

УДК: 004.89

**Худайберидева Г. Б., магистр, ассистент кафедры
«Информатика и информационные технологии»**

Московский Политехнический Университет,

Россия, г. Москва

**Кожухов Д. А., магистр, ассистент кафедры
«Информатика и информационные технологии»**

Московский Политехнический Университет,

Россия, г. Москва

**Пименкова А. А., студент-бакалавр кафедры
«Информатика и информационные технологии»**

Московский Политехнический Университет,

Россия, г. Москва

ПРОГНОСТИЧЕСКИЕ ИИ-МОДЕЛИ С ОБРАТНОЙ СВЯЗЬЮ НА ОСНОВЕ АНАЛИЗА ТЕХНОЛОГИЧЕСКОГО ДОЛГА ДЛЯ УПРАВЛЕНИЯ ПРОЕКТНЫМИ РИСКАМИ

Аннотация: Исследование посвящено разработке концепции предиктивных ИИ-моделей, ориентированных на выявление и прогнозирование проектных рисков посредством анализа скрытого технологического долга (ТД) в кодовой базе и процессах разработки программного обеспечения. Предлагаемый подход предполагает создание систем с обратной связью, способных выявлять паттерны, приводящие к долгосрочным негативным последствиям, часто упускаемые экспертами из-за когнитивных ограничений. Основное внимание уделяется необходимости разработки специфических метрик ТД и алгоритмов машинного обучения для их анализа, выходящих за рамки текущих промышленных стандартов и существующих научных исследований. Инновационность заключается в способности модели к прогнозированию будущих проблем на основе анализа текущего состояния технического контекста проекта.

Ключевые слова: технологический долг, предиктивная аналитика, управление рисками, искусственный интеллект, машинное обучение, качество программного обеспечения, технические метрики, когнитивные ограничения, обратная связь, прогнозные модели.

Khudaiberideva G. B.

master and department assistant at the department of

"Computer Science and Information Technology"

Moscow Polytechnic University

Moscow, Russia

Kozhukhov D. A.

master and department assistant at the department of

"Computer Science and Information Technology"

Moscow Polytechnic University

Moscow, Russia

Pimenkova A. A.

bachelor's student at the department of

"Computer Science and Information Technology"

Moscow Polytechnic University

Moscow, Russia

**PREDICTIVE AI FEEDBACK MODELS BASED ON
TECHNOLOGICAL DEBT ANALYSIS FOR PROJECT RISK
MANAGEMENT**

Annotation: The research is devoted to the development of the concept of predictive AI models focused on identifying and predicting project risks through the analysis of hidden technological debt (TD) in the code base and software development processes. The proposed approach involves the creation of feedback systems capable of identifying patterns that lead to long-term negative consequences, often overlooked by experts due to cognitive limitations. The main focus is on the need to develop specific TD metrics and machine learning

algorithms for their analysis that go beyond current industry standards and existing scientific research. Innovation lies in the ability of the model to predict future problems based on an analysis of the current state of the technical context of the project.

***Keywords:** technological debt, predictive analytics, risk management, artificial intelligence, machine learning, software quality, technical metrics, cognitive limitations, feedback, predictive models.*

Введение

Современная разработка программного обеспечения характеризуется возрастающей сложностью и скоростью изменений, что неизбежно ведет к накоплению технологического долга. Под технологическим долгом понимается совокупность решений, принимаемых для краткосрочной выгоды в ущерб долгосрочной поддержке и развитию системы [1]. Неявный характер значительной части ТД затрудняет его своевременное обнаружение и оценку последствий традиционными методами. Текущие подходы к управлению рисками проектов зачастую реактивны, фокусируясь на уже возникших проблемах, а не на их прогнозировании [2]. Существует критическая потребность в инструментах, способных проактивно идентифицировать паттерны, указывающие на формирование потенциально опасного ТД, способного перерасти в критические риски для проекта: срывы сроков, превышение бюджета, снижение качества и отказ системы. Развитие методов искусственного интеллекта, особенно машинного обучения и анализа данных, открывает новые возможности для создания предиктивных моделей, способных анализировать сложные взаимосвязи в технических артефактах и процессах разработки [3]. Целью данной работы является концептуализация ИИ-модели с обратной связью, способной прогнозировать проектные риски на основе анализа скрытых форм технологического долга через разработку специализированных метрик и алгоритмов, преодолевающих ограничения человеческой экспертизы.

