

Оптимальное решение задачи интервального поиска на булевом кубе в классе сбалансированных древовидных схем*

Т.Д. Блайвас

Показано, что задача поиска слов, в которых известны только некоторые буквы (как в кроссвордах) сводится к задаче интервального поиска на булевом кубе. Получено оптимальное решение задачи интервального поиска на булевом кубе в классе сбалансированных древовидных схем фиксированной высоты. Найден порядок сложности решения в классе всех сбалансированных древовидных схем.

1. Введение

В работе исследуется следующая задача информационного поиска. Имеется некоторое подмножество V n -мерного булева куба B_2^n , называемое библиотекой. На булевом кубе берется произвольный интервал (u, w) , где $u = (u_1, \dots, u_n)$, $w = (w_1, \dots, w_n)$ и $u \preceq w$, то есть $u_i \leq w_i$ $i = 1, \dots, n$. Требуется определить все такие элементы $y \in V$, $y = (y_1, \dots, y_n)$, называемые записями, для которых выполнено $u \preceq y \preceq w$.

Приведем интерпретацию данной задачи. Допустим, мы имеем частично разгаданный кроссворд, в котором все слова имеют одинаковую длину. Отгадываем слово, в котором известны не все буквы.

*Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований (грант 01-01-00748).

Требуется найти в словаре такие слова, которые потенциально могут быть разгадываемым словом.

Задачу можно решать, если на каждом шаге алгоритма проверять условие $u_j \leq y_j \leq w_j$, $j \in \{1, \dots, n\}$ для фиксированного набора компонент записи, причем номера компонент одинаковы для всех записей на одном шаге алгоритма.

Классу таких алгоритмов удобно сопоставить сбалансированные информационные деревья.

Получены следующие результаты.

1. В классе сбалансированных деревьев фиксированной высоты найдено оптимальное решение, представляемое при помощи решения линейной системы уравнений.

2. Получен порядок функции сложности решения в классе всех сбалансированных деревьев.

2. Основные понятия и формулировка результатов

Мы будем использовать терминологию и обозначения из работы [1], но поскольку в этой работе рассматриваются только древовидные схемы, то здесь будет приведена несколько упрощенная версия понятия информационного графа.

Если X — множество символов запросов с заданным на нем вероятностным пространством $\langle X, \sigma, \mathbf{P} \rangle$, где σ — алгебра подмножеств множества X ; \mathbf{P} — вероятностная мера на σ ; Y — множество символов данных (записей); ρ — бинарное отношение на $X \times Y$, называемое отношением поиска, то пятерка $S = \langle X, Y, \rho, \sigma, \mathbf{P} \rangle$ называется *типом*. Тройка $I = \langle X, V, \rho \rangle$, где V — некоторое конечное подмножество множества Y , называемое библиотекой, называется задачей информационного поиска (ЗИП) типа S . Содержательно ЗИП $I = \langle X, V, \rho \rangle$ состоит в перечислении для произвольно взятого запроса $x \in X$ всех и точно тех записей $y \in V$, что $x\rho y$. Если \mathcal{F} — суть множества символов одноместных предикатов, определенных на X , \mathcal{F} называется базовым множеством и описывает множество элементарных операций, используемых при решении задачи информационного поиска.

Над базовым множеством \mathcal{F} определяется понятие *информационного дерева* (ИД). В конечной многополюсной древовидной сети выбирается вершина — полюс, называемая корнем. Остальные полюса называются листьями и им приписываются записи из Y . задается ориентация от корня к листьям. Ребрам ИД приписываются предикаты из множества \mathcal{F} . Таким образом нагруженное многополюсное ориентированное дерево называют информационным деревом над базовым множеством \mathcal{F} . Затем определяется *функционирование ИД*. Ребро проводит запрос $x \in X$, если предикат ребра истинен на x ; ориентированная цепочка ребер проводит x , если каждое ребро цепочки проводит x ; запрос x проходит в вершину β ИД, если существует ориентированная цепь, ведущая из корня в вершину β , которая проводит x ; запись y , приписанная листу α , попадает в ответ ИД на x , если x проходит в лист α . Ответом ИД U на запрос x называют множество записей, попавших в ответ U на x , и обозначают его $\mathcal{J}_U(x)$. Эту функцию $\mathcal{J}_U(x)$ считают результатом функционирования ИД U . ИД наряду со структурой данных описывает алгоритм соответствующего поиска. Процесс поиска при заданном запросе начинается с корня и распространяется в зависимости от нагруженных предикатов, возможно, сразу по нескольким направлениям. Если этот процесс на дереве достигает элементов данных, то они включаются в ответ алгоритма.

ИД U *разрешает* ЗИП $I = \langle X, V, \rho \rangle$, если $\mathcal{J}_U(x) = \{y \in V : x\rho y\}$.

Вводится *сложность ИД*. Предикат $\varphi_\beta(x)$ истинный на x , если x проходит в вершину β , и ложный в противном случае, называется функцией фильтра вершины β . *Сложностью ИД U на запросе $x \in X$* называется число $T(U, x) = \sum_{\beta \in \mathcal{R}} \psi_\beta \cdot \varphi_\beta(x)$, где \mathcal{R} — множество вершин ИД U , ψ_β — количество ребер, исходящих из вершины β . Эта величина равна числу функций, вычисленных алгоритмом поиска, определяемым ИД U , на запросе x .

Если каждая функция из \mathcal{F} — измерима (относительно алгебры σ), то для любого ИД U над \mathcal{F} функция $T(U, x)$ измерима.

Сложностью ИД U называется математическое ожидание величины $T(U, x)$, равное $T(U) = \mathbf{M}_x T(U, x)$. Она характеризует среднее время поиска.

Если $f(x)$ — предикат, то обозначим $N_f = \{x : f(x) = 1\}$. Слож-

ностью ребра, исходящего из вершины β , будет число $P(N_{\varphi_\beta})$. Тогда понятно, что для ИД U

$$T(U) = \sum_{\beta \in U} \psi_\beta \cdot P(N_{\varphi_\beta}).$$

Рассмотрим следующую ЗИП. Имеется некоторое k -элементное подмножество n -мерного булева куба $V \in B_2^n$ (библиотека). На булевом кубе задан некоторый интервал (u, w) , где $u = (u_1, \dots, u_n)$, $w = (w_1, \dots, w_n)$, и $u \preceq w$, то есть $u_i \leq w_i, \forall i = 1, \dots, n$. Требуется определить все элементы $y \in V$, удовлетворяющие условию $u \preceq y \preceq w$.

