

УДК 681.3

ПЕРСПЕКТИВЫ АГЕНТСКИХ ТЕХНОЛОГИЙ В СИСТЕМАХ ДЕЦЕНТРАЛИЗОВАННОГО ОБУЧЕНИЯ

В.И. Городецкий

АО «Эврика», Санкт-Петербург

Россия, 196084, Санкт-Петербург, Московский пр-т., 118

vladim.gorodetsky@gmail.com

Ключевые слова: автономные агенты, многоагентные системы, децентрализованное машинное обучение, перспективы интеграции.

Аннотация: Применение технологий автономных агентов и многоагентных систем для децентрализованного извлечения знаний из распределенных источников данных относятся в настоящее время к числу потенциально весьма перспективных, но пока малоизученных проблем. В работе проводится краткий анализ возможностей, проблем и потенциальной синергии интеграции агентских технологий и децентрализованных технологий машинного обучения с различных точек зрения.

1. Введение

В настоящее время по ряду причин заметно растет интерес к использованию децентрализованных алгоритмов и технологий искусственного интеллекта (ИИ) [1,2], в частности, в задачах извлечения знаний из данных (Data Mining) и машинного обучения (Machine Learning). Этот тренд автоматически поднимает вопрос о перспективах концепций автономных агентов и многоагентных систем (МАС) в качестве технологической базы для программной реализации приложений децентрализованного ИИ. Отметим, что еще два десятилетия назад проблема интеграции агентских систем и систем извлечения знаний из данных, в частности, в децентрализованном варианте активно изучалась в ИИ. При этом были разработаны как алгоритмические основы децентрализованного извлечения знаний из данных, так и получен практический опыт создания агентских систем такого назначения. Поэтому имеет смысл оценить перспективу децентрализованного получения знаний из данных с использованием технологий автономных агентов и МАС. Эта задача является целью данной работы.

2. Почему актуальна децентрализация машинного обучения?

Исследования по анализируемой проблеме были начаты в 1990-е годы, и к началу 2000-х годов были получены достаточно зрелые результаты. К этому времени сформировалось международное сообщество специалистов (Special Interesting Group, SIG) под названием Agent Mining [3], объединившее ученых из Европы, Азии и Австралии, которое существует и сейчас, хотя в последние годы его активность невысока. Некоторые важные результаты этого сообщества представлены в [4-6]. Параллельно и относительно независимо аналогичные исследования развивалось в США [7, 8], а также в рамках проекта «KD-ubiq – a blueprint for ubiquitous knowledge

discovery systems» Европейской программы FP5 (2004 – 2008). Основные результаты этого проекта кратко изложены в [9]. Кроме упомянутых работ, имеется также ряд публикаций, некоторые из них обсуждаются далее. Примерно с 2010 года и до недавнего времени активность исследований в данном направлении заметно упала по ряду причин. Среди них основной можно считать то, что в этот период большие силы исследователей ИИ были сконцентрированы на развитии технологий глубокого обучения, которые до недавнего времени удовлетворяли текущие потребности индустрии ИИ. Однако революционные результаты, связанные с развитием технологии больших языковых моделей (Large Language Models, LLM) и концепции Базовых моделей (Foundation Models, FM), изменили ситуацию. Но для практической работы с ними и создания приложений на основе FM требуются вычислительные мощности уровня суперкомпьютеров, доступ к которым имеется у единиц компаний. И это стало одной из ряда причин реанимации интереса исследователей и разработчиков приложений ИИ к децентрализованным системам обработки данных, что совместно с другими обстоятельствами, породило тренд развития ИИ в направлении децентрализованных систем извлечения знаний из данных и децентрализованного машинного обучения.

