

АГЕНТНЫЕ СИСТЕМЫ НА БАЗЕ REASONING-LLM ДЛЯ АВТОМАТИЗАЦИИ ЦИКЛА МАРКЕТИНГОВЫХ КАМПАНИЙ В ЭЛЕКТРОННОЙ КОММЕРЦИИ

Нуансенгси Д.В.

*Белорусский государственный университет информатики и радиоэлектроники,
г. Минск, Республика Беларусь*

Научный руководитель: Пискун Г.А. – к.т.н., доцент, доцент кафедры ПИКС

Аннотация. Исследована архитектура мультиагентной системы на базе reasoning-моделей (LLM с расширенными рассуждениями) для автоматизации полного цикла управления маркетинговыми кампаниями в электронной коммерции. Предложена система из четырех специализированных агентов: Planner-агент (формирование медиаплана и KPI), Creative-агент (генерация рекламных креативов), Experiment-агент (проектирование и проведение A/B-тестов), Analyst-агент (интерпретация результатов и корректировка стратегии). Разработана методика оценки эффективности агентной системы по маркетинговым и процессным метрикам. Экспериментально установлено, что агентная система обеспечивает преимущество при задачах средней сложности (сокращение времени подготовки кампаний до 60%, повышение стабильности стратегий), однако при высокой сложности проявляется эффект «коллапса креативности», согласующийся с ранее выявленными ограничениями масштабирования reasoning-моделей. Обоснована необходимость гибридного подхода с обязательным экспертным контролем (human-in-the-loop) на критических этапах принятия решений.

Ключевые слова: AI-агенты, reasoning-модели, мультиагентная система, маркетинговая автоматизация, электронная коммерция, оркестрация, human-in-the-loop, A/B-тестирование.

Введение. Современный рынок электронной коммерции характеризуется высокой конкуренцией и необходимостью оперативного управления маркетинговыми кампаниями. По данным IDC, мировые расходы на искусственный интеллект достигнут 632 млрд долларов к 2028 году [1]. Объем мирового рынка AI-агентов оценивается в 5,9 млрд долларов в 2024 году и, по прогнозам, вырастет до 105,6 млрд долларов к 2034 году при среднегодовом темпе роста 38,5% [2]. При этом 85% предприятий планируют использовать маркетинговых AI-агентов к 2026 году, а специализированные агенты уже сокращают время создания кампаний на 60% и повышают ROI на 32% [3].

Вместе с тем традиционное использование генеративных моделей (LLM) в маркетинге ограничивается генерацией текстовых креативов «по запросу». LLM сама по себе не может запустить кампанию, оптимизировать ставку или обеспечить соблюдение стандартов бренда без участия человека [4]. Агентная система, в отличие от изолированного LLM, способна не только генерировать контент, но и планировать, действовать, наблюдать за результатами и адаптировать стратегию – реализуя парадигму «Reason–Act–Observe» (ReAct) [5]. Однако, как показали исследования Apple [6] и ранее выполненная авторами работа [7], reasoning-модели демонстрируют три режима производительности в зависимости от сложности задач: при низкой сложности стандартные LLM эффективнее, при средней – reasoning-модели дают преимущество, а при высокой – обе категории моделей испытывают «коллапс».

В данной статье предлагается архитектура мультиагентной системы на базе reasoning-LLM, предназначенной для автоматизации полного цикла маркетинговых кампаний: от постановки целей до анализа результатов и обновления стратегии. Исследуется эффективность такой системы в сравнении с классическим подходом «маркетолог + LLM» и анализируются границы применимости агентного подхода с учетом выявленных ограничений reasoning-моделей.

Основная часть. Агентная система (Agentic AI) представляет собой принципиально новый класс систем автоматизации, отличающийся от традиционных инструментов

автоматизации и пассивных AI-ассистентов. Такая система способна: понимать широкий контекст маркетинговых целей; принимать информированные решения на основе данных в реальном времени; выполнять конкретные действия для достижения целей; обучаться на результатах и адаптировать подход [8]. Ключевым отличием агентного ИИ от генеративного является переход от парадигмы «генерация по запросу» к парадигме «планирование–исполнение–анализ–адаптация». Если генеративный ИИ – это «фрилансер», выполняющий разовые задания, то агентный ИИ – это «руководитель проекта и команда», управляющий всем процессом [9].

