

Выучи все ситуации мира! Кластеризация семантики высказываний как метод обучения эмоционального робота-компаньона*

А. А. Котов

kotov@harpia.ru

РГГУ, Курчатовский институт, Москва

Аннотация: Мы демонстрируем метод автоматизированного создания семантических представлений (фреймов) для большого числа ситуаций, описанных в текстах на русском языке. Материалом анализа служат семантические представления крупного массива русских текстов, разобранных семантическим парсером. Эти фреймы используются эмоциональным роботом-компаньоном Ф-2 при автоматическом анализе высказываний: семантика каждого входящего высказывания приводится к ближайшему фрейму. Фреймы позволяют роботу классифицировать все ситуации, описанные в текстах. Метод основывается на приписывании существительным семантического класса (признака) на основе кластеризации векторных представлений *word2vec*, после чего в отдельный фрейм выделяются синтаксические шаблоны, где у заданного глагола ключевые актаны (агенса и пациенса) относятся к одному семантическому классу.

Ключевые слова: эмоциональные агенты, понимание текста, сценарии.

Крупные лингвистические школы сосредотачивают усилия в попытке перечислить фреймы, используемые человеком при понимании текста на естественном языке – см., например, проекты Framenet (Baker et al., 1998) и Frambank (Lyashevskaya et al., 2015). Предполагается, что в структуре каждого высказывания человек распознаёт фрейм (элемент мышления), который позволяет делать выводы из смысла суждения, реагировать на него, в том числе и эмоционально. Фрейм, как элемент семантики обычно соотносится с элементарной дискурсивной единицей или предикацией: структурой простого предложения (клаузы), состоящей из предиката (глагола, предикатива или связки) и набора существительных, замещающих валентности предиката: *Вася стукнул Петю. – Сегодня – холодно! – Вася – студент.* Сколько ситуаций такого вида может существовать? Это важный вопрос не только для теории, но и для прикладной компьютерной лингвистики: современные системы поддержания диалога (чат-боты) хранят базы шаблонов высказываний и для каждого входящего высказывания вычисляют наиболее близкий шаблон, чтобы ответить связанным с ним высказыванием.

Мы работаем над проектом робота-компаньона Ф-2. Этот робот распознаёт мимику и действия человека, а также обращённые к роботу высказывания, после чего реагирует с помощью жестов и речи. Лингвистический модуль робота Ф-2 основан на системе автоматического анализа текста (парсере), которая разбирает каждое входящее высказывание, строит для него синтаксическое и семантическое представления, после чего ищет в семантическом представлении ближайший фрейм и активизирует связанный с ним сценарий – реакцию, приводящую к ответу: жесту, высказыванию и т. д. (Kotov et al., 2018)

Для классификации ситуаций реального мира, описанных в текстах на русском языке, мы собрали достаточно большой корпус текстов (80 млн. словоформ) и разобрали его с помощью парсера. В результате мы получили около 10 млн фактов – семантических представлений отдельных клауз. После чего мы опробовали несколько методов разбиения множества фактов на фреймы (сценарии). Различные методы прямой кластеризации фактов не приводят к удовлетворительному результату: они позволяют выделить устойчивые выражения (например,

* Работа выполнена при финансовой поддержке РФФИ, проект № 19-18-00547

иметь в виду), но не позволяют разделить высказывания на классы, в каждом из которых описываются близкие ситуации. Наиболее успешный из опробованных нами методов состоит в следующем: существительным и глаголам в словаре приписываются семантические признаки, после чего выбираются все контексты с общим глаголом и общими признаками у подлежащего и прямого дополнения. Признаки приписываются следующим образом: каждому слову сопоставляется вектор *word2vec* (Mikolov et al., 2013), после чего проводится кластеризация на множестве этих векторов. На основе кластеризации каждому слову (глаголу или существительному) приписываются два признака: признак основного семантического класса и признак более общего семантического класса-гиперонима. Так, глаголы ($n = 12627$) были нами разделены на 1000 основных классов и 300 классов-гиперонимов, а существительные ($n = 22338$) были разделены на 2000 основных классов и 600 классов-гиперонимов. Применение двухуровневой классификации, а также число классов были выбраны вручную, но мы предполагаем, что данный метод будет работать на классификации с большим числом уровней с равномерно нарастающим числом классов на нижних уровнях классификации. После приписывания признаков словам для каждого глагола выделяются такие контексты, где все существительные в позиции агенса (подлежащего) имеют одинаковый признак-гипероним, а также все существительные в позиции пациенса (прямого дополнения переходных глаголов) имеют одинаковый признак-гипероним. При этом контекст должен встретиться в базе не менее 10 раз. В результате формируются семантические представления ситуаций следующего вида:

- (1) {человек, мужчина, девушка, женщина} @бегать_167
- (2) {крыса, лось, мышь, грызун, кролик, олень, пума, косуля, животное} @бегать_167
- (3) {футболист, вратарь, команда, полузащитник, игрок} @бегать_167
- (4) {мужчина, женщина, человек, девушка} @носить_3005 {плащ, костюм, бельё, кепка, ...}
- (5) {борьба, попытка, преследование, ликвидация, помощь, ...} @носить_3005 {характер}
- (6) {арест, расследование, обыск, пропажа, вербовка} @носить_3005 {характер}