Очевидно, что если $u_i = 1$ для некоторого i , то и $w_i = 1$, а, следовательно, и $y_i = 1$. Аналогично, если $w_i = 0$, то и $y_i = 0$. Таким образом, вышеописанная ЗИП сводится к следующей: есть библиотека $V \in B_2^n$, $|V| = k$, берем запрос $x = (x_1, \dots, x_n)$ — трехзначный вектор, компоненты которого могут быть равны либо 1, либо 0, либо 2: если $u_i = 1$, то $x_i = 1$, если $w_i = 0$, то $x_i = 0$, иначе $x_i = 2$. Для данного запроса $x = (x_1, \dots, x_n)$ хотим найти все $y = (y_1, \dots, y_n) \in V$, для которых $y_i = x_i$, если $x_i = 1$ или $x_i = 0$, и y_i любое из $\{0, 1\}$, если $x_i = 2$.

Получаем класс задач $S(n) = \langle B_3^n, B_2^n, \rho \rangle$, где B_3^n и B_2^n трехзначный и двузначный (булев) кубы, соответственно, и $\rho: xry \Leftrightarrow (x_i = y_i) \vee (x_i = 2)$.

Опишем класс ИД, при помощи которых решаются задачи из $S(n)$. *Высотой дерева* назовем длину максимального пути из корня дерева в вершину со степенью полуисхода, равной 0.

Через $\mathcal{D}_{sym}(h)$ обозначим множество всевозможных ИД высоты h , для которых выполняются следующие условия.

1) Из любой вершины на фиксированном ярусе (кроме последнего) выходит одинаковое количество ребер, равное положительной степени двойки.

2) Ребрам ИД приписаны предикаты из следующего множества: $\mathcal{F} = \{f_y\}$, $f_y(x) = x_1^{y_1} \cdot x_2^{y_2} \cdot \dots \cdot x_n^{y_n}$,

$$x_j^{y_j} = \begin{cases} x_j, & \text{если } (y_j = 1) \& (x_j \neq 2) \\ \bar{x}_j, & \text{если } (y_j = 0) \& (x_j \neq 2) \\ 1, & \text{если } (y_j = 2) \vee (x_j = 2) \end{cases},$$

причем \bar{x}_j понимается здесь как отрицание булевой переменной. Эти предикаты приписаны следующим образом. Каждому ярусу i дерева сопоставлено некоторое число m_i , и из каждой вершины i -го яруса выходит 2^{m_i} -е ребер. Ребрам, выходящим из фиксированной (вообще говоря из любой) вершины этого яруса приписываются всевозможные конъюнкции из переменных $x_{j_1}, \dots, x_{j_{m_i}}$ и их отрицаний. Для любых двух ребер из одной вершины приписанные им конъюнкции различны. Множества переменных, входящих в конъюнкции на двух различных ярусах, не пересекаются.

Дерево D будем называть симметричным деревом высоты h , если $D \in \mathcal{D}_{sym}(h)$.

Дерево высоты 0 (одну вершину) также будем считать симметричным.

Дерево D назовем *сбалансированным ИД* высоты $h + 1$, если оно получено из некоторого ИД $D_s \in \mathcal{D}_{sym}(h)$, добавлением к нему k ребер, где k — любое целое неотрицательно число, причем ребра добавлены следующим образом: если в последнем ярусе симметричного дерева $D_s \in \mathcal{D}_{sym}(h)$ было 2^h ребер, то из каждой вершины этого яруса в сбалансированном дереве может выходить $k \leq 2^{n-l_h}$ ребер. Каждому из этих ребер приписана элементарная конъюнкция длины $n - l_h$ из всех тех переменных (или их отрицаний), которые не входили в конъюнкции предыдущих ярусов. Любые две конъюнкции, приписанные ребрам на новом ярусе, различны. Множество всех таких деревьев для каждого n и $k \leq 2^n$ обозначим через $\mathcal{D}_b(n, k, h)$.

Множество задач $I = \langle B_3^n, V, \rho \rangle$ типа S_n , где $|V| = k$, обозначим через $\mathcal{I}(n, k)$.

Введем понятие сложности ЗИП $I \in \mathcal{I}(n, k)$ в классе сбалансированных деревьев высоты h :

$$T_d(I, h) = \inf_{D \in \mathcal{D}_b(I, n, k, h)} T(D),$$

где $\mathcal{D}_b(I, n, k, h)$ — множество деревьев из $\mathcal{D}_b(n, k, h)$, разрешающих задачу I .

Сложностью задачи $I \in \mathcal{I}(n, k)$ назовем

$$T_d(I) = \min_h T_d(I, h).$$

Обозначим

$$\begin{aligned} T_l(x) &= 2^x + 2^l \left(\frac{2}{3}\right)^x, \\ T_{l,m}(x) &= 2^x \left(\frac{2}{3}\right)^l + 2^m \left(\frac{2}{3}\right)^x, \\ T_l^k(x) &= 2^x \left(\frac{2}{3}\right)^l + k \left(\frac{2}{3}\right)^x. \end{aligned} \quad (1)$$

Теорема 1. Пусть $I \in \mathcal{I}(n, k)$,

$$z = \begin{pmatrix} z_1 \\ \vdots \\ z_h \end{pmatrix} = \begin{pmatrix} z_1(h) \\ \vdots \\ z_h(h) \end{pmatrix} \text{ — решение системы уравнений } Az = \hat{b}, \text{ где}$$

$$A = \begin{pmatrix} 1 & -\log_3 2 & 0 & \dots & 0 & 0 & 0 \\ -\log_3 1,5 & 1 & -\log_3 2 & \dots & 0 & 0 & 0 \\ \vdots & \ddots & \ddots & \ddots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \ddots & \ddots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & -\log_3 1,5 & 1 & -\log_3 2 \\ 0 & 0 & 0 & \dots & 0 & -\log_3 1,5 & 1 \end{pmatrix}$$

— трехдиагональная матрица размера $(h \times h)$,

$$\hat{b} = \begin{pmatrix} \log_3(\log_2 1,5) \\ \vdots \\ \log_3(\log_2 1,5) \\ \log_3(\log_2 1,5) + \log_3 k \end{pmatrix} \text{ — столбец высоты } h.$$

Тогда $T_d(I, h) = 2^{l_1} + 2^{l_2} \cdot \left(\frac{2}{3}\right)^{l_1} + \dots + 2^{l_h} \cdot \left(\frac{2}{3}\right)^{l_{h-1}} + k \cdot \left(\frac{2}{3}\right)^{l_h}$, где l_1, \dots, l_h выбраны следующим образом:

$$l_1 = \begin{cases} [z_1], & \text{если } T_{z_2}([z_1]) \leq T_{z_2}(\lfloor z_1 \rfloor) \\]z_1[& \text{иначе,} \end{cases}$$

$$l_i = \begin{cases} [z_i], & \text{если } T_{z_{i-1}, z_{i+1}}([z_i]) \leq T_{z_{i-1}, z_{i+1}}(\lfloor z_i \rfloor) \quad i = 2, \dots, h-1, \\]z_i[& \text{иначе,} \end{cases}$$

$$l_h = \begin{cases} [z_h], & \text{если } T_{z_{h-1}}^k([z_h]) \leq T_{z_{h-1}}^k(\lfloor z_h \rfloor) \\]z_h[& \text{иначе.} \end{cases}$$