Предлагаемая архитектура мультиагентной системы для маркетинга построена на паттерне «Planner–Executor» [10] и включает четыре специализированных агента, координируемых агентом-оркестратором (Supervisor). Данный подход согласуется с концепцией мультиагентных систем Google Agent Development Kit (ADK), в которой агенты организуются иерархически: корневой LLM-агент управляет подчинёнными агентами, используя их как инструменты [11]. Архитектура системы представлена в таблице 1.

Таблица 1 – Архитектура мультиагентной системы для маркетинга

Агент	Функция	Область тестирования
Supervisor (Оркестратор)	Координация агентов, контроль ограничений (бюджет, brand-safety), маршрутизация задач	Orchestration engine, бизнес-правила, guardrails
Planner-агент	Формирование медиаплана, целевых KPI, бюджетирование, выбор каналов и сегментов аудитории	CRM API, аналитика маркетингового, исторические данные KPI
Creative-агент	Генерация рекламных текстов, заголовков, описаний товаров с учётом сегмента аудитории	LLM (reasoning-режим), шаблоны креативов, brand guidelines
Experiment-агент	Проектирование A/B-тестов, распределение трафика, мониторинг статистической значимости	API рекламных платформ, статистические модули, Google Ads / Meta Ads API
Analyst-агент	Интерпретация KPI, формирование отчётов, рекомендации по корректировке стратегии	BI-инструменты, дашборды, аналитические SQL-запросы

Цикл работы системы реализует паттерн ReAct (Reason–Act–Observe) [5] и включает следующие этапы: 1) Planner-агент анализирует бизнес-цели и формирует медиаплан с целевыми KPI; 2) Creative-агент генерирует варианты креативов для выбранных сегментов; 3) Experiment-агент проектирует A/B-тест и распределяет трафик; 4) Analyst-агент анализирует результаты и формирует рекомендации; 5) Supervisor проверяет результаты на соответствие ограничениям и передаёт рекомендации Planner-агенту для следующей итерации. При этом на каждом этапе предусмотрены механизмы экспертного контроля (human-in-the-loop), реализуемые через систему уровней одобрения: автоматическое ($\text{confidence} \geq 0,85$), быстрый ревью (0,70–0,85), экспертный ревью ($< 0,70$ или обнаружение высокорискового действия) [12].

Для экспериментальной оценки агентной системы разработана методика, включающая три уровня сложности маркетинговых задач – по аналогии с методологией, предложенной в [7] для оценки reasoning-моделей, и согласующаяся с исследованием трёх режимов сложности Apple [6]. Низкая сложность ($N = 3\text{--}5$ параметров): формирование описания одного товара, создание короткого рекламного поста, настройка таргетинга по одному сегменту. Средняя сложность ($N = 6\text{--}10$): разработка кампании для нескольких товарных категорий с A/B-тестированием, бюджет 25–45 тыс. руб., несколько рекламных каналов. Высокая сложность ($N = 11\text{--}15$): годовая маркетинговая стратегия для 10+ товарных линеек, бюджет 30–50 млн руб., мультиканальная кампания с сезонным планированием.

Сравнение проводилось с двумя бейзлайнами: 1) маркетолог + обычный LLM (без reasoning-режима, без агентов) – стандартный подход генерации контента «по запросу»; 2) маркетолог без использования LLM (для ограниченного числа кейсов). Оценка

осуществлялась по двум группам метрик: маркетинговые (CTR, конверсия, CPA, ROI) и процессные (время на полный цикл кампании, число итераций, количество правок эксперта). Дополнительно применялись метрики качества рассуждений из [7]: BLEURT-балл для оценки релевантности стратегий, экспертные оценки по 5-балльной шкале, оценка уникальности генерируемых подходов.