Кроме того, этот тренд обусловлен также тем, что существуют классы приложений, требующих работы с распределенными источниками данных, которые или невозможно, или нецелесообразно собирать в единое хранилище или озеро данных, чтобы затем воспользоваться привычными системами централизованной обработки. Это нерационально в тех случаях, когда данные, собранные вместе, обладают слишком большой размерностью и объемом. Работать с такими данными сложно как с позиций потребных вычислительных ресурсов, так и с позиций робастности вычислительных процессов. Это нерационально также тогда, когда коммуникационная среда обладает низкой пропускной способностью, что часто свойственно современным системам беспилотных средств, например, подводных, для которых машинное обучение для принятия решений требуется выполнять в реальном времени. Существующие решения для децентрализованной обработки данных типа среды Hadoop или систем федеративного машинного обучения не решают проблемы в случае сложных структур данных или, когда нужно выполнять объединение локальных решений.

Однако наиболее строгие ограничения на возможность централизованной обработки данных, распределенных по многим источникам, налагают требования приватности и конфиденциальности данных. Их обработка возможна только в исходном узле хранения данных. Дополнительными аргументами против консолидации данных в одном хранилище являются проблемы отказоустойчивости (в централизованных системах существует единственная точка отказа) в случае машинного обучения, а также проблемы с безопасностью каналов передачи данных. Для некоторых данных могут быть также законодательные запреты по перемещению данных.

Актуальность исследований и разработок в интересах решения задач децентрализованного обучения является частью более широкой проблемы, формирующей современный тренд на существенное повышение роли децентрализованных приложений ИИ. Этот тренд, новые проблемы, которые при этом появляются, типовые новые классы приложений, в которых необходимо использовать децентрализованное машинное обучение, детально анализируются в [2] и недавних публикациях [8, 9].

3. Перспективы агентов децентрализованного обучения

Имеющийся опыт создания систем децентрализованного извлечения знаний из данных и децентрализованного машинного обучения однозначно свидетельствует о хороших перспективах агентских технологий для разработки и имплементации децентрализованных систем, в частности, систем того типа, которые обсуждаются в работе. Обратим внимание на то, что все имеющиеся разработки систем децентрализованного извлечения знаний из данных и машинного обучения (см. их обзор в разд. 4) были выполнены на основе агентских технологий. И это естественно.

Действительно, агентские вычисления, которые по своей сути основаны на взаимодействии распределенных автономных сущностей (программных агентов), идеально подходят для вычислений в сетях из большого числа простых вычислителей, существующих в общей коммуникационной среде. Агентские вычисления – это вычисления на основе взаимодействий. А это как раз является спецификой алгоритмов децентрализованного извлечения знаний из данных и машинного обучения.

Этот баланс является не единственным аргументом в пользу утверждения о том, что в системах децентрализованного обучения нет альтернативы агентским архитектурам и технологиям. В общем случае автономные агенты способны работать на основе локальной информации о внешнем мире, восполняя ее недостаток путем обмена сообщениями с другими агентами сети, например, с агентами, работающими с локальными источниками данных. Автономность и ограниченное использование внешней информации при этом существенно упрощают решение проблем безопасности.

Особым требованием к системам децентрализованной обработки данных в интересах задач обучения является масштабируемость алгоритмов и инструментов для создания систем децентрализованного обучения и возможность их адаптивной реконфигурации в соответствии с конфигурацией источников данных конкретного приложения с индивидуальными свойствами. В архитектурах агентских систем оба эти требования выполняются без особых проблем. Все агенты сети могут быть легко проинформированы о появлении в сети новых агентов или о выходе некоторых агентов из сети с помощью стандартных протоколов, реализуемых путем обмена сообщениями. В частности, это не представляет проблем и в одноранговых (peer-to-peer, p2p) сетях агентов.

В настоящее время имеются разработки, в которых предложены протоколы автономного оперативного исполнения сетью агентов заданной стратегии *группового управления*, в частности, поведения, реализующего план решения частично упорядоченного множества задач технологии децентрализованной обработки распределенных данных [10], что позволяет минимизировать вмешательство человека в этот процесс. Ряд дополнительных аргументов в пользу применения агентских архитектур и технологий в системах децентрализованной обработки данных для извлечения знаний можно найти в [4-6].