Теорема 2. Пусть $I \in \mathcal{I}(n, k)$. При $k \rightarrow \infty$

$$T_d(I) = O(k^{2-\log_2 3}).$$

3. Оптимальное решение в классе сбалансированных ИД фиксированной высоты

Пусть мы имеем оптимальное сбалансированное дерево D с параметрами $l_i, i = 1, \dots, h$, то есть на i -м ярусе симметричного дерева 2^{l_i} ребер, $i = 1, \dots, h$, а на $(h + 1)$ -м ярусе соответствующего сбалансированного дерева k ребер, и сложность такого сбалансированного дерева

$$T(D) = t_k(l_1, \dots, l_h) \stackrel{\text{def}}{=} 2^{l_1} + 2^{l_2} \cdot \left(\frac{2}{3}\right)^{l_1} + \dots + k \cdot \left(\frac{2}{3}\right)^{l_h} \quad (2)$$

по определению сложности дерева, так как если β вершина i -го яруса, то $P(N_{\varphi_\beta}) = \left(\frac{2}{3}\right)^{l_i}$, а $\psi_\beta = 2^{l_{i+1}}$. Далее, для того чтобы зафиксировать структуру дерева D , вместе с записью $T(D)$ будем использовать обозначение $t_k(l_1, \dots, l_h)$ для сложности дерева.

Докажем теорему 1.

Найдем экстремум функции $T_{l_2}(x)$:

$$T'_{l_2}(x) = 2^x \cdot \ln 2 + 2^{l_2} \cdot \left(\frac{2}{3}\right)^x \cdot (\ln 2 - \ln 3) = 0,$$

$$\ln 2 + 2^{l_2} \cdot (\ln 2 - \ln 3) \cdot \frac{1}{3^x} = 0,$$

$$3^x = \frac{(\ln 3 - \ln 2)}{\ln 2} \cdot 2^{l_2}, \quad 3^x = 2^{l_2} \cdot \log_2 1,5,$$

$$x = l_2 \cdot \log_3 2 + \log_3(\log_2 1,5) \stackrel{\text{def}}{=} \hat{x}.$$

Получаем, что точка $x = \hat{x}$ является стационарной точкой для функции $T_{l_2}(x)$. Проверим, что она является точкой минимума для $T_{l_2}(x)$. Обозначим

$$f = 2^{\hat{x}},$$

$$g = 2^{l_2} \cdot \left(\frac{2}{3}\right)^{\hat{x}},$$

тогда $T_{l_2}(\hat{x}) = f + g$, $T_{l_2}(\hat{x} + 1) = 2 \cdot f + \frac{2}{3} \cdot g$, $T_{l_2}(\hat{x} - 1) = \frac{1}{2} \cdot f + \frac{3}{2} \cdot g$.
Точка \hat{x} была бы точкой минимума при следующих условиях:

$$\begin{cases} f + g < 2 \cdot f + \frac{2}{3} \cdot g \\ f + g < \frac{1}{2} \cdot f + \frac{3}{2} \cdot g \end{cases} \Leftrightarrow \begin{cases} \frac{g}{3} < f \\ \frac{f}{2} < \frac{g}{2} \end{cases} \Leftrightarrow \begin{cases} g < 3 \cdot f \\ f < g \end{cases} \Leftrightarrow 1 < \frac{g}{f} < 3.$$

Но $\frac{g}{f} = \frac{2^{l_2} \cdot \left(\frac{2}{3}\right)^{\hat{x}}}{2^{\hat{x}}} = \frac{2^{l_2}}{3^{\hat{x}}} = \frac{2^{l_2}}{2^{l_2 \cdot \log_2 1,5}} = \frac{1}{\log_2 1,5} \approx 1,7$, что удовлетворяет условиям минимума.

Найдем экстремум функции $T_{l_{i-1}, l_{i+1}}(x)$, $i = 2, \dots, h - 1$.

$$T'_{l_{i-1}, l_{i+1}}(x) = 2^x \cdot \left(\frac{2}{3}\right)^{l_{i-1}} \cdot \ln 2 + 2^{l_{i+1}} \cdot \left(\frac{2}{3}\right)^x \cdot \ln \frac{2}{3} = 0,$$

$$\left(\frac{2}{3}\right)^{l_{i-1}} \cdot \ln 2 + \frac{2^{l_{i+1}}}{3^x} \cdot \ln \frac{2}{3} = 0,$$

$$3^x \cdot \left(\frac{2}{3}\right)^{l_{i-1}} = \frac{(\ln 3 - \ln 2)}{\ln 2} \cdot 2^{l_{i+1}},$$

$$3^x = 2^{l_{i+1}} \cdot \left(\frac{3}{2}\right)^{l_{i-1}} \cdot \log_2 1,5,$$

$$x = l_{i-1} \cdot \log_3 1,5 + l_{i+1} \cdot \log_3 2 + \log_3(\log_2 1,5) \stackrel{def}{=} \hat{x}$$

— стационарная точка. Для того, чтобы убедиться в том, что \hat{x} точка минимума, необходимо и достаточно проверить справедливость неравенства $1 < \frac{g}{f} < 3$, где $f = 2^{\hat{x}} \cdot \left(\frac{2}{3}\right)^{l_{i-1}}$, $g = 2^{l_{i+1}} \cdot \left(\frac{2}{3}\right)^{\hat{x}}$.

$$\frac{g}{f} = \frac{2^{l_{i+1}} \cdot \left(\frac{2}{3}\right)^{\hat{x}}}{2^{\hat{x}} \cdot \left(\frac{2}{3}\right)^{l_{i-1}}} = \frac{2^{l_{i+1}} \cdot \left(\frac{3}{2}\right)^{l_{i-1}}}{3^{\hat{x}}} = \frac{2^{l_{i+1}} \cdot \left(\frac{3}{2}\right)^{l_{i-1}}}{2^{l_{i+1}} \cdot \left(\frac{3}{2}\right)^{l_{i-1}} \cdot \log_2 1,5} = \frac{1}{\log_2 1,5} \approx 1,7$$

