

ОТЗЫВ

официального оппонента Зуева Евгения Александровича
на диссертацию Головешкина Алексея Валерьевича
на тему «Устойчивая алгоритмическая привязка к коду программы»,
представленную на соискание учёной степени кандидата технических наук
по специальности 2.3.5 — математическое и программное обеспечение
вычислительных систем, комплексов и компьютерных сетей.

Диссертация Головешкина А.В. посвящена решению задачи устойчивой алгоритмической привязки к коду программы. Также решается вспомогательная задача легковесного парсинга программ.

Целью диссертационного исследования является разработка моделей и алгоритмов, позволяющих сконструировать описание участка кода программы по абстрактному синтаксическому дереву («привязаться» к коду), сохранить это описание и впоследствии алгоритмически найти по нему данный участок в отредактированной программе («перепривязаться»). Требуемая «устойчивость» привязки заключается в том, что искомый код должен быть найден всегда, за исключением случаев, когда он был удалён в ходе редактирования. На базе указанных моделей и алгоритмов реализуется панель разметки кода, интегрируемая в различные среды разработки.

Актуальность работы заключается в том, что изучение кода с целью поиска участков, имеющих отношение к решаемой задаче (к прорезающей функциональности, над которой ведётся работа), занимает у программиста в несколько раз больше времени, чем собственно написание кода. Собранную информацию важно не потерять, чтобы не заниматься повторными поисками. Ситуации, когда данная информация теряется, возникают часто: программист не работает над задачей непрерывно, переключается на другие задачи и другие виды деятельности, теряя «рабочее состояние» текущей задачи. Устойчивая привязка к коду позволяет сохранить информацию о расположении участков кода, нужных программисту, и впоследствии автоматически найти эти участки. В долгосрочной перспективе это решает проблему отсутствующей или устаревшей документации: с участками кода, к которым произведена привязка, можно связать пометки и дополнительную информацию, построив тем самым разметку кода.

Наиболее важными **результатами**, полученными в работе, на мой взгляд, являются следующие:

- 1) предложенный метод легковесного парсинга на основе упрощённых LL(1) и LR(1) грамматик, использующий модифицированные алгоритмы LL(1) и LR(1) синтаксического анализа;
- 2) реализованный генератор легковесных парсеров LanD со встроенным языком описания легковесных грамматик;
- 3) разработанный метод устойчивой алгоритмической привязки к меняющемуся коду на основе контекстов, использующий предложенные автором модели и алгоритмы;
- 4) реализованная на основе этих алгоритмов практически применимая панель разметки кода, интегрируемая в различные среды разработки;
- 5) предложенный метод учёта многострочных фрагментов кода в абстрактном синтаксическом дереве программы.

Результаты 1, 3 и 5 образуют **научную новизну** диссертационного исследования.

Практическая значимость полученных Головешкиным А.В. результатов заключается в практической применимости разработанного им генератора легковесных парсеров и панели разметки кода. Генератор легковесных парсеров LanD и одноимённый язык описания грамматик позволяют создавать простые и короткие грамматики промышленных языков программирования (автор приводит примеры грамматик для языков C#, Java и входного языка генератора анализаторов yacc). Генерируемые парсеры могут быть использованы в задачах обратной инженерии программ, при разборе кода с ошибками и т. д. Панель разметки кода может применяться в задачах разработки и сопровождения программ, служить для ускорения навигации по коду и сохранения знания о предназначении его участков с последующим обменом этим знанием внутри коллектива разработчиков. Также разметка может быть использована при обучении программированию.

Достоверность полученных результатов обеспечивается использованием известных и проверенных положений и методов теории алгоритмов, теории формальных языков и грамматик, математической строгостью изложения. Для проверки результатов проводятся вычислительные эксперименты, практические результаты подтверждены внедрениями. Результаты исследования апробированы на 8 всероссийских и международных конференциях, на 3 научных семинарах, опубликованы в 10 печатных работах, из которых 1 статья проиндексирована в

международной базе данных Scopus, 4 статьи опубликованы в журналах из перечня ВАК. Имеются 3 свидетельства о государственной регистрации программы для ЭВМ.

Диссертация состоит из введения, пяти глав, заключения и списка литературы. Общий объём диссертации составляет 170 страниц текста с 21 рисунком и 12 таблицами. Библиография содержит 162 наименования.