Новое уникальное качество агентским системам в задачах децентрализованного получения знаний из данных и децентрализованного машинного обучения придает технология мобильных агентов, благодаря которой агенты могут передаваться по узлам сети, где размещены источники данных, что просто решает проблему приватности и конфиденциальности данных источников (во «внешний мир» в этом случае доставляется только метаинформация о данных источника), а также позволяет агентам работать с динамической конфигурацией множества источников.

4. Алгоритмы и системы децентрализованного обучения

К настоящему времени разработано большое число достаточно разнообразных моделей и алгоритмов децентрализованного излечения знаний из распределенных источников данных и, в частности, децентрализованного машинного обучения. Основные разработки по этой теме датируются не позже 2010 г. В последующий период новые модели и алгоритмы децентрализованного машинного обучения не были предметом внимания исследователей. В период после 2010 г. проблемы децентрализованного обучения изучаются, в основном, с технологической точки зрения, и эти проблемы являются предметом исследований и разработок в современном разделе машинного обучения, называемом *федеративным обучением* (Federated Learning). В нем не исследуются методы и алгоритмы объединения решений, полученных в результате машинного обучения на данных локальных источников. Предметом исследований в этом разделе машинного обучения являются технологии подготовки и преобразования форматов данных к стандартным формам, сами эти стандартные формы представления данных, а также соответствующие программные инструменты представлены в [11].

Что касается моделей и алгоритмов объединения решений, построенных по результатам машинного обучения на данных локальных источников, то наиболее полные материалы обзорного плана на эту тему можно найти в [4, 9, 12]. На русском языке эти вопросы частично освещены в учебнике [12] и в обзоре [13].

Разработанные модели и алгоритмы децентрализованного извлечения знаний из данных разных источников и машинного обучения можно объединить в следующие группы однотипных алгоритмов:

(1) Вероятностные модели и алгоритмы, основанные на классическом правиле Байеса и его различных упрощениях. Их много, и они отличаются разнообразием. В частности, к этой группе относят различные варианты голосования.

(2) Группа методов и алгоритмов, которые используют объединения решений, полученных на основе знаний, извлеченных их локальных источников данных, с помощью обучаемого мета-классификатора. В зарубежной литературе они называются методами, построенными на основе «стекового обобщения» (*«stacked generalization»*). Наиболее интересные модели и алгоритмы этого типа описаны в [7, 8, 14].

(3) группа методов, основанных на понятии *областей компетентности* решателей и использовании процедур, позволяющих оценивать их компетентность по отношению к каждому входу системы принятия решений.

(4) методы объединения решений, основанные на применении нейросетевых технологий.

(5) P2P-методы вычислений и объединения решений в схеме, в которой классификаторы не структурированы иерархически, а взаимодействуют как равноправные на основе парных взаимодействий.

Детальные описания моделей и алгоритмов каждой группы с характеристиками их областей применения можно найти в обзоре [15]. Эти модели децентрализованного обучения на основе данных многих источников, реализующие различные варианты объединения решений, сформированных на основе локальных источников данных, хорошо приспособлены для их имплементации с помощью агентских технологий. Следует обратить особое внимание на P2P-методы вычислений и объединения локальных решений. В настоящее время просматривается только агентская их реализация. Модели и алгоритмы именно этой группы в наибольшей степени гарантируют соблюдение приватности и конфиденциальности данных источников.

Рассмотрим имеющийся опыт использования агентских технологий в реализованных инструментальных системах децентрализованного излечения знаний из данных и машинного обучения. Такие инструменты активно разрабатывались рядом

научных групп в период 1990-2010 гг. Рассмотрим кратко некоторые из них, используя [2, 3, 12].