Рассуждая аналогично для нахождения минимума $T_{l_{h-1}}^k(x)$ получаем, что $\left(T_{l_{h-1}}^k(x)\right)' = 0$, если и только если

$$x = l_{h-1} \cdot \log_3 1,5 + \log_3 k + \log_3(\log_2 1,5) \stackrel{def}{=} \hat{x},$$

$$\begin{aligned}
&\geq C \cdot \log_3 2 + \log_3(\log_2 1, 5) = \\
&= \log_3 2 \cdot \log_{\frac{4}{3}}(\log_{\frac{3}{2}} 2) + \log_3(\log_2 1, 5) = \log_3(2^{\log_{\frac{4}{3}}(\log_{\frac{3}{2}} 2)} \cdot \log_2 1, 5) = \\
&= \log_3 \left(\left(\frac{4}{3} \right)^{\log_2 \frac{4}{3} \cdot \log_{\frac{4}{3}}(\log_{\frac{3}{2}} 2)} \cdot \log_2 \frac{3}{2} \right) = \\
&= \log_3 \left((\log_{\frac{3}{2}} 2)^{\log_{\frac{4}{3}} 2} \cdot \log_2 \frac{3}{2} \right) = \\
&= \log_3 \left((\log_{\frac{3}{2}} 2)^{\log_{\frac{4}{3}} 2 - 1} \right) = \log_3 \left((\log_{\frac{3}{2}} 2)^{\log_{\frac{4}{3}} \frac{3}{2}} \right) = \\
&= \log_3 \left(\left(\log_2 \frac{3}{2} \right)^{-\log_{\frac{4}{3}} \frac{3}{2}} \right) = -\log_{\frac{4}{3}} \frac{3}{2} \cdot \log_3(\log_2 \frac{3}{2}) = \\
&= -\log_{\frac{4}{3}} \frac{3}{2} \cdot \frac{\log_{\frac{4}{3}}(\log_2 \frac{3}{2})}{\log_{\frac{4}{3}} 3} = \frac{\log_{\frac{4}{3}} \frac{3}{2}}{\log_{\frac{4}{3}} 3} \cdot \log_{\frac{4}{3}}(\log_2 \frac{3}{2})^{-1} = \\
&= \log_3 \frac{3}{2} \cdot \log_{\frac{4}{3}}(\log_{\frac{3}{2}} 2).
\end{aligned}$$

3. Пусть

$$z_2 - z_1 \geq C > 1,$$

$$z_1 = z_2 \cdot \log_3 2 + \log_3(\log_2 1, 5),$$

тогда

$$\begin{aligned}
z_1 \cdot \log_3 \frac{3}{2} &= \log_3 2 \cdot (z_2 - z_1) + \log_3(\log_2 \frac{3}{2}) \geq \\
&\geq C \cdot \log_3 2 + \log_3(\log_2 \frac{3}{2}) \geq C \cdot \log_3 \frac{3}{2}
\end{aligned}$$

по ранее доказанному.

Что и требовалось доказать.

Пусть $f_1(x)$, $f_i(x, y)$, $i = 2, \dots, h-1$, $f_h(x, y)$ такие функции, что $T_{l_x}(f_1(x)) = \min_z T_x(z)$, $T_{l_x, l_y}(f_i(x, y)) = \min_z T_{l_x, l_y}(z)$, $T_{l_x}^k(f_h(x, k)) = \min_z T_{l_x}^k(z)$.

Лемма 2. Если $(\hat{l}_1, \dots, \hat{l}_h)$ точка минимума функции $t_k(l_1, \dots, l_h)$, определяемой соотношением (2), то справедливо

$$\hat{l}_1 = f_1(\hat{l}_2), \quad \hat{l}_i = f_i(\hat{l}_{i-1}, \hat{l}_{i+1}), \quad i = 2, \dots, h-1, \quad \hat{l}_h = f_h(\hat{l}_{h-1}, k).$$

Доказательство. Допустим, существует $j : \hat{l}_j$ j -тая компонента точки минимума функции (2), но $\hat{l}_j \neq f_j(\hat{l}_{j-1}, \hat{l}_{j+1}) = l_j$. Так как \hat{l}_j является компонентой точки минимума функции (2), а функция (2) — это сумма положительных слагаемых (то есть она принимает минимальное значение тогда и только тогда, когда минимальны все ее слагаемые), то $T_{l_{j-1}, l_{j+1}}(\hat{l}_j) \leq T_{l_{j-1}, l_{j+1}}(l_j)$, а так как l_j — минимум по x $T_{l_{j-1}, l_{j+1}}(x)$, то $T_{l_{j-1}, l_{j+1}}(l_j) \leq T_{l_{j-1}, l_{j+1}}(\hat{l}_j)$. Получаем противоречие с предположением.

Что и требовалось доказать.

Если в лемме 2 для каждой из функций $T_{l_2}(x)$, $T_{l_{j-1}, l_{j+1}}(x)$ ($j = 2, \dots, h-1$), $T_{l_{h-1}}^k(x)$ в качестве выражения для точки минимума на множестве целых чисел брать то из ближайших двух целых ($x_{i, \min} = [f_i(\hat{l}_{i-1}, \hat{l}_{i+1})]$ или $x_{i, \min} = \lceil f_i(\hat{l}_{i-1}, \hat{l}_{i+1}) \rceil$), $i = 1, \dots, h$, для которого будут наименьшими значения функций T_{l_2} , $T_{l_{j-1}, l_{j+1}}$ ($j = 2, \dots, h-1$), $T_{l_{h-1}}^k$, то получим справедливость утверждения теоремы.

Корректность найденных величин l_1, \dots, l_h (то есть возможность построить по ним сбалансированное информационное дерево) доказана в лемме 1.

Теорема 1 доказана.

4. Оценки сложности

Лемма 3. Пусть $I \in \mathcal{I}(n, k)$. При $n \rightarrow \infty$, $k \rightarrow \infty$ для высоты h_0 оптимального, решающего задачу I , сбалансированного дерева выполнено $h_0 \rightarrow \infty$.

Доказательство. Покажем, что $l_{h_0} \rightarrow \infty$ при $k \rightarrow \infty$. Допустим, построено оптимальное дерево D высоты h_0 , у которого на предпоследнем ярусе $2^{l_{h_0}}$ ребер, $l_{h_0} < n$, а на последнем — k , тогда сложность последнего яруса такого дерева равна $k \cdot \left(\frac{2}{3}\right)^{l_{h_0}}$. Рассмотрим теперь

сбалансированное дерево D' , решающее данную задачу, у которого до яруса с номером h_0 структура совпадает со структурой дерева D , из каждой вершины ребер h_0 -го яруса выходит по два ребра (всего 2^{m+1} ребер), а ярус с номером $(h_0 + 2)$ является последним, и на нем, согласно определению сбалансированного дерева, k ребер. Сложности первых h_0 ярусов такого дерева совпадают с соответствующими сложностями дерева D , а сложность последних двух ярусов равна $2^{l_{h_0+1}} \cdot \left(\frac{2}{3}\right)^{l_{h_0}} + k \cdot \left(\frac{2}{3}\right)^{l_{h_0+1}}$. Следовательно,

$$T(D) - T(D') = k \cdot \left(\frac{2}{3}\right)^{l_{h_0}} - 2^{l_{h_0+1}} \cdot \left(\frac{2}{3}\right)^{l_{h_0}} - k \cdot \left(\frac{2}{3}\right)^{l_{h_0+1}} =$$

$$k \cdot \left(\frac{2}{3}\right)^{l_{h_0}} \cdot \left(1 - \frac{2^{l_{h_0+1}}}{k} - \frac{2}{3}\right).$$