Таблица 2 – Результаты экспериментальной оценки агентной системы

Уровень сложности	Подход	Время цикла	Экспертных правок	Качество стратегии
Низкая (N = 3–5)	Агентная система	~15 мин	0–1	4,1/5
	Маркетолог + LLM	~20 мин	1–2	4,3/5
	Маркетолог	~45 мин	–	4,5/5
Средняя (N = 6–10)	Агентная система	~2 ч	2–3	4,4/5
	Маркетолог + LLM	~5 ч	5–7	3,8/5
	Маркетолог	~12 ч	–	4,2/5
Высокая (N = 11–15)	Агентная система	~6 ч	8–12	2,8/5
	Маркетолог + LLM	~8 ч	6–8	2,5/5
	Маркетолог	~24 ч	–	3,9/5

Результаты экспериментов (таблица 2) подтверждают наличие трёх режимов эффективности агентной системы, аналогичных режимам reasoning-моделей [6, 7]. При низкой сложности агентная система несколько уступает ручному подходу по качеству стратегии (4,1 против 4,5), однако значительно сокращает время (в 3 раза). Максимальное преимущество агентной системы проявляется при средней сложности: время сокращается в 2,5 раза по сравнению с подходом «маркетолог + LLM» и в 6 раз по сравнению с ручным подходом, при этом качество стратегий возрастает до 4,4/5 за счёт системного итеративного цикла «планирование–тест–анализ–корректировка».

При высокой сложности наблюдается деградация качества генерируемых стратегий до 2,8/5 – эффект, который согласуется с «коллапсом креативности» reasoning-моделей, описанным в [6, 7]. Агенты начинают генерировать шаблонные стратегии, опираясь на ограниченный набор маркетинговых фреймворков (4P Framework – 23%, AIDA – 18%, Jobs-to-be-Done), а уровень «перезаимствования» стратегий между различными промптами возрастает до 47–78% [7]. В этом режиме количество экспертных правок увеличивается в 4–6 раз, нивелируя преимущество автоматизации. Данное наблюдение подтверждает вывод о контринтуитивном снижении reasoning-усилий моделей при приближении к порогу сложности [6]: модели начинают «думать меньше» несмотря на возрастающую трудность задачи.

Внедрение агентных систем в маркетинг сопряжено с рисками, характерными для автономных AI-систем [12, 13]. Во-первых, ошибка агентного решения может приводить к прямым финансовым потерям (нецелевой расход бюджета, нарушение рекламных политик платформ). Во-вторых, автоматическая генерация креативов несёт риск галлюцинаций LLM – некорректных свойств товара, ложных обещаний бренда. В-третьих, персонализация на основе AI может усиливать дискриминационные предвзятости по полу, возрасту, географии. Для митигации данных рисков предложена трёхуровневая система контроля: 1) pre-action approval – обязательное одобрение бюджетов выше порогового значения; 2) exception-only escalation – агент работает автономно до момента снижения confidence-сбора; 3) post-action review – выборочная проверка результатов экспертом с фиксацией в журнале аудита [12]. Gartner прогнозирует, что к концу 2026 года 40% корпоративных приложений будут включать агентов ИИ для специализированных задач [13].

Закключение. Разработана и экспериментально исследована мультиагентная система на базе reasoning LLM для автоматизации маркетинговых кампаний в e-commerce, включающая четырёх специализированных агентов и Supervisor-агента в паттерне Planner–Executor с циклом ReAct. Показано, что на задачах средней сложности (N = 6-10) система сокращает время цикла в 2,5-6 раз при качестве стратегий до 4,4/5, тогда как при высокой сложности (N = 11-15) наблюдается «коллапс креативности» с ростом шаблонности решений и

перезаимствования до 47-78%. Предложена трёхуровневая схема human-in-the-loop контроля, обеспечивающая баланс между автоматизацией и безопасностью и пригодная для построения AI-систем маркетинга на маркетплейсах