Система PADMA (Parallel Data Mining Agents, [16]) предназначалась для децентрализованного решения задач иерархической кластеризации числовых и текстовых данных больших масштабов, хранящихся в разных источниках. Сеть агентов этой системы включает агентов обнаружения знаний (DM-агентов), агентов, обеспечивающих локальный доступ к данным и агентов вычисления метаданных.

Система JAM (Java Agents for Meta-learning, [15]) – это сеть, которая реализует запуск и параллельную работу локальных обучающих и тестирующих агентов, агентов, обучающих метаклассификатор, который предназначен для объединения решений классификаторов, обученных на данных локальных источников. Каждый узел сети JAM содержит одну или несколько локальных баз данных, одного или нескольких локальных обучающих агентов, одного или нескольких агентов обучения метаклассификатора, хранилище решений локальных классификаторов и решений, импортированных ими. Каждый JAM-узел хранит также файл конфигурации приложения и графический пользовательский интерфейс. Узлы JAM-сети работают параллельно. Подробности архитектуры и технологии работы системы JAM можно найти в [18].

В [19] описана система Rarugus, предназначенная для работы с распределенными кластерами и метакластерами данных. Система построена на основе технологии мобильных агентов, которые могут перемещаться между источниками данных и перемещать данные, промежуточные результаты и модели между кластерами данных.

В тот же период времени предложено несколько технологических разработок для решения задач децентрализованного извлечения знаний из данных, которые, однако, не были имплементированы. Технология, предложенная в работе [20], ориентирована на решение сложных проблем децентрализованного извлечения знаний и машинного обучения в ситуациях, когда большие распределенные данные не могут быть перемещены и/или обработаны централизованными системами. Процедура поиска решения, реализуемая сетью агентов, использует механизм децентрализованного обучения с подкреплением, начиная с некоторого начального приближения. Варианты построения агентских систем для решения задач децентрализованного извлечения знаний и машинного обучения описываются также в [21, 22 и др.].

Заметим, что в ряде работ того времени подчеркивалось, что ключевые проблемы создания систем того класса, который рассматривается в данной работе, связаны с созданием инфраструктуры для решения прикладных задач децентрализованного машинного обучения [23]. В настоящее время о том же самом говорят, как о необходимости создания экосистем для разработки приложений этого класса.

5. Заключение

Интеграция передовых технологий отвечает естественному пути их развития. Предлагая такую интеграцию, авторы всегда надеются на синергетический эффект, который образно можно описать неравенством $2+2 > 4$. Интеграция агентских технологий, с одной стороны, и технологий децентрализованного извлечения знаний из данных и децентрализованного машинного обучения – с другой представляется важным и перспективным шагом на современном этапе развития ИИ.

Эти перспективы анализируются в работе с разных точек зрения. Как представляется автору, в работе сформулированы достаточно убедительные аргументы в пользу перспективности обсуждаемой интеграции.