Несложно заметить, что если $\frac{2^{l_{h_0+1}}}{k} < \frac{1}{3}$, то $T(D) > T(D')$, то есть D не может быть оптимальным деревом. Следовательно, должно выполняться

$$\frac{2^{l_{h_0+1}}}{k} > \frac{1}{3} \text{ или } k < 3 \cdot 2^{l_{h_0+1}}.$$

Покажем, что $h_0 \rightarrow \infty$ при $l_{h_0} \rightarrow \infty$. Пусть на ярусе с номером $(i-1) 2^{i-1}$ ребер, а на ярусе с номером $i 2^i$ ребер, $i > 1$. Следовательно, сложность ребер i -го яруса $2^i \cdot \left(\frac{2}{3}\right)^{l_{i-1}}$. Рассмотрим новое сбалансированное дерево D' высоты $(h_0 + 1)$, которое получится, если i -й ярус дерева D , состоящий из $2^{l_{i-1}}$ поддеревьев высоты 1, заменить на $2^{l_{i-1}}$ поддеревьев высоты 2, причем первый ярус такого нового поддерева содержит два ребра, с приписанными им переменной x_j , входящей в конъюнкцию i -го яруса дерева D , и ее отрицанием. Из каждого из этих двух ребер, в свою очередь, выходят $2^{l_{i-1}-l_{i-1}-1}$ ребер, которым приписаны всевозможные конъюнкции из всех переменных кроме x_j , входящих в конъюнкции на i -м ярусе D , и их отрицаний. Таким образом, на i -м ярусе нового дерева D' $2^{l_{i-1}+1}$ ребро, на $(i+1)$ -м 2^i ребер, а все ярусы с номерами большими, чем $(i+1)$ повторяют конструкцию всех ярусов с номерами большими, чем i в дереве D . Сложность двух измененных ярусов в дереве D' равна

$$2^{l_{i-1}+1} \cdot \left(\frac{2}{3}\right)^{l_{i-1}} + 2^{l_i} \cdot \left(\frac{2}{3}\right)^{l_{i-1}+1}.$$

Значит,

$$\begin{aligned} T(D) - T(D') &= 2^{l_i} \left(\frac{2}{3}\right)^{l_{i-1}} - 2^{l_{i-1}+1} \left(\frac{2}{3}\right)^{l_{i-1}} - 2^{l_i} \left(\frac{2}{3}\right)^{l_{i-1}+1} = \\ &= 2^{l_i} \left(\frac{2}{3}\right)^{l_{i-1}} \cdot \left(1 - \frac{2}{2^{l_i-l_{i-1}}} - \frac{2}{3}\right). \end{aligned}$$

Отсюда видно, что если дерево D оптимально, то

$$\frac{2}{2^{l_i-l_{i-1}}} > \frac{1}{3} \text{ или } l_i - l_{i-1} < 3.$$

Рассуждая аналогично, получим, что и $l_1 < 3$. Так как

$$l_{h_0} = \sum_{i=2}^{h_0} (l_i - l_{i-1}) < h_0 \cdot 3,$$

то $h_0 > \frac{l_{h_0}}{3}$, а значит $h_0 \rightarrow \infty$ при $l_{h_0} \rightarrow \infty$.

Лемма доказана.

Обозначим $r_1(k, h) = 2^{z_1(h)}$, $r_h(k, h) = 2^{z_h(h)} \cdot \left(\frac{2}{3}\right)$, $r_i(k, h) = 2^{z_i(h)} \cdot \left(\frac{2}{3}\right)$, $i = 2, \dots, h-1$, где $z_i(h)$ определяются как решения системы (3).

Пусть $f(k, h) = \sum_{i=1}^h r_i(k)$.

Лемма 4. Если $h \in \mathbb{N}$, то $r_i(k, h) = r_1(k, h) \cdot (\log_{1,5} 2)^{i-1}$, $i = 2, \dots, h$.

Доказательство. По индукции.

1) Так как

$$z_2(h) = z_1(h) \cdot \log_2 3 - \log_2(\log_2 1, 5),$$

то

$$2^{z_2(h)} \cdot \left(\frac{2}{3}\right)^{z_1(h)} = 2^{z_1(h)} \cdot \frac{1}{\log_2 1,5}.$$

2) Пусть $j = 2, \dots, h-1$, тогда так как

$$z_{j+1}(h) = z_j(h) \cdot \log_2 3 - z_{j-1}(h) \cdot \log_2 1,5 - \log_2(\log_2 1,5),$$

то

$$2^{z_{j+1}(h)} \cdot \left(\frac{2}{3}\right)^{z_j(h)} = 2^{z_j(h)} \cdot \left(\frac{2}{3}\right)^{z_{j-1}(h)} \cdot \frac{1}{\log_2 1,5}.$$

3) Так как

$$k = 3^{z_h(h)} \cdot \left(\frac{3}{2}\right)^{-z_{h-1}(h)} \cdot \frac{1}{\log_2 1,5},$$

то

$$k \cdot \left(\frac{2}{3}\right)^{z_h(h)} = 2^{z_h(h)} \cdot \left(\frac{2}{3}\right)^{z_{h-1}(h)} \cdot \frac{1}{\log_2 1,5}.$$

Что и требовалось доказать.

Согласно лемме 4, в функции $f(k, h)$ каждое следующее слагаемое в $\frac{1}{\log_2 1,5}$ раз больше предыдущего. Значит, если

$$k \cdot \left(\frac{2}{3}\right)^{z_h(h)} = r_h(k, h), \text{ то}$$

$$f(k, h) = r_h(k, h) \cdot \left((\log_2 1,5)^{h-1} + \dots + (\log_2 1,5)^2 + \log_2 1,5 + 1 \right) =$$

$$r_h(k, h) \cdot \frac{1 - (\log_2 1,5)^h}{1 - \log_2 1,5} \rightarrow r_h(k, h) \cdot \frac{1}{1 - \log_2 1,5} \text{ при } h \rightarrow \infty.$$

Кроме того, при округлении действительных решений $z_i(h)$ системы (3) (для того, чтобы найти целые номера $l_i : |l_i - z_i(h)| \leq 0,5$, необходимые при построении дерева),

$$r_i(k, h) \cdot 2^{-0,5} \left(\frac{2}{3}\right)^{0,5} \leq 2^{l_i} \cdot \left(\frac{2}{3}\right)^{l_i-1} \leq r_i(k, h) \cdot 2^{0,5} \left(\frac{2}{3}\right)^{-0,5},$$

$$r_i(k, h) \cdot \frac{1}{\sqrt{3}} \leq 2^{l_i} \left(\frac{2}{3}\right)^{l_i-1} \leq \sqrt{3} \cdot r_i(k, h).$$

Здесь $i = 1, \dots, h$. Следовательно,

$$f(k, h) \cdot \frac{1}{\sqrt{3}} \leq t_k(l_1, \dots, l_h) \leq f(k, h) \cdot \sqrt{3}.$$

Таким образом, достаточно исследовать только последнее слагаемое в функции $f(k, h)$.

