

## МОДЕЛИРОВАНИЕ И АНАЛИЗ ЗНАНИЙ В СИСТЕМАХ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Е.В. Щуревич, Е.Н. Крючкова

В последнее время на фоне неуклонного роста объемов информации, которые ежедневно приходится перерабатывать человеку, появляется необходимость построения интеллектуальных систем, основанных на знаниях и реализующих функции от поиска до принятия решений.

Для интеллектуальных систем, основанных на знаниях, большую роль играет процесс наблюдения за базой знаний, ее формированием и изменением во времени. Однако в связи с большими объемами информации, которыми оперируют такие системы, а также ее сложностью эта задача становится трудно выполнимой и требует большого количества ресурсов.

В данной работе представлены модели визуализации и оценки текущего состояния базы знаний, способствующие решению этой проблемы.

Модель визуализации знаний основана на отображении многомерного пространства базы знаний на двумерное и включает в себя:

- построение интуитивно понятного графического изображения знаний системы с учетом их пространственной структуры;
- возможность наложения различных фильтров для отображения только необходимой части базы.

В связи с большими объемами подлежащей отображению информации, человеку очень сложно сделать выводы по структуре сформированной базы. Дополнительные сложности представляет и то, что визуализация является отображением многомерного пространства знаний на двумерное, а это неизбежно влечет за собой наложение изображений различных не связанных между собой частей базы знаний друг на друга, еще больше ухудшая восприятие. В связи с этим появляется необходимость в возможности наложения различных фильтров на отображаемую часть знаний. Использование фильтров позволяет специалисту увидеть только ту часть базы и только в том разрезе, которая необходима в данный момент.

Но даже при использовании фильтров объем подлежащих отображению знаний ос-

тается велик, поэтому человеку очень сложно сделать выводы о структуре всей базы.

По этой причине возникает необходимость автоматизации оценки базы знаний, которая включает в себя:

- анализ общей структурированности базы;
- анализ свойств отдельных частей базы знаний, таких, как, например, определение вида, к которому относится каждый кластер (структурная единица базы знаний), возможные пути расширения кластеров, степень и характер связности кластеров и т. д.

В данной работе предложено решение этой проблемы с использованием муравьиных алгоритмов и нейронных сетей.

### Структура знаний интеллектуальной системы

Рассмотрим интеллектуальную систему, которая создавалась в предположении, что все множество фраз естественного языка представимо в виде суперпозиции функций и понятий. Элементарными структурными единицами знаний в этой системе являются *понятия*  $C$ , объединяющие в себе слова, схожие по смыслу.

Более крупной структурной единицей является *функция*  $F$ , задаваемая понятием — названием функции, определяющим семантическое значение функции, группой возвращаемых понятий и конечным множеством аргументов, каждый элемент которого определяется порядковым номером и множеством понятий, участвующих в аргументе.




Рисунок 1 — Структура функции

Однако знания не существуют обособленно, они объединены в некие блоки, представляющие собой те или иные знания о мире. Как правило, в блоке знаний — кластере — можно рассматривать *определяющую* функцию, задающую основную семантику блока, и функции, её *окружающие*.

### Визуализация знаний

Как уже говорилось выше, структура кластеров, состоящих из функций, является многомерной. Но при визуализации необходимо по возможности отображать расстояния между функциями, сохраняя их пропорции.

Для отображения многомерной структуры кластера на двумерное пространство в данной работе используется антиградиентный метод, который заключается в следующем.

Пусть задано  $k$  точек многомерного пространства (элементарных структурных единиц базы знаний) и известны все расстояния  $\overline{d}_{ij}$  между этими точками. Поставим каждой точке  $v$  в соответствие двумерный вектор  $y^1, \dots, y^k$  и обозначим расстояния между ними

$$d_{ij} = \sqrt{(y_1^i - y_1^j)^2} + \sqrt{(y_2^i - y_2^j)^2}$$

Таким образом, критерием наилучшего отображения является близость между расстояниями  $\overline{d}_{ij}$  и  $d_{ij}$ .

Ошибка оценим как

$$E = \frac{1}{2} \sum_{i < j}^k \frac{(\overline{d}_{ij} - d_{ij})^2}{\overline{d}_{ij}}$$

На каждом шаге будем считать

$$y_1^l = y_1^l - \Delta \frac{\partial E}{\partial y_1^l};$$

$$y_2^l = y_2^l - \Delta \frac{\partial E}{\partial y_2^l},$$

где  $l = 1 \dots k$ ,

$\Delta$  — произвольная константа (в данном случае было выбрано  $\Delta = 0,05$ ).