Список литературы

1. Cao L. Decentralized AI: Edge Intelligence and Smart Blockchain, Metaverse, Web3, and DeSci // IEEE Intelligent Systems. June 2022. P. 6-19.
2. Gorodetsky V.I. Basic Trends of Decentralized Artificial Intelligence // Pattern Recognition and Image Analysis. 2023. Vol. 33, No. 3. P. 324-333.
3. Agent Mining Special Interesting Grou. URL: <http://www.agentmining.org> (дата обращения 22.01.2024).
4. Moemeng Ch., Gorodetsky V., Cao L Agent-Based Distributed Data Mining: A Survey // Data Mining and Multi-agent Integration. L .Cao (Ed.). Springer, 2009. P. 47-58.
5. Data Mining and Multi-agent Integration. L. Cao (Ed.). Springer, 2009. 334 p
6. Cao L., Gorodetsky V., Mitkas P.A. Agent Mining: The Synergy of Agents and Data Mining // International Journal IEEE Intelligent Systems. 2009. Vol. 24. No. 3. P. 64-72.
7. Chan Ph. K., Fan W, Stolfo S.J. Distributed Data Mining in Credit Card Fraud Detection // IEEE Intelligent Systems. 1999. Vol. 14. P. 67-74.
8. Prodromidis A.L., Chan Ph.K., Stolfo S.L. Meta-Learning in Distributed Data Mining Systems: Issues and Approaches. In: Advances of Distributed Data Mining. AAAI Press, 2000. <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.54.1896&rep=rep1&type=pdf> (дата обращения 23.12.2023).
9. May M, Saitta L. Ubiquitous Knowledge Discovery. Challenges, Techniques, Applications. Lecture Notes in Computer Science. Vol, 6202. Springer, 2010. 255 p.
10. Городецкий В.И. Поведенческие модели киберфизических систем и групповое управление // Известия ЮФУ. Технические науки. 2019. № 1 (203). С. 144-162.
11. Иогансон И.. Обзор методов федеративного обучения. CEUR Workshop Proceedings. 2023. https://www.researchgate.net/publication/376083291_Obzor_metodov_federativnogo_obucenia (дата обращения 20.12.2023).
12. Datta S., Bhaduri K., Giannella C., RWolff E., Kargupta H.. Distributed data mining in peer-to-peer networks // IEEE Internet Computing special issue on Distributed Data Mining. 2006. Vol. 10. No.4. P. 18-26.
13. Журавлев Ю.И., Рязанов В.В., Сенько О.В. Распознавание. Математические методы. Программная система. Практические применения. ФАЗИС, 2005. 159 с.
14. Городецкий В.И., Серебряков С.В. Методы и алгоритмы коллективного распознавания // Автоматика и телемеханика. 2008. № 11. С. 3-40.
15. Stolfo S., Prodromidis A.L., Tselepis S., Lee,W., Fan D.W., Chan P.K. JAM: Java agents for meta-learning over distributed databases. In: Proceedings of the 3rd International Conference on Knowledge Discovery and Data Mining. 1997. P. 74-81.
16. Panait L., Luke S. Cooperative Multi-Agent Learning: The State of the Art. Autonomous Agents and Multi-Agent Systems. 2005. Vol. 11. No. 3. P. 387-434.
17. Kargupta H., Hamzaoglu I., Stafford B. Scalable, distributed data mining using an agent based architecture // Proceedings the Third International Conference on the Knowledge Discovery and Data Mining. AAAI Press, Menlo Park, California. 1997. P. 211-214.
18. Prodromidis A.L. Management of intelligent learning agents in distributed data mining systems. Ph.D. thesis. New York: Columbia University, 1999.
19. Bailey S., Grossman R., Sivakumar H., Turinsky A. Papyrus: a system for data mining over local and wide area clusters and super-clusters // Supercomputing '99: Proceedings of the 1999 ACM/IEEE conference on Supercomputing (CDROM). ACM, New York. 1999. P. 63. DOI <http://dx.doi.org/http://doi.acm.org/10.1145/331532.331595> (дата обращения 20.12.2023).
20. Weiss G. A multiagent perspective of parallel and distributed machine learning // Agents. 1998. P. 226-230. <http://wwwbrauer.in.tum.de/~weissg/Docs/weissg-aa98.pdf> (дата обращения 20.12.2023).
21. Klusch M., Lodi S., Moro G. Agent-based distributed data mining: The KDEC scheme. AgentLink, Springer. Lecture Notes in Computer Science. 2003. Vol. 2586.
22. Dasilva J., Giannella C., Bhargava R., Kargupta H., Klusch M. Distributed data mining and agents // Engineering Applications of Artificial Intelligence. 2005. Vol. 18, No. 7. P. 791-807.
23. Gorodetskiy V., Karsaev O., Samoilov V. Infrastructural Issues for Agent-based Distributed Learning // Proceedings of the 2006 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT 2006 Workshops Proceedings). Hong Kong. 2007. P. 3-6.