Пусть $c = -\log_3 1,5$, $d = -\log_3 2$, $b = \log_3(\log_2 1,5)$. Тогда система (3) представляется в виде

$$\begin{pmatrix} 1 & d & 0 & \dots & 0 & 0 & 0 \\ c & 1 & d & \dots & 0 & 0 & 0 \\ \vdots & \ddots & \ddots & \ddots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \ddots & \ddots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & c & 1 & d \\ 0 & 0 & 0 & \dots & 0 & c & 1 \end{pmatrix} \begin{pmatrix} z_1(h) \\ \dots \\ \dots \\ \dots \\ \dots \\ \dots \\ z_h(h) \end{pmatrix} = \begin{pmatrix} b \\ \dots \\ \dots \\ \dots \\ \dots \\ b \\ b + \log_3 k \end{pmatrix}$$

или $Az = \hat{b}$.

Будем решать эту систему методом прогонки, предварительно разложив матрицу A в произведение двудиagonalных матриц

$$\begin{pmatrix} 1 & d & 0 & \dots & 0 & 0 & 0 \\ c & 1 & d & \dots & 0 & 0 & 0 \\ \vdots & \ddots & \ddots & \ddots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \ddots & \ddots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & c & 1 & d \\ 0 & 0 & 0 & \dots & 0 & c & 1 \end{pmatrix} = Q \times V, \tag{4}$$

где

$$Q = \begin{pmatrix} q_1(h) & 0 & \dots & 0 & 0 \\ 1 & q_2(h) & \dots & 0 & 0 \\ \vdots & \ddots & \ddots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \ddots \\ 0 & 0 & \dots & q_{h-1}(h) & 0 \\ 0 & 0 & \dots & 1 & q_h(h) \end{pmatrix},$$

$$V = \begin{pmatrix} v_1(h) & u_1(h) & \dots & 0 & 0 \\ 0 & v_2(h) & \ddots & 0 & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \ddots \\ \vdots & \vdots & \vdots & \vdots & \ddots \\ 0 & 0 & \dots & v_{h-1}(h) & u_{h-1}(h) \\ 0 & 0 & \dots & 0 & v_h(h) \end{pmatrix},$$

где $q_i(h)$, $v_i(h)$, $i = 1, \dots, h$, $u_i(h)$, $i = 1, \dots, h - 1$, ищем следующим образом:

$$\begin{aligned} v_1(h) &= c, \quad q_1(h) = 1/v_1(h), \quad u_1(h) = d/q_1(h); \\ v_i(h) &= c, \quad q_i(h) = (1 - u_{i-1}(h))/v_i(h), \quad u_i(h) = d/q_i(h), \quad i = 2, \dots, h-1; \\ q_h(h) \cdot v_h(h) &= 1 - u_{h-1}(h). \end{aligned} \quad (5)$$

Решение системы $Q(Vl) = \hat{b}$ сводится к решению систем $Qy = \hat{b}$ и $Vz = y$,

$$y = \begin{pmatrix} y_1(h) \\ \vdots \\ y_h(h) \end{pmatrix}.$$

Нас, в основном, интересуют неизвестные $y_h(h)$ и $z_h(h)$ в первой и во второй системах соответственно (в скобках указывается размерность систем). Очевидно, что $z_h(h) = y_h(h)/v_h(h) = y_h(h)$, $y_h(h) = \frac{(b + \log_3 k) - y_{h-1}(h)}{q_h(h)}$.

Лемма 5. Для $q_h(h)$, определяемого соотношением (5), верно следующее:

$$q_2(2) = 1 - c \cdot d, \quad q_h(h) = 1 - \frac{c \cdot d}{q_{h-1}(h-1)}$$

для любого $h \in \mathbb{N}$.

Доказательство. Индукцией по размерности системы j .

1. $j = 2$. $v_1(2) = c$, $v_2(2) = 1$, $q_1(2) = 1/c$, $u_1(2) = cd$, $q_2(2) = 1 - cd$.

2. Пусть для $j < h$ предположение верно. Тогда имеем следующую систему уравнений, из которой находится $q_{h-1}(h-1)$:

$$\begin{cases} q_1(h-1) = \frac{1}{c}, & u_1(h-1) = \frac{d}{q_1(h-1)} \\ q_i(h-1) = \frac{1-u_{i-1}(h-1)}{c}, & u_i(h-1) = \frac{d}{q_i(h-1)}, \quad i = 1, \dots, h-2 \\ q_{h-1}(h-1) = 1 - u_{h-2}(h-1). \end{cases}$$

3. Покажем, что предположение индукции верно и для $j = h$. Для нахождения $q_h(h)$ имеем следующую систему уравнений:

$$\begin{cases} q_1(h) = \frac{1}{c} & u_1(h) = \frac{d}{q_1(h)}, \\ q_i(h) = \frac{1-u_{i-1}(h)}{c}, & u_i(h) = \frac{d}{q_i(h)}, \quad i = 2, \dots, h-2 \\ q_{h-1}(h) = \frac{1-u_{h-2}(h)}{c}, & u_{h-1}(h) = \frac{d}{q_{h-1}(h)}, \\ q_h(h) = 1 - u_{h-1}(h). \end{cases}$$

В этой системе все вычисления до $(h-2)$ -го шага включительно совпадают с вычислениями, производимыми в системе для матрицы размера $(h-1) \times (h-1)$: $q_{h-2}(h-1)(c, d) = q_{h-2}(h)(c, d)$, $u_{h-2}(h-1)(c, d) = u_{h-2}(h)(c, d) = u_{h-2}$. Далее $q_{h-1}(h-1) = 1 - u_{h-2}$; $q_{h-1}(h) = \frac{1-u_{h-2}}{c} = \frac{q_{h-1}(h-1)}{c}$, $u_{h-1}(h) = \frac{cd}{q_{h-1}(h-1)}$, и $q_h(h) = 1 - \frac{cd}{q_{h-1}(h-1)}$.

Что и требовалось доказать.

Лемма 6. Если $q_h(h)$ определены соотношением (5), то $\lim_{h \rightarrow \infty} q_h(h) = \log_2 3$.

Доказательство. По индукции.

1. $q_1(1) = 1$, $q_2(2) = 1 - cd = 1 - \log_3 2 \cdot \log_3 1,5 < 1$.

2. Пусть $q_i(i) < q_{i-1}(i-1)$, тогда

$$3. q_{i+1}(i+1) = 1 - \frac{cd}{q_i(i)} < 1 - \frac{cd}{q_{i-1}(i-1)} = q_i(i).$$

Пусть $\lim_{h \rightarrow \infty} q_h(h) = q$ — бесконечная дробь, для которой верно соотношение $q = 1 - \frac{cd}{q}$ или $q^2 - q + cd = 0$. Решая квадратное уравнение и подставляя значения c, d в решение, получаем: $q = \frac{1 + \sqrt{1 - 4cd}}{2} = \log_3 2$; $q = \frac{1 - \sqrt{1 - 4cd}}{2} = \log_3 1, 5$.