### Анализ знаний

Анализ знаний системы производится следующим образом. Сначала муравьиный алгоритм работает на пространственной

(многомерной) модели базы знаний, после чего модель упрощается: удаляются некоторые связи, отдельные функции объединяются в более крупные структурные единицы. После этого муравьиный алгоритм запускается на упрощенной плоской структуре знаний.

Выводы по результатам работы муравьиного алгоритма делаются на основании следующих данных:

- по остаточным следам феромона на ребрах графа связности функций базы знаний определяется степень и характер связности кластеров;
- по конечному расположению муравьев определяются наиболее вероятные пути развития системы.

Результаты работы муравьиного алгоритма обрабатываются с помощью нейронной сети, которая определяет принадлежность кластеров к тому или иному виду. После этого в системе производится поиск достаточно полных, хорошо обученных блоков знаний, способных стать учителями в процессе обучения по аналогии. Для них ищутся менее полные блоки схожей структуры, то есть блоки-ученики. Результаты анализа сохраняются и передаются в систему для использования.

### Муравьиные алгоритмы

Муравьиные алгоритмы — новый перспективный метод оптимизации, базирующийся на моделировании поведения колонии муравьев.

Основу «социального» поведения муравьев составляет *самоорганизация* — множество динамических механизмов, обеспечивающих достижение системой глобальной цели в результате низкоуровневого взаимодействия её элементов. Принципиальной особенностью такого взаимодействия является использование элементами системы *только локальной информации*. При этом исключается любое централизованное управление и обращение к глобальному общему миру. Самоорганизация является результатом взаимодействия следующих четырех компонентов:

- Случайность;
- Многократность;
- Положительная обратная связь;
- Отрицательная обратная связь.

Для применения муравьиных алгоритмов к представленной задаче необходимо соответствующим образом уточнить реализацию

четырёх составляющих самоорганизации муравьёв. В данной работе было предложено конкретизировать алгоритм следующим образом.

*Многократность взаимодействия* реализуется итерационным движением по графу взаимосвязей базы знаний одновременно несколькими муравьями. Каждый муравей начинает маршрут из своей точки — функции базы знаний. При этом муравей является как бы «привязанным» к тому кластеру, из которого он начал свое движение.

*Положительная обратная связь* реализуется как имитация поведения муравьёв типа «оставление следов — перемещение по следам». Для данной задачи это поведение подчиняется следующему стохастическому правилу: вероятность выбора ребра в качестве следующего на пути пропорциональна количеству феромона на нем. Будем считать, что муравьи будут различать следы, оставленные на ребрах муравьями «своего» кластера и остальными, и станут отдавать большее предпочтение следам «своего» феромона.

Применение такого вероятностного правила обеспечивает реализацию и другой составляющей самоорганизации — *случайности*. Количество откладываемого муравьем феромона на ребре графа связности обратно пропорционально длине маршрута.

Использование только положительной обратной связи приводит к случаю, когда все муравьи двигаются одним и тем же маршрутом. Во избежание этого используется *отрицательная обратная связь* — испарение феромона. Время испарения не должно быть слишком большим, так как при этом возникает опасность сходимости популяции маршрутов к одному. С другой стороны, время испарения не должно быть и слишком малым, так как это приводит к быстрому «забыванию», потере памяти колонии и, следовательно, к некооперативному поведению муравьёв.

Пусть для каждого муравья переход из функции  $i$  в функцию  $j$  зависит от двух составляющих: видимости и виртуального следа феромона.

*Видимость* — величина, обратная расстоянию:

$$\eta_{ij} = 1 / D_{ij},$$

где  $D_{ij}$  — расстояние между функциями  $i$  и  $j$ .

Видимость — это локальная статистическая информация, выражающая эвристическое желание посетить функцию  $j$  из функции

$i$ : чем ближе функция, тем больше желание посетить её.

*Виртуальный след феромона* на ребре  $(i, j)$  представляет подтвержденное муравьиным опытом желание посетить функцию  $j$  из функции  $i$ . В отличие от видимости след феромона является более глобальной и динамической информацией — она изменяется после каждой итерации алгоритма, отражая приобретенный муравьями опыт. Количество виртуального феромона на ребре  $(i, j)$  на итерации  $t$  обозначим через  $\tau_{ij}(t)$ .