Во введении даются определения основных понятий, вводимых в диссертации: «привязка», «перепривязка», «разметка». Обосновывается актуальность диссертационного исследования, анализируется степень разработанности темы исследования, формулируются цели и задачи работы, научная новизна и практическая значимость; приводятся данные об апробации работы и о публикациях, в которых изложены результаты диссертации; формулируются положения, выносимые на защиту.

В первой главе проводится обзор литературы по теме исследования. Рассматриваются работы, посвящённые проблематике прорезающих функциональностей как таковых, вопросам изучения кода, поиска информации о назначении участков кода, сохранения собранной информации. Приводятся сведения об инструментальных средствах, предложенных научным сообществом для упрощения исследования кода в процессе разработки программы. Проводится обзор исследований, посвящённых проблемам, смежным с проблемой устойчивой привязки к коду, а также работ, посвящённых легковесному парсингу программ. Для каждой из рассматриваемых групп работ автор формулирует связь с решаемой в диссертационном исследовании задачей, тем самым подчёркивая важность проведённого диссертационного исследования.

Во второй главе рассматривается задача легковесного парсинга кода для построения абстрактного синтаксического дерева, достаточного для использования в задаче привязки к коду. Для случаев LL(1) и LR(1) вводятся формальные определения легковесной грамматики со специальным терминальным символом A_{μ} и упрощённой грамматики — легковесной грамматики с символом A_{μ} , строящейся по некоторой «полной» грамматике. Символ A_{μ} используется вместо явного описания структуры областей программы, несущественных для целей привязки. Автор отмечает принципиальные отличия вводимого им подхода от ближайших аналогов, по-своему вводящих концепцию символа A_{μ} . Для работы с упрощёнными грамматиками модифицируются алгоритмы LL(1) и LR(1) синтаксического анализа. Доказывается, что парсер, сгенерированный по

упрощённой LL(1) грамматике, разбирает все правильные программы из «полного» языка, и что любая легковесная LL(1) или LR(1) грамматика является упрощённой относительно некоторого множества «полных» грамматик. Формулируется практический способ разработки легковесной грамматики: грамматика пишется с нуля и итеративно уточняется с тем, чтобы в итоге она стала упрощённой для грамматики, порождающей, как минимум, правильные программы на целевом языке. В разделе экспериментов демонстрируется разработка упрощённой LL(1) грамматики для языка C# на разработанном автором языке описания легковесных грамматик LanD.

В третьей главе вводятся элементы «синтаксического сахара» для языка LanD, позволяющие писать более короткие и понятные грамматики. Для случаев LL(1) и LR(1) предлагаются алгоритмы восстановления от ошибки, основанные на обработке Aну. Анализируется влияние восстановления от ошибок на сложность алгоритмов парсинга, делается вывод о том, что в среднем сложность можно по-прежнему считать линейной. В разделе экспериментов демонстрируется успешное применение легковесных LL(1) и LR(1) парсеров языков C# и Java для разбора крупных промышленных проектов.

В четвёртой главе описываются модели и алгоритмы, разработанные для устойчивой привязки к синтаксическим элементам программы — участкам кода, соответствующим некоторым нетерминальным символам легковесной грамматики. Вводится шестиэлементная модель для описания таких участков (точек привязки), состоящая из типа (нетерминального символа, соответствующего участку) и пяти структур, называемых «контекстами». Структура каждого из контекстов описывается подробно. Вводится алгоритм перепривязки, проводящий сравнение ранее сохранённых описаний точек привязки одного типа, расположенных в одном файле, с описаниями, которые можно построить для элементов того же типа, присутствующих в отредактированной версии файла. Подробно рассматриваются алгоритмы поконтекстных сравнений, алгоритм-отсечение, обрабатывающий простые случаи поиска, эвристики для настройки весовых коэффициентов, отражающих важность каждого из контекстов в конкретной ситуации. Анализируется сложность алгоритма перепривязки, приводятся результаты замеров производительности. Экспериментально оценивается устойчивость производимой привязки, а также проводится сравнение с ближайшим аналогом.

В пятой главе устойчивая привязка к синтаксическим элементам расширяется на «произвольные» однострочные и многострочные участки кода.

Привязка к строке происходит за счёт привязки к объёмлющему синтаксическому элементу и расширения описания этого элемента дополнительным «контекстом строки». Для контекстов строки приводится дополнительный алгоритм сравнения. Привязка к многострочным фрагментам сводится к привязке к синтаксической сущности путём обрамления фрагмента псевдокомментариями (или другими лексическими элементами, пропускаемыми в ходе синтаксического анализа) и встраивания соответствующего ему узла в синтаксическое дерево программы. При этом встраивать разрешается только фрагмент, удовлетворяющий определённым условиям, означающим его согласованность с синтаксической структурой программы. Приводится алгоритм встраивания узла для такого фрагмента, анализируется сложность алгоритма, доказывається корректность дерева, получившегося после встраивания. В разделе экспериментов оценивается устойчивость привязки к однострочным фрагментам.