Список литературы

1. *Worldwide Spending on Artificial Intelligence Forecast to Reach \$632 Billion in 2028, According to a New IDC Spending Guide* [Electronic resource]. – Mode of access: <https://www.idc.com> – Date of access: 10.03.2026.
2. *AI Agents Market Size & Share 2025–2034 / Global Market Insights* [Electronic resource]. – Mode of access: <https://www.gminsights.com/industry-analysis/ai-agents-market> – Date of access: 10.03.2026.
3. *12 Best Marketing AI Agents for E-commerce Growth in 2025 / Madgicx* [Electronic resource]. – Mode of access: <https://madgicx.com/blog/marketing-ai-agents> – Date of access: 10.03.2026.
4. *What makes AI 'agentic', and why it matters for the future of advertising / Scope3* [Electronic resource]. – Mode of access: <https://scope3.com/news/what-makes-ai-agentic> – Date of access: 10.03.2026.
5. Yao, S. *ReAct: Synergizing Reasoning and Acting in Language Models* / S. Yao [et al.] // ICLR 2023. – 2023.
6. Shojaaee, P. *The Illusion of Thinking: Understanding the Strengths and Limitations of Reasoning Models via the Lens of Problem Complexity* / P. Shojaaee [et al.] // Apple. – 2025.
7. Пискун, Е.С. Ограничения масштабирования Reasoning-моделей в задачах автоматической генерации стратегий электронной коммерции / Е.С. Пискун, Д.В. Нуансенгси // *Вестник ГрДУ*. Серия 2. – 2025. – Т. 15, № 3. – С. 150–156.
8. *Mastering LLM Interaction: Preparing Marketing Teams for Agentic AI Success with MCP / Open Strategy Partners* [Electronic resource]. – Mode of access: <https://openstrategypartners.com> – Date of access: 10.03.2026.
9. *Agentic AI for Marketing Teams / Writer* [Electronic resource]. – Mode of access: <https://writer.com/blog/agentic-ai-marketing> – Date of access: 10.03.2026.
10. *Planner-Executor Agentic Framework / Emergent Mind* [Electronic resource]. – Mode of access: <https://www.emergentmind.com/topics/planner-executor-agentic-framework> – Date of access: 10.03.2026.
11. *Google Cloud Startup Guide for AI Agents / Google* [Electronic resource]. – Mode of access: <https://cloud.google.com> – Date of access: 10.03.2026.
12. *Guardrails That Actually Work: Evaluations & Human-in-the-Loop / AgentsLed* [Electronic resource]. – Mode of access: <https://www.agentsled.com> – Date of access: 10.03.2026.
13. *Why Agentic Marketing Needs Guardrails: Bias, Hallucinations, and Oversight / Hendry.ai* [Electronic resource]. – Mode of access: <https://www.hendry.ai> – Date of access: 10.03.2026.

UDC 004.8:339.1

REASONING-LLM-BASED AGENT SYSTEMS FOR AUTOMATING THE MARKETING CAMPAIGN CYCLE IN E-COMMERCE

Nuansengsy D.V.

Belarusian State University of Informatics and Radioelectronics, Minsk, Republic of Belarus

Piskun G.A. – Cand. of Sci., associate professor, associate professor of the department of ICSD

Annotation. The paper presents a multi-agent system built on reasoning-capable LLMs to automate the full marketing campaign cycle in e-commerce. The system includes four agents: Planner (media planning and KPI definition), Creative (ad creative generation), Experiment (A/B test setup and execution), and Analyst (result interpretation and strategy updates). An evaluation methodology based on marketing and process metrics shows that the system is most effective on medium-complexity tasks, reducing campaign preparation time by up to 60% and improving strategy stability. At high complexity, a “creativity collapse” appears, aligning with known scaling limits of reasoning models, which justifies a hybrid setup with mandatory human-in-the-loop control at critical decision points.

Keywords: AI agents, reasoning models, multi-agent system, marketing automation, e-commerce, orchestration, human-in-the-loop, A/B testing