Проблематика технологического долга как источника проектных рисков

Технологический долг представляет собой многогранное явление, включающее в себя долг проектирования, кода, тестирования, документации и инфраструктуры [4]. Особую опасность для проектов представляют скрытые формы ТД, которые не фиксируются явно в системах отслеживания и остаются вне поля зрения менеджеров и архитекторов. Накопление такого долга происходит постепенно, часто в результате компромиссных решений, принятых под давлением сроков или недостаточной информированности [5]. Паттерны, приводящие к высокому риску, могут быть крайне сложны для выявления человеком из-за когнитивных ограничений: невозможности обработки больших объемов разнородных данных, склонности к подтверждению своей точки зрения и недооценки долгосрочных последствий локальных решений [6]. Существующие инструменты статического анализа кода и метрики качества (такие как цикломатическая сложность, покрытие тестами, поддержка стандартов кодирования) направлены преимущественно на оценку текущего состояния, но обладают ограниченной прогностической силой в отношении будущих проблем, вызванных комплексным взаимодействием факторов [7]. Стандартизированные подходы к оценке ТД, такие как SQALE или SIG, предоставляют полезные срезы информации, но не моделируют динамику накопления долга и его влияние на будущую трудоемкость или стабильность системы [8]. Необходимость выхода за рамки существующих метрик и создания моделей, способных к обучению на исторических данных проекта и выявлению специфических "сигнатур" риска, является ключевой для предиктивного управления.

Концепция ИИ-модели с обратной связью для предиктивного анализа рисков

Предлагаемая ИИ-модель базируется на принципе непрерывного анализа и прогнозирования с интегрированным контуром обратной связи. Ее ядром является способность к выявлению сложных, неочевидных корреляций и каузальных связей между наблюдаемыми техническими характеристиками проекта и возникновением критических инцидентов или значительных затрат в будущем. Инновационность подхода заключается в фокусировке на прогнозировании именно тех рисков, которые происходят из латентного ТД, а не на общем анализе качества [9]. Модель требует разработки нового класса предиктивных метрик, выходящих за рамки традиционных. Такие метрики должны количественно оценивать не только состояние артефактов (код, тесты, документация), но и динамику их изменения, взаимное влияние, а также контекстуальные факторы процесса разработки (частота коммитов, паттерны ревью кода, история изменений в модулях с высоким риском) [10]. Для обработки этих метрик и построения прогнозов необходимы специализированные алгоритмы машинного обучения. Алгоритмы, основанные на обучении с учителем (например, градиентный бустинг, рекуррентные нейронные сети), могут быть применены для прогнозирования вероятности возникновения инцидентов или резкого роста затрат на основе исторических данных проекта [11]. Методы обучения без учителя (кластеризация, анализ аномалий) способны выявлять неочевидные паттерны в структуре кода или процессах, указывающие на формирование скрытых очагов ТД [12]. Ключевым элементом модели является механизм обратной связи: прогнозы модели и последующие реальные события (или их отсутствие) фиксируются и используются для переобучения и уточнения алгоритмов, повышая их точность и адаптивность к специфике конкретного проекта или домена [13].

Архитектурные аспекты и методология разработки метрик

Реализация концепции требует проектирования архитектуры, интегрирующей сбор данных из разнородных источников (системы контроля версий, трекеры задач, CI/CD пайплайны, системы мониторинга), их преобразование в комплексные предиктивные метрики и применение алгоритмов машинного обучения. Разработка адекватных предиктивных метрик является фундаментальной задачей. Эти метрики должны отражать потенциальную "дороговизну" будущего обслуживания или риск отказа, а не только текущее нарушение стандартов [14]. Примеры таких метрик могут включать: "индекс энтропии изменений" (хаотичность истории модификаций модуля), "потенциал каскадного отказа" (оценка взаимозависимостей и их устойчивости), "коэффициент скрытой сложности" (расхождение между воспринимаемой и реальной сложностью на основе анализа зависимостей и паттернов вызовов), "динамику накопления антипаттернов" [15]. Каждая метрика требует строгого обоснования ее связи с потенциальным риском и валидации на исторических данных. Применение алгоритмов машинного обучения к этим метрикам позволяет строить многомерные модели риска. Важным аспектом является интерпретируемость результатов модели. Прогнозы должны сопровождаться указанием на ключевые факторы, внесшие наибольший вклад в оценку риска, что позволяет разработчикам и менеджерам принимать обоснованные решения по рефакторингу или изменению процессов [16]. Архитектура должна обеспечивать возможность адаптации метрик и моделей к особенностям различных типов проектов (веб-приложения, встроенные системы, высоконагруженные бэкенды) и технологических стеков.

Научные и практические вызовы внедрения

Внедрение предиктивных ИИ-моделей на основе анализа ТД сопряжено с рядом значительных вызовов. Научная проблема заключается в отсутствии устоявшихся теоретических моделей, описывающих сложные причинно-следственные связи между конкретными проявлениями ТД и отдаленными во времени негативными последствиями для проекта [17]. Необходимы фундаментальные исследования для установления этих связей и верификации предлагаемых предиктивных метрик. Проблема качества и доступности данных также является критической. Для обучения и функционирования модели требуются детальные исторические данные высокого качества, включающие не только технические артефакты, но и информацию о возникших проблемах, затратах на их устранение и контексте разработки [2]. Сбор и согласование таких данных из различных инструментальных цепочек представляет сложную инженерную задачу. Существуют методологические вызовы, связанные с интеграцией прогнозов модели в реальные процессы управления проектами. Прогнозы носят вероятностный характер и требуют интерпретации в контексте других факторов проекта [10]. Необходимо разработать подходы к представлению результатов модели (например, через "тепловые карты" риска модулей или временные прогнозные графики) и процедуры принятия решений на их основе. Этические аспекты, такие как прозрачность работы алгоритма и минимизация потенциальных смещений в данных, также требуют пристального внимания [16]. Преодоление этих вызовов требует тесного сотрудничества исследователей в области программной инженерии, машинного обучения и специалистов-практиков.