Важную роль в муравьиных алгоритмах играет вероятностно-пропорциональное правило, определяющее вероятность перехода  $k$ -го муравья из функции  $j$  в функцию  $i$  на  $t$ -й итерации. В данном случае было предложено использовать следующую формулу для этого правила:

$$P_{ij,k}(t) = \frac{[\tau_{ij}(t)]^\alpha \cdot [\eta_{ij}]^\beta}{\sum_l [\tau_{il}(t)]^\alpha \cdot [\eta_{il}]^\beta},$$

$$\tau_{ij}(t) = \alpha_{self} \cdot \tau_{ij,cl} + \sum_{z \neq cl} \alpha_{alien} \cdot \tau_{ij,z},$$

где  $\alpha$  и  $\beta$  — два регулируемых параметра, задающие веса феромона и видимости при выборе маршрута,

$\alpha_{self}$  — коэффициент доверия «своему» феромону,

$\alpha_{alien}$  — коэффициент доверия «чужому» феромону.

После прохождения ребра каждый муравей  $k$  откладывает на ребре  $(i, j)$  количество «своего» феромона  $\Delta\tau_{ij,k}(t)$ , обратно пропорциональное параметру  $Q$ .

Для исследования всего пространства решений необходимо обеспечить испарение феромона. Обозначим коэффициент испарения феромона через  $p \in [0,1]$ . Тогда правило обновления каждого вида феромона примет вид:

$$\tau_{ij}(t+1) = (1-p) \cdot \tau_{ij}(t) + \Delta\tau_{ij}(t),$$

$$\text{где } \Delta\tau_{ij}(t) = \sum_{k=1}^m \Delta\tau_{ij,k}(t),$$

$m$  — количество муравьёв в колонии.

В начале работы алгоритма количество феромона каждого вида принимается равным небольшому положительному числу  $\tau_0$ . Общее количество муравьёв в колонии остается постоянным.

### Нейронные сети

Результаты работы муравьиного алгоритма обрабатывает нейронная сеть, определяющая характеристики каждого кластера. В качестве исходных данных для нее было предложено использовать:

- Количество функций в кластере;
- Количество связей между функциями кластера;
- Количество связей, ведущих за пределы кластера;
- Число «своих» и «чужих» муравьев, закончивших движение в кластере;
- Суммарное количество «своего» и «чужого» феромона на связях в конце алгоритма;

Результатом работы нейронной сети являются выводы о:

- типе и степени полноты кластера;
- степени и характере связности с другими кластерами.

Основанием для выводов относительно полноты кластера является количество связей внутри кластера, количество связей, ведущих за пределы кластера (чем их больше по отношению к внутренним связям, тем лучше знания из кластера интегрированы в общие знания о мире, а значит, кластер является более полным), а также количество феромона на этих связях.

О типе кластера можно судить по распределению феромона по связям кластера, а также по расположению в нем муравьев. Конечное положение муравьев позволяет сделать выводы о перспективных направлениях развития кластеров. Так, например, если наблюдается достаточно глубокое проникновение в кластер муравьев из соседнего блока знаний, то можно говорить о возможном слиянии этих кластеров. А в случае концентрации муравьев в некоторой области кластера имеет смысл предположение о дальнейшем расширении кластера в этом направлении.

### Подобные блоки знаний

Большое значение в процессе обучения базы знаний имеет обучение по аналогии, когда на основе хорошо обученной части базы обучается более слабо обученная часть схожей структуры. Основополагающей частью такого обучения является поиск в базе образований подобной структуры. Эти образования могут являться как отдельными кластерами (в этом случае идет речь о поиске

кластера-учителя и кластера-ученика), так и более сложными блоками, включающими несколько кластеров и связи между ними.

В данной работе рассмотрен поиск подобных по структуре блоков, содержащих в общем случае более одного кластера. Для решения этой задачи было предложено использовать результаты работы муравьиных алгоритмов на пространственной и упрощенной плоской моделях базы знаний.