Покажем, что нам подходит только первый из этих корней. Последовательность $\{q_h(h)\}$ убывает от единицы и до положительного числа (одного из наших корней), и $q_{h+1}(h+1) = 1 - \frac{cd}{q_h(h)}$. Значит, $1 - \frac{cd}{q_h(h)} - q_h(h) > 0$ и $q_h^2(h) - q_h(h) + cd < 0$, то есть $q_h(h) > \log_3 2$ или $q_h(h) < \log_3 1, 5$. Очевидно, что второй вариант не удовлетворяет условию $q_1(1) = 1$. Значит $\lim_{h \rightarrow \infty} q_h(h) = q = \log_3 2$.

Что и требовалось доказать.

Лемма 7. Пусть $q_i(h)$, $i = 1, \dots, h-1$, определены соотношением (5). Тогда выполнены следующие условия:

- 1) $q_1(h) = -\log_{1,5} 3$;
- 2) $q_i(h) < 0 \quad \forall i = 1, \dots, h-1$;
- 3) $1 < |q_i(h)| < |q_{i-1}(h)|, \quad i = 2, \dots, h-1$;
- 4) $\lim_{\substack{h \rightarrow \infty \\ i \rightarrow \infty \\ i \neq h}} q_i(h) = -\log_{1,5} 2$.

Доказательство.

$q_1(h) = \frac{1}{c} = -\log_{1,5} 3$. Далее, рассуждая тем же образом, что и в лемме 5, получаем следующее рекуррентное выражение для $q_i(h)$, $i = 2, \dots, h-1$:

$$q_i(h) = \frac{1 - \frac{cd}{c \cdot q_{i-1}(h)}}{c}.$$

Выражение, стоящее в числителе этой дроби то же, что и $q_i(i)$, следовательно, при росте i оно убывает от единицы до $\log_3 2$. Кроме того, для любого $i = 2, \dots, h-1$ числитель положителен, а значит для таких i $q_i(h) < q_{i-1}(h)$.

$$\lim_{\substack{h \rightarrow \infty \\ i \rightarrow \infty \\ i \neq h}} q_i(h) = \frac{\log_3 2}{-\log_3 1, 5} = -\log_{1,5} 2 < -1,$$

значит $\forall i = 2, \dots, h-1 \quad |q_i(h)| > 1$.

Что и требовалось доказать.

Лемма 8. При решении уравнения $Qy = \hat{b}$, где матрица Q определяется соотношением (4), получаем следующее ограничение: $\frac{1}{6} < |y_{h-1}(h)| < \frac{3}{2}$.

Доказательство. Вычислим $y_{h-1}(h)$ индуктивно через предыдущие переменные рассматриваемой системы, учтем, что $y_1(h) = \frac{b}{q_1(h)}$.

$$\begin{aligned} y_{h-1}(h) &= \frac{b - y_{h-2}(h)}{q_{h-1}(h)} = \frac{b - \frac{b - y_{h-3}(h)}{q_{h-2}(h)}}{q_{h-1}(h)} = \\ &= b \cdot \left(\frac{1}{q_{h-1}(h)} - \frac{1}{q_{h-1}(h) \cdot q_{h-2}(h)} \right) + \frac{y_{h-2}(h)}{q_{h-1}(h) \cdot q_{h-2}(h)} = \\ &= b \cdot \left(\frac{1}{q_{h-1}(h)} - \frac{1}{q_{h-1}(h) \cdot q_{h-2}(h)} + \dots + (-1)^h \frac{1}{q_{h-1}(h) \dots q_1(h)} \right). \end{aligned}$$

Учитывая результат леммы 6, получаем, что так как $q_i < 0$ при $i < h-1$, и $b < 0$, то $y_{h-1}(h) > 0$ и

$$y_{h-1}(h) = |b| \left(\frac{1}{|q_{h-1}|} + \dots + \frac{1}{|q_{h-1}| \cdot |q_{h-2}| \dots |q_1|} \right).$$

Оценим более точно эту величину. Используем то, что $\log_{1,5} 2 < |q_i(h)| < \log_{1,5} 3$, $i = 1, \dots, h-1$. Тогда

$$\begin{aligned} y_{h-1}(h) &> |b| (\log_3 1,5 + (\log_3 1,5)^2 + \dots + (\log_3 1,5)^{h-1}) = \\ &|b| \cdot \log_3 1,5 \cdot \left(\frac{1 - (\log_3 1,5)^{h-1}}{1 - \log_3 1,5} \right) > |b| \cdot \log_3 1,5 > \frac{1}{6}. \end{aligned}$$

С другой стороны,

$$\begin{aligned} y_{h-1}(h) &< |b| (\log_2 1,5 + (\log_2 1,5)^2 + \dots + (\log_2 1,5)^{h-1}) = \\ &|b| \cdot \left(\frac{\log_2 1,5 - (\log_2 1,5)^h}{1 - \log_2 1,5} \right) < |b| \frac{\log_2 1,5}{1 - \log_2 1,5} < \frac{3}{2}. \end{aligned}$$

Что и требовалось доказать.

Приступим непосредственно к доказательству теоремы 2.

Далее будем пользоваться результатом леммы 3, учитывая, что при стремлении к бесконечности мощности библиотеки k высота h_0

оптимального дерева также растет. Исследуем порядок по k слагаемого $k \cdot \left(\frac{2}{3}\right)^{z_{h_0}}$, где z_{h_0} найден из системы (3) оптимальной размерности h_0 . Как было замечено ранее, при построенном нами $Q - V$ -разложении (4) $z_{h_0}(h_0) = y_{h_0}(h_0)$, а для $y_{h_0}(h_0)$ справедлива оценка, основанная на результатах лемм 6 и 7:

$$y_{h_0}(h_0) = \frac{\log_3 k}{q_{h_0}(h_0)} + \frac{b + y_{h_0-1}(h_0)}{q_{h_0}(h_0)},$$

$$\log_2 k + \frac{-\frac{1}{2} + \frac{1}{6}}{\log_3 2} < \lim_{h_0 \rightarrow \infty} y_{h_0}(h_0) < \log_2 k + \frac{-\frac{1}{2} + \frac{3}{2}}{\log_3 2},$$

$$\log_2 k - \frac{1}{3} \cdot \log_2 3 < \lim_{h_0 \rightarrow \infty} y_{h_0}(h_0) < \log_2 k + \log_2 3,$$

$$\log_2 \frac{k}{\sqrt{3}} < \lim_{h_0 \rightarrow \infty} y_{h_0}(h_0) < \log_2 3k.$$

