

НОВЫЕ АСИМПТОТИЧЕСКИ ОПТИМАЛЬНЫЕ АЛГОРИТМЫ ДУАЛИЗАЦИИ

Дюкова Е. В.

Прокофьев П.А.

edjukova@mail.ru

p_prok@mail.ru

Москва, ВЦ РАН

Задача дуализации

(труднорешаемая перечислительная задача)

- ▶ Дана КНФ, реализующая монотонную булеву функцию $F(x_1, \dots, x_n)$ и состоящая из m элементарных дизъюнкций. Требуется построить сокращенную ДНФ D_F функции $F(x_1, \dots, x_n)$ (перечислить все максимальные конъюнкции функции F).
- ▶ Если в ДНФ D_F заменить знаки \wedge и \vee соответственно на знаки \vee и \wedge , то получим КНФ для функции **dual** $F = \bar{F}(\bar{x}_1, \dots, \bar{x}_n)$.
- ▶ Другие формулировки дуализации используют понятия неприводимого покрытия булевой матрицы и минимального вершинного покрытия гиперграфа.

Тривиальный алгоритм

- ▶ **Этап 1.** Умножение логических скобок с использованием закона дистрибутивности.
- ▶ **Этап 2.** Упрощение ДНФ, полученной на этапе 1, за счет устранения повторяющихся конъюнкций и замены не элементарных конъюнкций на элементарные.
- ▶ **Этап 3.** Устранение элементарных поглощений с применением равенства $X \vee XY = X$.
- ▶ **Пример.**

$$\begin{aligned}
 & (x_1 \vee x_2) \wedge (x_1 \vee x_3) \wedge (x_2 \vee x_4) = \\
 & = (x_1 \wedge x_2) \vee (x_1 \wedge x_4) \vee (x_1 \wedge x_3 \wedge x_2) \vee (x_1 \wedge x_3 \wedge x_4) \vee \\
 & (x_2 \wedge x_1) \vee (x_2 \wedge x_1 \wedge x_4) \vee (x_2 \wedge x_3) \vee (x_2 \wedge x_3 \wedge x_4) = \\
 & = (x_1 \wedge x_2) \vee (x_1 \wedge x_4) \vee (x_2 \wedge x_3)
 \end{aligned}$$

(при увеличении n на 1 время работы алгоритма возрастает в два раза).

Теоретические оценки сложности дуализации «в худшем случае»

- ▶ Эффективность алгоритма дуализации оценивается временем выполнения одного шага (на каждом шаге находится в точности одно решение). Временные оценки даются для самой сложной задачи (для худшего случая).
- ▶ Наилучший результат получен в 1995 г. Л. Хачияном с соавторами). Построен **инкрементальный алгоритм** с квазиполиномиальной временной оценкой $O(N^{\log N})$, где N – полином от размера входа и выхода задачи (полином от m, n и числа решений, найденных на предыдущих шагах).
- ▶ Для немногих частных случаев построены **алгоритмы с полиномиальными задержками**, имеющие временные оценки вида $O(N)$, где N – полином от размера входа задачи (полином от m, n).
- ▶ Вопрос о полиномиальной разрешимости дуализации является открытым.

Матричная формулировка дуализации

- ▶ Пусть $L = (a_{ij}), i = 1, 2, \dots, m, j = 1, 2, \dots, n$, – булева матрица,
- ▶ Набор различных столбцов H матрицы L называется **неприводимым покрытием**, если выполнены два условия:
- ▶ **1)** подматрица, образованная столбцами из H , содержит каждую из строк $(1, 0, 0, \dots, 0, 0), (0, 1, 0, \dots, 0, 0), \dots, (0, 0, 0, \dots, 0, 1)$;
- ▶ **2)** каждая строка матрицы L в пересечении хотя бы с одним столбцом из H дает 1.
- ▶ Условие **1)** – **условие совместимости**. Если выполнено 1), то H – совместимый набор столбцов
- ▶ Условие **2)** – **условие покрываемости**. Если выполнено 2), то H – покрытие (H покрывает каждую строку матрицы L).
- ▶ Требуется построить (перечислить) все неприводимые покрытия матрицы L .

Теоретические оценки сложности дуализации «в среднем»

- ▶ В 1977 г. (Е.В. Дюкова) предложен подход к построению **асимптотически оптимальных алгоритмов** дуализации (алгоритмов, эффективных в среднем).
- ▶ Асимптотически оптимальные алгоритмы построены для случая $\log t \leq (1 - \varepsilon) \log n$, $0 < \varepsilon < 1$, и отличаются от алгоритмов с полиномиальными задержками тем, что имеют «лишние» полиномиальные шаги.
- ▶ На каждом шаге строится максимальный совместимый набор столбцов H матрицы L (совместимый набор столбцов H – максимальный, если не существует другого совместимого набора столбцов, содержащего H).
- ▶ Неприводимое покрытие матрицы L – максимальный совместимый набор столбцов. Обратное неверно, так как может быть не выполнено условие покрываемости.

