000. – С. 719–725.
2. Аналіз методів підвищення производительності комп'ютерів з використанням графічних процесорів і програмно-аппаратної платформи *CUDA* / С.Д. Погорелый, Ю.В. Бойко, М.И. Трибрат и др. // Математичні машини та системи. – 2010. – № 1. – С. 40–54.

ситуаций, возникающих при сравнении эталонных (представленных в нормативных источниках, в частности учебниках) формулировок понятий и дефиниций предметной области с фактическими их формулировками, которые есть объектами оценивания, если и первые и вторые представлены цепочками вида A и B .

Описанная модель была применена в процессе оценивания реальных ответов студентов курса «Информатика и вычислительная техника».

1. Kinshuk D., Patel A. A conceptual framework for Internet based intelligent tutoring systems. Knowledge transfer (II) // Educational Technology & Society. – Р. 117–124. – <http://ifets.ieee.org>
2. Кириличев Б.В., Широков Л.А., Рабинович П.Д. Системный анализ проблемы создания интеллектуальных компьютерных обучающих комплексов: Сб. науч. тр. МГИУ. – Г.: МГИУ. – 1996. – С. 166–171.

Поступила 28.12.2010
Тел. для справок: (067) 442-2688 (Киев)
E-mail: vada@ukr.net
© Л.Н. Бадёрина, 2011

Окончание статьи С.Д. Погорелого и др.

3. Методика вимірювання обчислювальної потужності відеоадаптера (платформа *CUDA*) / С.Д. Погорільй, М.І. Трібрать, Ю.В. Бойко та ін. // ІКВТ (ДонНТУ), 2010. – № 11. – С. 94–98.
4. Погорільй С.Д., Камардинна О.О., Бавікін О.І. Про підхід до розпаралелювання алгоритму Флойда–Уоршала // Математичні машини і системи. 2005. – № 3. – С. 91–101.
5. NVIDIA CUDA Programming Guide 2.3. – http://developer.download.nvidia.com/compute/cuda/2_3/toolkit/docs/NVIDIA_CUDA_Programming_Guide_2.3.pdf
6. Программное обеспечение *UAClaster* / В.А. Мар'яновский, С.Д. Погорелый, Ю.В. Бойко и др. // УСиМ. – 2009. – № 5. – С. 76–80.
7. Inter-Block GPU Communication via Fast Barrier Synchronization. – http://www.nvidia.com/content/GTC/posters/73_Feng_Accelerating_Applications.pdf
8. PCI Express. –http://ru.wikipedia.org/wiki/PCI_Express
9. All-Pairs Shortest-Paths for Large Graphs on the GPU / G.J. Katz, J.T. Kider Jr. – <http://www.seas.upenn.edu/~kiderj/research/papers/APSP-gh08-fin-T.pdf>

Поступила 07.12.2010
Тел. для справок: (044) 526-0522 (Киев)
E-mail: sdp@univ.kiev.ua, mike3b@univ.kiev.ua, boyko@univ.kiev.ua, dima@univ.kiev.ua
© С.Д. Погорелый, М.И. Трибрат, Ю.В. Бойко, Д.Б. Грязнов, 2011