Для каждого такого контекста формируется «сценарий» – абстрактная структура, обладающая «посылкой» (фреймом) – набором признаков, распределённых по валентностям для распознавания во входящем тексте, а также «следствием» – семантическим выводом или коммуникативной реакцией, передаваемой на робота. Всего таким образом нами было построено 11371 сценариев. Из примеров видно, что ситуации ‘человек бегаёт’, ‘крыса бегаёт’ и ‘футболист бегаёт’ разделились на разные сценарии, поскольку соответствующие существительные принадлежат к разным семантическим классам-гиперонимам. Для формирования *посылки* сценария берётся набор валентностей во всех предложениях данного контекста. Семантика каждой валентности задаётся как семантика наиболее частотного слова в этой валентности во всех предложениях контекста (например, *футболист бегаёт с мячом в полуфинале*). Принцип автоматического анализа каждого предложения состоит в том, что его смысл сравнивается со всеми сценариями робота и для «понимания» и последующей реакции выбирается наиболее близкий сценарий. При сравнении используется модифицированная мера Жаккара: оценивается число признаков сценария, присутствующих в смысле входящего текста, а также вес каждого из признаков. Иными словами, при анализе текста мы относим каждую входящую ситуацию к одному или нескольким ближайшим сценариям. Например, высказывание *Лингвисты исследуют синтаксические деревья* классифицируются как относящиеся к сценариям типа @изучить_1781 – *Специалисты изучили образцы*, @выяснить_833 – *Психологи выяснили факторы* и т. д. Если же в тексте появляется более сложное высказывание, то его классификация будет менее однозначна.

Например, высказывание *Инсайт подсказывает решение* классифицируется как относящееся к сценариям типа @подтверждать_15690 – *Исключение подтверждает правило*, а также @пояснить_16344 – *Мэр пояснил ремонт* и @огласить_13841 – *Судья огласил решение*. По-видимому, наиболее точное понимание ‘инсайт приводит к решению’ здесь отсутствует, робот

может выбрать как более близкие сценарии ‘подтверждение решения’ (~ ‘инсайт подтверждает существование/появление решения’) или ‘объявление решения’ (~ ‘инсайт объявляет/выражает решение’). Такая вариативность в выборе сценария связана с тем, что некоторые сценарии могут обращать внимание на прямое значение ‘говорить’ глагола *подсказывать*, либо на его переносное значение ‘способствовать’. Обработка метафор, таким образом, оказывается интересной областью приложения данной модели.

К примеру, высказывание *Банкомат съел карточку* должно рассматриваться как метафорический перенос из области-источника ‘человек ест еду’ в область-цель – ситуацию ‘банкомат не выдал карточку’. При разборе парсером это высказывание классифицируется как относящееся к сценарию @съесть_5275 – *Фотографирование съело половину [времени]*, то есть сразу относится к такому классу, где уже зафиксирована метафоричность глагола *съесть* (речь идёт не о еде, а о метафоре ВРЕМЯ – ЭТО РЕСУРС). Вторым по близости сценарием является @питаться_3565 – *Человек питается трубочками*: при этом слово *трубочка* в нашем словаре не содержит семантических признаков еды, как и кредитная карточка. Далее по снижению близости следует группа сценариев типа @перехватить_15085 – *Истребитель на границе перехватил самолёт*, поскольку глагол *перехватить* обладает признаком ‘съесть’ в своём втором, жаргонном значении. То есть эти сценарии неверно распознают смысл ‘истребитель перекусил самолётом’. Таким образом, для данного высказывания парсер стремится выбрать сценарии: (а) в которых упоминается несъедобное дополнение – *половина [времени], трубочка, самолёт*, и (б) у которых глагол может обладать признаком ‘съесть’ – *съесть, перехватить*.

Представленный метод автоматического создания сценариев позволяет роботу существенно расширить список моделируемых когнитивных функций. Если разработанный нами ранее инвентарь сценариев, общим числом 77 единиц, позволял роботу лишь отвечать на базовые вопросы и демонстрировать простые эмоциональные реакции, то представленный метод позволяет роботу построить типологию ситуаций реального мира, отражённых в текстах на естественном языке, объёмом более 10 тыс. единиц. Это даёт возможность роботу отвечать аналогиями: для входящего высказывания подбирать описание похожей ситуации. Более того, возможность классифицировать ситуации текста может позволить в перспективе продвигнуться в моделировании естественно-языкового вывода: автоматически выделять сюжетные отношения и стандартные последовательности действий, используемые для понимания историй.

Список литературы

1. Baker, C. F., Fillmore, C. J., & Lowe, J. B. (1998). The Berkeley FrameNet Project.
2. Kotov, A., Arinkin, N., Filatov, A., Zaidelman, L., & Zinina, A. (2018). Semantic comprehension system for F-2 emotional robot. *Advances in Intelligent Systems and Computing* (Vol. 636). Springer, Cham. 126–132.
3. Lyashevskaya O., & Kashkin E. (2015) FrameBank: A Database of Russian Lexical Constructions. In: Khachay M., Konstantinova N., Panchenko A., Ignatov D., Labunets V. (eds) *Analysis of Images, Social Networks and Texts*. AIST 2015. Communications in Computer and Information Science, vol 542. Springer, Cham. https://doi.org/10.1007/978-3-319-26123-2_34
4. Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. *1st International Conference on Learning Representations, ICLR 2013 – Workshop Track Proceedings*. arXiv:1301.3781