В заключении перечисляются основные результаты, полученные в диссертации, и обозначаются возможные направления для дальнейших исследований.

Считаю, что текст диссертации хорошо структурирован, научные положения, логика проведения исследования и выводы обосновываются автором; состоятельность теоретических результатов, предложенных в каждой главе, подтверждаются экспериментами на больших объёмах промышленного кода. Формулируются рекомендации по практическому применению разработанных алгоритмов.

Необходимо сделать несколько замечаний.

1. Следует признать, что наибольший интерес с точки зрения оппонента представляет часть работы, посвященная «легковесным» грамматикам и, соответственно, феномену легковесного синтаксического разбора. В работе содержится всестороннее рассмотрение данного понятия, в том числе, в исторической перспективе. При этом, складывается ощущение, что в большинстве практических случаев построение легковесной грамматики из «полной» возможно эмпирическим путем и не требует создания специальных формализмов и программных инструментов для этих целей. Кроме того, при наличии общедоступных парсеров полных грамматик того или иного языка создание специальных «урезанных» грамматик и основанных на них распознавателей имеет преимущественно теоретический интерес и с практической точки зрения представляется сомнительным. Аргумент автора о возможном отсутствии полной

(нормативной) грамматики для некоторого языка программирования вряд ли может считаться убедительным.

2. Ключевое понятие всей диссертационной работы – *привязка* – можно неформально определить как смысловое описание некоторого фрагмента исходного кода в виде набора структур специального вида (*контекстов*). Совокупность фрагментов кода, относящимися к прорезающим функциональностям, и соответствующих привязок, образует *разметку* кода.

В диссертационной работе большое внимание уделяется формальному определению введенных понятий и теоретическому обоснованию алгоритмов, с ними связанных. При этом, практически отсутствуют как практические примеры семантических привязок и разметки в целом, так и описание логики их формирования и использования разработчиками. Некоторые (схематические и явно недостаточные) примеры приводятся в главе 5, которая трактует расширение понятия привязки, однако и в этой главе ощущается явный перекокс внимания в сторону теоретических рассуждений в ущерб содержательному объяснению их целей и смысла.

3. Хотя диссертационная работа содержит детальные описания и обоснования алгоритмов первичной и повторной привязок фрагментов исходного кода – в работе практически отсутствует информация технологического характера: как разработанные и реализованные алгоритмы используются или могут использоваться в практической деятельности по разработке и сопровождению программ. Упомянутая в разд. 4.5 «панель привязки» – компонент, встроенный в IDE Visual Studio – описана весьма лаконично и не позволяет судить ни о ее назначении, ни о реальной применимости в процессе разработки. Этот недостаток, в точки зрения оппонента, особенно огорчителен, так как, судя по информации из Введения, инструменты, созданные автором на основе результатов работы, реально используются в ряде организаций. К этому можно добавить, что ряд публикаций автора, в частности, его магистерская диссертация содержат более конкретную информацию о реальных инструментах и аспектах их использования.

Указанные замечания не снижают значимости полученных результатов и не влияют на положительную оценку диссертационного исследования. Диссертационная работа Головешкина А.В. «Устойчивая алгоритмическая привязка к коду программы» является законченной научно-квалификационной работой, вносящей научный вклад в области теории формальных языков и анализа эволюции программного обеспечения, а также решающей актуальную прикладную

задачу разметки прорезающих функциональностей, представленных в коде программы.

Тема диссертации и её содержание **соответствуют паспорту специальности 2.3.5** — математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей. Автореферат **правильно и полно** отражает содержание работы.

По моему мнению, диссертация удовлетворяет всем критериям, установленным Положением о порядке присуждения учёных степеней, а её автор, Головешкин Алексей Валерьевич, безусловно заслуживает присуждения учёной степени кандидата технических наук по специальности 2.3.5 — математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей.

Руководитель лаборатории операционных систем, языков программирования и компиляторов Автономной некоммерческой организации высшего образования «Университет Иннополис», кандидат физико-математических наук (05.13.11 — математическое и программное обеспечение вычислительных машин, комплексов и компьютерных сетей)

29.11.2022г.

Зуев Евгений Александрович