А значит для исследуемого нами слагаемого функции сложности получаем: при росте k h_0 и $z_{h_0} = y_{h_0}(h_0)$ возрастают, следовательно, степень порядка самого слагаемого убывает и

$$k \cdot \frac{\frac{k}{\sqrt{3}}}{k^{\log_3 2} \cdot 2} < \lim_{h_0 \rightarrow \infty} k \cdot \left(\frac{2}{3}\right)^{z_{h_0}} < k \cdot \frac{3k}{k^{\log_3 2} \cdot \frac{1}{\sqrt{2}}},$$

$$\frac{1}{2\sqrt{3}} \cdot k^{2-\log_2 3} < \lim_{h_0 \rightarrow \infty} k \cdot \left(\frac{2}{3}\right)^{l_{h_0}} < 3\sqrt{2} \cdot k^{2-\log_3 2}.$$

Так как $f(k, h_0) = \frac{1 - (\log_2 1,5)^{h_0}}{1 - \log_2 1,5} \cdot k \cdot \left(\frac{2}{3}\right)^{z_{h_0}}$, то

$$\frac{1}{2\sqrt{3} \cdot (1 - \log_2 1,5)} \cdot k^{2-\log_2 3} < \lim_{h_0 \rightarrow \infty} f(k, h_0) < \frac{3\sqrt{2}}{1 - \log_2 1,5} \cdot k^{2-\log_2 3}.$$

Следовательно,

$$\frac{1}{\sqrt{3}} \cdot \frac{1}{2\sqrt{3} \cdot (1 - \log_2 1,5)} \cdot k^{2-\log_2 3} < \lim_{h_0 \rightarrow \infty} t_k(l_1, \dots, l_{h_0}) <$$

$$\sqrt{3} \cdot \frac{3\sqrt{2}}{1 - \log_2 1,5} \cdot k^{2-\log_2 3}.$$

Теорема 2 доказана.

Утверждение 1.

$$\log_2 k > h_0 > \left\lceil \frac{\log_2 k - \log_2 3}{3} \right\rceil.$$

Доказательство утверждения. В процессе доказательства леммы 3 было показано, что $h_0 > \frac{l_{h_0}}{3}$, и $l_{h_0} > \log_2 k - \log_2 3$, откуда следует нижняя оценка для h_0 . Докажем теперь верхнюю оценку.

Рассмотрим оптимальное дерево D , сложность двух последних ярусов его ребер равна $2^{l_{h_0}} \left(\frac{2}{3}\right)^{l_{h_0}-1} + k \cdot \left(\frac{2}{3}\right)^{l_{h_0}}$. Теперь построим дерево D' , удаляя из дерева D ярус ребер с номером h_0 , и подсоединяя k ребер последнего яруса дерева D к ярусу с номером $(h_0 - 1)$. Допустим, $l_{h_0} \geq \log_2 k$. Тогда

$$\begin{aligned} T(D) - T(D') &= 2^{l_{h_0}} \cdot \left(\frac{2}{3}\right)^{l_{h_0}-1} + k \cdot \left(\frac{2}{3}\right)^{l_{h_0}} - k \cdot \left(\frac{2}{3}\right)^{l_{h_0}-1} \geq \\ &k \cdot \left(\frac{2}{3}\right)^{l_{h_0}-1} + k \cdot \left(\frac{2}{3}\right)^{l_{h_0}} - k \cdot \left(\frac{2}{3}\right)^{l_{h_0}-1} = k \cdot \left(\frac{2}{3}\right)^{l_{h_0}} > 0. \end{aligned}$$

Получили противоречие с оптимальностью дерева. А так как

$$l_{h_0} = \sum_{i=2}^{h_0} (l_i - l_{i-1}) + l_1 \geq h_0,$$

то $h_0 \leq \log_2 k$.

Утверждение доказано.

Замечание. В некоторых ситуациях, при фиксированном h для нахождения наилучших целых номеров $l_i, i = 1, \dots, h$, достаточно взять ближайшее целое к соответствующему решению системы (3).

Рассмотрим минимальные значения функций $T_{l_2}(f_1(l_2)), T_{l_{i-1}, l_{i+1}}(f_i(l_{i-1}, l_{i+1})), i = 2, \dots, h - 1, T_{l_{h-1}}^k(f_h(l_{h-1}, k))$, определяемые соотношениями (1). Для $T_{l_{i-1}, l_{i+1}}(f_i(l_{i-1}, l_{i+1})), i = 2, \dots, h - 1$, положим $\Delta_+ = T_{l_{i-1}, l_{i+1}}(f_i(l_{i-1}, l_{i+1}) + 0, 5) - T_{l_{i-1}, l_{i+1}}(f_i(l_{i-1}, l_{i+1})), i = 2, \dots, h - 1, \Delta_- = T_{l_{i-1}, l_{i+1}}(f_i(l_{i-1}, l_{i+1}) - 0, 5) - T_{l_{i-1}, l_{i+1}}(f_i(l_{i-1}, l_{i+1})), i = 2, \dots, h - 1$. Пусть f, g — те же, что и при доказательстве теоремы 1 для $T_{l_{i-1}, l_{i+1}}(x)$. Тогда

$$\Delta_+ = \sqrt{2} \cdot f + \sqrt{\frac{2}{3}} \cdot g - f - g = (\sqrt{2} - 1) \cdot f + \left(\sqrt{\frac{2}{3}} - 1 \right) \cdot g =$$

$$\left((\sqrt{2} - 1) + \log_{1,5} 2 \cdot \left(\sqrt{\frac{2}{3}} - 1 \right) \right) \cdot f \approx 0,1004 \cdot f$$

с точностью до четвертого знака после запятой.

$$\Delta_- = \frac{1}{\sqrt{2}} \cdot f + \sqrt{\frac{3}{2}} \cdot g - f - g =$$

$$\left(\left(\frac{1}{\sqrt{2}} - 1 \right) + \log_{1,5} 2 \cdot \left(\sqrt{\frac{3}{2}} - 1 \right) \right) \cdot f \approx 0,0912 \cdot f.$$

$$\Delta_+ - \Delta_- \approx 0,009 \cdot f.$$

Аналогичные результаты получаются и для T_{l_2} , $T_{l_{h-1}}^k$ в окрестностях точек минимумов с радиусом $\frac{1}{2}$. Так как $f = (\log_2 1,5)^{h-i} \cdot \left(\frac{2}{3}\right)^{lh} \cdot k$, — линейно зависит от сложности, то при небольших мощностях библиотек (порядка сотни) в качестве наилучшего целого номера l_i без больших потерь можно брать округление от соответствующего решения системы уравнений (3).

В частности, при больших n и h , когда сложность порядка, лучшего, чем \sqrt{k} , при $k \leq 10000$ можно в качестве наилучших целых брать ближайшие целые номера.

В заключение автор выражает благодарность Э.Э. Гасанову за постановку задачи и научное руководство.

Список литературы

- [1] Гасанов Э.Э. Информационно-графовая модель хранения и поиска данных // Интеллектуальные системы. 1998. Т. 3. Вып. 3–4. С. 163–192.
- [2] Богачев К.Ю. Методы решения линейных систем и нахождения собственных значений. М., 1998.