Основные виды асимптотически оптимальных алгоритмов

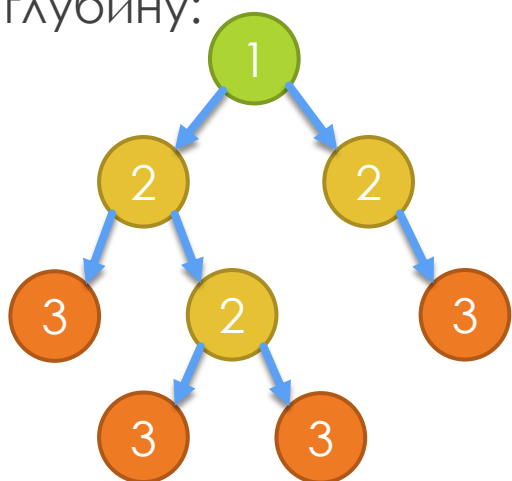
- ▶ **Шаг считается лишним в двух случаях:** 1) построенный набор столбцов не является покрытием; 2) построенный набор столбцов уже строился на предыдущих шагах. Лишний шаг определяется за полиномиальное время от размера входа.
- ▶ Существуют **два вида асимптотически оптимальных алгоритмов:** алгоритмы с повторяющимися шагами и алгоритмы без повторяющихся шагов.
- ▶ **Основное требование:** для почти всех булевых матриц размера $m \times n$ число лишних шагов должно иметь более низкий порядок роста по сравнению с числом неприводимых покрытий при росте размера задачи (при $m, n \rightarrow \infty$).

Экспериментально эффективные алгоритмы дуализации

- ▶ В работах *Murakami K., Uno T. (2011- 2013 гг.)* построены алгоритмы, которые являлись до настоящего времени лидерами по скорости счета. При описании алгоритмов использовались понятия теории гиперграфов
- ▶ Принципиальная схема работы японских алгоритмов не отличается от схемы работы асимптотически оптимальных алгоритмов, построенных ранее в наших работах (в основе японских алгоритмов лежит условие «crit»), которое эквивалентно условию совместимости набора столбцов булевой матрицы) .
- ▶ Наши алгоритмы работали медленнее. Была поставлена задача усовершенствования их конструкций с целью получения лучших, чем у японцев результатов.

Дерево решений асимптотически оптимального алгоритма

- ▶ Работу асимптотически оптимального алгоритма дуализации можно представить в виде обхода дерева решений (ДР) в глубину:



- 1 — пустой набор;
- 2 — совместимый набор столбцов;
- 3 — максимальный совместимый набор столбцов, который либо является неприводимым покрытием, либо соответствует лишнему шагу.

- ▶ Каждая дочерняя вершина внутренней вершины H образуется добавлением к H в точности одного столбца.
- ▶ Время работы алгоритма зависит от числа вершин в ДР, которое строит этот алгоритм.

Алгоритмы АО2 и ОПТ

- ▶ Первоначально наши усилия были направлены в основном на сокращение числа лишних шагов за счет усложнения шага. Среди алгоритмов без повторений лидером был алгоритм ОПТ (Е.В. Дюкова, А.С. Инякин, 2008 г.). Этот алгоритм **имеет сложный шаг** с оценкой $O(qmn(m+q))$, где $q = \min\{m, n\}$.
- ▶ Среди алгоритмов с повторяющимися шагами лидером являлся алгоритм АО2 (Е.В. Дюкова, , 2004 г.), с той же сложностью, что и ОПТ. Алгоритм АО2 на каждом шаге за полиномиальное время строит неприводимое покрытие. Однако повторяет решения, найденные ранее.
- ▶ Усовершенствование алгоритма АО2 (на основе уменьшения числа промежуточных вычислений на шаге без изменения сложности шага) привело к уменьшению сложности ДР и максимальному сокращению времени счета примерно в 4 раза (Е.В. Дюкова, П.А. Прокофьев, 2014 г.).

Новые алгоритмы дуализации RUNC, RUNC-M и PUNC

- ▶ Более существенные результаты были получены при усовершенствовании алгоритма ОПТ [Дюкова Е.В., Прокофьев П.А., Построение и исследование новых асимптотически оптимальных алгоритмов дуализации // Машинное обучение и анализ данных, 2014].
- ▶ Были применены конструктивные приемы, которые ранее использовались для модификации алгоритма АО2.
- ▶ В результате были построены новые алгоритмы дуализации **RUNC**, **RUNC-M** и **PUNC**, которые выгодно отличаются от **ОПТ** следующими показателями: 1) число вершин в ДР значительно меньше; 2) сложность шага равна $O(qmn)$ (меньше сложности шага **ОПТ**).