Заключение

Концепция ИИ-моделей с обратной связью для прогнозирования проектных рисков через анализ скрытого технологического долга представляет перспективное направление в области управления разработкой программного обеспечения. Основной тезис заключается в

том, что предиктивный потенциал таких моделей существенно превосходит возможности традиционных методов анализа и экспертных оценок, ограниченных когнитивными барьерами человека. Ключевым условием реализации этой концепции является разработка специализированных предиктивных метрик технологического долга, способных количественно оценить потенциал будущих проблем, и создание адаптивных алгоритмов машинного обучения для их анализа в динамике. Инновационность подхода определяется его ориентацией на выявление сложных, неочевидных паттернов в данных, указывающих на формирование критического ТД. Несмотря на наличие значительных научных и практических вызовов, связанных с валидацией метрик, обеспечением качества данных, интерпретацией результатов и интеграцией модели в процессы управления, потенциальная выгода от внедрения подобных систем является существенной. Прогностические способности модели могут способствовать переходу от реактивного к проактивному управлению технологическим долгом, минимизации рисков срыва сроков, превышения бюджета и снижения качества программных продуктов. Дальнейшие исследования должны быть сосредоточены на разработке и эмпирической валидации предлагаемых предиктивных метрик ТД, исследовании применимости различных классов алгоритмов машинного обучения к задаче прогнозирования рисков и создании методологий эффективного использования результатов прогнозирования в практиках управления проектами разработки программного обеспечения.

СПИСОК ЛИТЕРАТУРЫ:

1. Cunningham W. The WyCash Portfolio Management System // OOPSLA'92 Experience Report. 1992.
2. Alves N.S.R., Mendes T.S., de Mendonça M.G., Spinola R.O., Shull F., Seaman C. Identification and management of technical debt: A systematic mapping study // Information and Software Technology. 2016. Vol. 70. P. 100–121.

3. Zhang F., Hassan S., McIntosh S., Zou Y. The use of summation to aggregate software metrics hinders the performance of defect prediction models // IEEE Transactions on Software Engineering. 2017. Vol. 43, № 5. P. 476–491.
4. Kruchten P., Nord R.L., Ozkaya I. Technical debt: From metaphor to theory and practice // IEEE Software. 2012. Vol. 29, № 6. P. 18–21.
5. Besker T., Martini A., Bosch J. Managing architectural technical debt: A unified model and systematic literature review // Journal of Systems and Software. 2018. Vol. 135. P. 1–16.
6. Kahneman D. Thinking, Fast and Slow. Farrar, Straus and Giroux, 2011. 499 p.
7. ISO/IEC 25010:2011 Systems and software engineering – Systems and software Quality Requirements and Evaluation (SQuaRE) – System and software quality models.
8. Letier E., Stefan D., Earl T. Uncertainty Risk and Information Value in Software Requirements and Architecture // Proceedings of the 36th International Conference on Software Engineering (ICSE '14). 2014. P. 883–894.
9. Zazworka N., Shaw M.A., Shull F., Seaman C. Investigating the impact of design debt on software quality // Proceedings of the 2nd Workshop on Managing Technical Debt (MTD '11). 2011. P. 17–23.
10. Rahman F., Devanbu P. How, and why, process metrics are better // Proceedings of the 2013 International Conference on Software Engineering (ICSE '13). 2013. P. 432–441.
11. Kim S., Zimmermann T., Whitehead Jr. E.J., Zeller A. Predicting faults from cached history // Proceedings of the 29th International Conference on Software Engineering (ICSE '07). 2007. P. 489–498.
12. D'Ambros M., Lanza M., Robbes R. An extensive comparison of bug prediction approaches // Proceedings of the 7th IEEE Working Conference on Mining Software Repositories (MSR '10). 2010. P. 31–41.

13. Bosch J., Olsson H.H., Crnkovic I. Engineering AI Systems: A Research Agenda // Artificial Intelligence Paradigms for Smart Cyber-Physical Systems. 2021. P. 1–19.
14. Martini A., Bosch J. The danger of architectural technical debt: Contagious debt and vicious circles // Proceedings of the 12th Working IEEE/IFIP Conference on Software Architecture (WICSA '15). 2015. P. 1–10.
15. ГОСТ Р 57580.1-2017 Национальный стандарт Российской Федерации. Системы и программная инженерия. Качество архитектуры программного средства. Часть 1. Характеристики качества и их показатели.
16. Arpteg A., Brinne B., Crnkovic-Friis L., Bosch J. Software Engineering Challenges of Deep Learning // Proceedings of the 44th Euromicro Conference on Software Engineering and Advanced Applications (SEAA '18). 2018. P. 50–59.
17. Li Z., Avgeriou P., Liang P. A systematic mapping study on technical debt and its management // Journal of Systems and Software. 2015. Vol. 101. P. 193–220.