Результатами работы муравьиного алгоритма являются остаточные следы феромона на связях между функциями базы знаний и конечное положение муравьев. Очевидно, более обученные части базы знаний будут иметь большее количество феромона на единицу длины связей. Если установить предел для блока, способного стать учителем, в  $F_{min}$  феромона на единицу длины, то становится возможным выделить все такие блоки. Величина  $F_{min}$  может варьироваться в зависимости от величины и полноты базы знаний. Так для небольшой по объему, но достаточно обученной базы этот лимит будет выше, чем для содержащей большое количество слабо связанных функций. В результате экспериментальных исследований в рамках данной работы было установлено, что оптимальным предельным значением для определения блока-учителя является

$$F_{min} \approx 0,6 \cdot \bar{F},$$

где  $\bar{F}$  — среднее по базе знаний количество феромона на единицу длины связей.

Таким образом, становится возможным найти все хорошо обученные блоки знаний, причем для каждого блока будет известно, из каких кластеров он состоит. На основании результатов работы нейронной сети можно определить общие структурные характеристики полного блока знаний:

- Количество и типы составляющих его кластеров;
- Характер связности кластеров в блоке;
- Взаимное расположение кластеров блока.

Будем считать блоки подобными по структуре, если их можно отнести к одному из следующих типов:

- Структурные связи одинаково соединяют равное количество кластеров, виды которых на соответствующих позициях совпадают.
- В более обученном блоке содержится меньшее число более крупных кластеров, при этом в менее обученном блоке есть тесно связанные небольшие кла-

## МОДЕЛИРОВАНИЕ И АНАЛИЗ ЗНАНИЙ В СИСТЕМАХ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

стеры, в случае объединения которых в один, блоки попадут под определение первого типа подобных блоков.

- Ситуация обратная второму типу: более обученный блок содержит большее количество кластеров, а менее обученный имеет кластеры, способные в будущем разделиться на меньшие.
- Объединение второго и третьего случаев: если часть кластеров в менее обученном блоке знаний объединить, а часть разделить, то получится первый тип.

В результате выявления подобных блоков знаний можно с достаточно большой долей уверенности говорить о дальнейшем развитии менее обученных блоков знаний как с применением алгоритмов обучения по аналогии, так и без их использования.

Рассмотрим пример, иллюстрирующий подобие кластеров. На рисунке 2 приведено изображение достаточно полного, хорошо обученного кластера, а на рисунке 3 – менее обученного.



Рисунок 2 — Полный кластер



Рисунок 3 – Неполный кластер

Видно, что кластеры имеют схожую структуру, в которой функции, составляющие

кластер, расположены вокруг определяющей. При этом связей между функциями в пределах одного кластера довольно много и они имеют приблизительно равную длину. В связи с тем, что кластер, представленный на рисунке 2 обучен больше, то есть функции, из которых он состоит, были представлены в обучающих текстах чаще и полнее, повторности между элементами кластера выше, чем в среднем по базе, а, следовательно, расстояние между ними меньше, и сам кластер выглядит более компактно. Повторности же между функциями, составляющими кластер, представленный на рисунке 3, меньше, так как они реже встречались в одном контексте при обучении базы. Соответственно больше и расстояния между этими функциями.

То, что приведенные кластеры имеют схожую структуру, позволяет сделать вывод об их подобии, а то, что один из них явно более полон, дает возможность использования его в качестве блока-учителя для второго.

Полученная в результате анализа знаний системы информация (типы кластеров, подобные блоки знаний, вероятные пути развития системы) помогает специалисту следить за состоянием базы интеллектуальной системы, выявлять и своевременно устранять ошибки в алгоритмах обучения, определять области, в которых система должна получать больше данных для равномерного обучения и т.д.

### СПИСОК ЛИТЕРАТУРЫ

1. Лорьер Ж.-Л. Системы искусственного интеллекта. – М.: Мир, 1991. – 568 с.
2. Сотник С.Л. Основы проектирования систем искусственного интеллекта: Курс лекций / С.Л. Сотник. – 1997-1998.
3. Штовба С. Д. Муравьиные алгоритмы // Эксперимента Pro. – 2003. – №4. – С. 70–75.
4. Уинстон П. Искусственный интеллект. – М.: Мир, 1980. – 520 с.
5. Щуревич Е.В. Проблема визуализации и фильтрации знаний в системах искусственного интеллекта / Е.В. Щуревич, Е.Н. Крючкова // Материалы конференции-конкурса «Технологии Microsoft в информатике и программировании». – Новосибирск, 2005. – С. 147-149.