ГИБРИДНОЕ ИЗВЛЕЧЕНИЕ ИМЕНОВАННЫХ СУЩНОСТЕЙ И АНСАМБЛЕВОЕ ОБНАРУЖЕНИЕ АНОМАЛИЙ НА ГРАФЕ ЗНАНИЙ СУБЪЕКТОВ

Болтаев Ж.Э.[1], Абдирайимов Х.Б.[1],
Марахимов А.Р.[2], д.т.н., профессор, Худайбергенов К.К.[3], PhD
[1] Термезский государственный университет, г. Термез
[2] Ташкентский государственный технический университет им. И. Каримова, г. Ташкент
[3] Международный университет Кимё, г. Ташкент

Ключевые слова: гибридное извлечение сущностей, граф знаний, ансамблевый детектор, графовые нейронные сети, значения Шепли, объяснимый ИИ.

Проблема. Существующие подходы к мониторингу гетерогенных данных решают лишь фрагменты задачи: одни системы оптимизированы для извлечения именованных сущностей из неструктурированного текста, но не обеспечивают графового анализа связей между субъектами; другие строят графы знаний, но не предоставляют интерпретируемых решений на индивидуальном уровне; третьи обнаруживают финансовые аномалии, но требуют полностью структурированного входа и неприменимы к реальным многоскриптовым текстам. Ни один из подходов не обеспечивает полного конвейера от гетерогенного текста до объяснимого решения с формальной атрибуцией вклада каждого признака. Необходима интегрированная система, объединяющая извлечение сущностей, построение графа связей, обнаружение аномалий и формально обоснованную объяснимость в едином конвейере.

Предлагаемое решение. Разработаны три интегрированных компонента архитектуры тезиса 1 — экстрактор сущностей M, построитель графа знаний G и ансамблевый детектор A — совместно с модулем объяснимости E на основе теории кооперативных игр.

Гибридное извлечение сущностей. Экстрактор реализован как объединение правиловой и нейросетевой компонент с непересекающимися доменами типов:

$$M(t) = R(t) \cup M_{neur}(N(t)), \quad types(R) \cap types(M_{neur}) = \emptyset.$$

Компонента R обрабатывает форматированные сущности (идентификационные номера, реквизиты, суммы); компонента M_{neur} на основе XLM-RoBERTa [1] — контекстно-зависимые (имена, организации, географические объекты). Непересечение доменов исключает конфликты разметки и гарантирует сохранение минимальной точности компонент при их объединении.

Граф знаний субъектов. Построен граф $\mathcal{G}$ = (V, E, Λ) с типизацией рёбер по онтологии из пяти классов отношений: учредительские, родственные, транзакционные, имущественные и процессуальные. Для корпуса финансового мониторинга граф содержит 78 вершин и 3 256 рёбер. Типизация обеспечивает автоматическое выявление скрытых связей через цепочки длины k > 1, что критически важно для обнаружения схем с промежуточными звеньями.

Ансамблевый детектор с объяснимостью. Детектор A(v) = λ_R A_rules(v) + λ_G A_GNN(v) + λ_T A_TS(v) объединяет экспертные правила, графовую нейронную сеть [2] и анализатор временны́х паттернов. Модуль объяснимости E атрибутирует вклад каждого признака через значения Шепли [3]:

$$\varphi_i = \sum_{S \subseteq \Phi \setminus \{i\}} \frac{|S|!\,(n - |S| - 1)!}{n!} [\nu(S \cup \{i\}) - \nu(S)]$$

Значения удовлетворяют аксиомам эффективности, симметрии, нулевого игрока и линейности, формируя «карту причин» каждого решения.

Результаты. Валидация на 76 642 записях (25 источников, κ = 0,9937) с тестом Макнемара относительно эталонной системы (χ^2 = 10 490, $p < 10^{-3}$) приведена в таблице 1.

Компонент	**Метрика**	**Результат**
Гибридный экстрактор M	F_1 (gold, K-Fold)	0,998 ± 0,001
Многоязычный baseline	F_1	0,009
Граф знаний G	|V| / |E|	78 / 3 256
Ансамбль A	AUC (unseen)	0,774

Таблица 1. Сводка экспериментальных результатов.

Провал многоязычного baseline (F_1 = 0,009) подтверждает фундаментальную непригодность стандартных предобученных моделей для многоскриптовых финансовых текстов без специализированной нормализации. Доминирующим фактором точности является скриптовая унификация кириллицы и латиницы (ΔLOO = −3,32 п.п.): 42,7 % записей содержат смешение скриптов, при этом 87,3 % ошибок без этой компоненты концентрируются в узбекско-кириллических контекстах. Ансамблевый детектор аномалий демонстрирует устойчивость компонент: удаление графовой составляющей снижает AUC на 0,031, правиловой — на 0,018, временно́й — на 0,012, что подтверждает их комплементарный вклад. Модуль объяснимости на основе значений Шепли формирует структурированную карту причин каждого решения, обеспечивая полную прослеживаемость аналитики на уровне отдельных признаков.

Выводы. (1) Разработан гибридный экстрактор именованных сущностей с непересекающимися доменами правиловой и нейросетевой компонент, обеспечивающий F_1 = 0,998 на реальном корпусе финансового мониторинга. (2) Построен граф знаний субъектов с формальной онтологией пяти классов отношений (78 вершин, 3 256 рёбер), допускающий автоматическое выявление скрытых связей через цепочки длины k > 1. (3) Реализован ансамблевый детектор аномалий с AUC = 0,774 и доказанной комплементарностью трёх компонент — экспертных правил, графовой нейронной сети и анализатора временны́х паттернов. (4) Интегрирован модуль объяснимости на основе значений Шепли, формирующий формально-обоснованную карту причин каждого решения с соблюдением аксиом эффективности, симметрии и линейности. (5) Совместно с архитектурой тезиса 1 формируется замкнутый контур интеллектуального анализа гетерогенных слабоструктурированных данных, допускающий перенос на смежные предметные области — образовательный мониторинг, медицинские информационные системы, логистические и таможенные платформы.

Литература

1. Conneau A. et al. XLM-RoBERTa // Proc. ACL. 2020. P. 8440–8451.
2. Veličković P. et al. Graph Attention Networks // Proc. ICLR. 2018.
3. Shapley L.S. A value for n-person games // Contr. Theory of Games II. Princeton, 1953. P. 307–317.
4. Lundberg S., Lee S. Interpreting model predictions // Proc. NeurIPS. 2017. P. 4765–4774.

5. Hamilton W., Ying R., Leskovec J. Inductive representation learning on large graphs // Proc. NeurIPS. 2017. P. 1024–1034.
6. Kipf T.N., Welling M. Semi-supervised classification with graph convolutional networks // Proc. ICLR. 2017.
7. McNemar Q. Sampling error // Psychometrika. 1947. V. 12(2). P. 153–157.