Наилучший алгоритм дуализации RUNC-M

- ▶ Наилучшие результаты показал алгоритм **RUNC-M**.
- ▶ В алгоритме **RUNC-M** применяется «жадная» стратегия построения ДР:
 - ▶ всякий раз после построения очередной вершины H выбирается строка i , непокрытая набором столбцов H и содержащая наименьшее число единиц в пересечении со столбцами, которые совместимы с H (столбец h совместим с набором столбцов H , если $\{H \cup h\}$ – совместимый набор столбцов);
 - ▶ каждая дочерняя для H вершина строится путём добавления к H столбца, покрывающего строку i и совместимого с H .

Тестовые задачи

- ▶ Тестирование новых и ранее построенных алгоритмов дуализации проводилось на задачах трех принципиально разных типов:
 - 1) случайные матрицы различного размера с равновероятным появлением 0 и 1;
 - 2) модельные данные различного типа и размера;
 - 3) прикладные задачи большого размера.
- ▶ Всего обсчитывалось около 1000 матриц.
- ▶ Модельные и прикладные данных полностью совпадали с тестовыми данными, на которых осуществляли тестирование своих алгоритмов японские учёные.

Результаты экспериментов

- ▶ Практически на всех задачах лидирует один из новых алгоритмов. Исключением являются два типа модельных задач (порядка 20 матриц), ключевой характеристикой которых является сильная разреженность матриц.
- ▶ Наилучшие результаты показывает алгоритм RUNC-M. Причем на некоторых задачах большого размера скорость RUNC-M превосходит скорость ближайшего соперника по меньшей мере в два раза, а иногда и в 5 раз.
- ▶ Счет, проведенный в настоящей работе и в работе японских авторов, демонстрирует преимущество асимптотически оптимальных алгоритмов дуализации перед с алгоритмами, имеющими другие принципы конструирования. Асимптотически оптимальным алгоритмам значительно уступают инкрементальные алгоритмы.

Число вершин в ДР

Модельная задача dualmatching					
ОПТ	39375	354305	3188659	9565952	<u>28697829</u>
RUNC	1033	4107	16397	32782	65551
RUNC-M	1033	4107	16397	32782	65551
PUNC	1034	4108	16398	32783	65552
m	1024	4096	16384	32768	65536
n	21	25	29	31	33
P(L)	10	12	14	15	16

Прикладная задача lose					
ОПТ	18381	218422	568938	1614743	<u>18803203</u>
RUNC	6937	59228	120265	326222	990441
RUNC-M	5039	44205	69178	174305	462764
PUNC	6570	52171	105525	248472	664007
m	100	200	400	800	1600
n	77	77	79	81	81
P(L)	2341	22760	33087	79632	212761

Время счёта (лидирует RUNC-M)

Прикладная задача accidents						
AO1	25.3	-	-	-	-	-
AO2	0.11	5.4	68.7	-	-	-
AO2M	0.05	1.7	23.1	175.6	-	-
ОПТ	0.001	0.05	0.23	1.1	8.2	136.3
MMCS	0.016	0.06	0.27	0.8	3.7	33.
RS	0.001	0.05	0.3	0.8	3.4	35.3
RUNC	0.031	0.031	0.09	0.25	0.9	7.6
RUNC-M	0.001	0.016	0.08	0.25	0.9	7.3
PUNC	0.001	0.031	0.27	1.4	9.9	208.3
m	447	2000	4322	10968	32207	135439
n	64	81	336	336	336	442
P(L)	1039	3547	7617	17486	47137	185218

Время счёта (лидирует RUNC-M)

Прикладная задача lose							
AO1	-	-	-	-	-	-	-
AO2	-	-	-	-	-	-	-
AO2M	2.7	28.7	325.9	-	-	-	-
ОПТ	1.3	4.2	66.5	-	-	-	-
MMCS	0.11	0.3	1.1	12.9	41.8	185.8	519.5
RS	0.16	0.5	1.7	17.1	107.1	449.7	-
RUNC	0.09	0.5	2.2	10.3	58.5	278.6	-
RUNC-M	0.05	0.17	0.5	4.3	12.5	49.2	137.7
PUNC	0.4	1.5	5.8	71.1	501.2	-	-
m	400	800	1600	3200	6400	12800	16635
n	79	81	81	81	81	85	85
P(L)	33087	79632	212761	2396735	4707877	16405082	39180611

Время счёта (лидирует алгоритм японских учёных)

Модельная задача self dual threshold hypergraph								
АО2М	-	-	-	-	-	-	-	-
ОПТ	103.2	217.8	411.1	-	-	-	-	-
ММCS	0.05	0.08	0.09	0.14	0.23	0.4	0.5	0.7
RS	0.05	0.06	0.09	0.16	0.23	0.3	0.6	0.6
RUNC	0.08	0.11	0.19	0.4	0.7	1.4	2.	3.1
RUNC-M	0.09	0.12	0.23	0.4	0.9	1.3	2.	3.2
PUNC	0.5	0.7	1.7	2.2	5.7	20.9	12.7	27.6
m	6482	8192	10102	14522	19742	25762	32582	40202
n	163	183	203	243	283	323	363	403
 P(L) 	6482	8192	10102	14522	19742	25762	32582	40202

Средняя скорость работы алгоритмов дуализации

