

УДК 004.75 + 004.056.3025.1

ББК 32.973.202

РЕЗЕРВИРОВАНИЕ ВЗАИМОСВЯЗАННЫХ МАССИВОВ ДАННЫХ В РАСПРЕДЕЛЕННЫХ СИСТЕМАХ ОБРАБОТКИ ДАННЫХ.

Сомов С.К.¹

*(Учреждение Российской академии наук
Институт проблем управления РАН, Москва)*

Аннотация: рассмотрены вопросы применения резервирования информации в распределенных системах обработки данных (РСОД), функционирующих в рамках вычислительных сетей, с целью повышения безопасности их работы. Рассмотрены проблемы и задачи оптимизации резервирования массивов данных в РСОД с учетом их взаимосвязи между собой.

Ключевые слова: распределенные системы обработки данных, резервирование взаимосвязанных массивов данных, задачи оптимизации резервирования.

1. Введение

Распределенные системы обработки данных (РСОД) представляют собой сложные аппаратно-программные комплексы. Компоненты этих систем могут быть распределены на больших расстояниях друг от друга и объединяются в единую систему программными и техническими средствами вычислительных сетей (ВС).

Во время работы РСОД могут в силу различных причин происходить инциденты, которые могут приводить к возникновению искаженных данных, ошибочным результатам решения задач и обработки запросов системой. В самом неблагоприятном случае последствия серьезных инцидентов могут привести к невозможности нормального функционирования системы, т.е. к отказу РСОД, потере системой работоспособности. Восстановление потерянной в результате инцидента информации и последующее восстановление работоспособности РСОД может по-

¹Сергей Константинович Сомов, ведущий инженер
(ssomov2016@ipu.ru)

требовать значительных затрат ресурсов и времени. А в критических ситуациях восстановление работоспособности системы может быть просто невозможным.

Одним из методов решения задачи повышения безопасности и работоспособности систем обработки данных является применение информационной избыточности (создание и хранение резервных данных) [1]. В РСОД основным методом обеспечения сохранности данных служит метод резервирования, который предполагает использование следующих видов избыточности: создание и хранение копий массивов данных и/или создание и хранение предыстории массивов данных (предыдущие версии массива вместе с журналами их изменений).

2. Описание проблемы

В работах [2, 3] представлены особенности и сформулированы задачи оптимального резервирования, сделанные в предположении, что резервируемые в системе массивы данных используются независимо друг от друга. Это позволило упростить проблему повышения безопасности систем обработки данных и сформулировать и представить решения задач оптимального резервирования независимо и отдельно каждого массива данных. На практике же в системах обработки данных разного класса и назначения чаще всего решаются задачи и обрабатываются запросы, для которых требуется использование некоторого множества массивов данных, взаимосвязанных между собой по ссылкам или алгоритмически.

Использование методов резервирования в РСОД по сравнению с системами, работающими на базе автономных компьютеров, обладает рядом особенностей [3], одна из которых заключается в том, что, в случае хранения резерва данных в нескольких узлах сети для обработки поступающих запросов можно использовать различные дисциплины. Ниже дано краткое описание четырех основных дисциплин обработки запросов:

1. Запрос пересылается и обрабатывается в ближайшем (согласно некоторому критерию) узле с резервом массива данных, необходимого для обработки запроса.

2. Запрос пересылается для обработки одновременно в несколько узлов с требуемым резервом.

3. Запрос, возникший в узле j , последовательно пересылается по узлам пути длины K , начинающегося в узле j и состоящим из узлов с резервом требуемого массива. Запрос пересылается по узлам этого пути до тех пор, пока он или не будет успешно обработан в одном из узлов, либо не будет пройден весь путь без получения ответа на запрос.

4. Запрос, возникший в узле j , поочередно посылается для обработки в K ближайших узлов с необходимым резервом. Запрос посылается в ближайшие узлы до тех пор, пока из очередного узла не будет получен ответ, либо все узлы не будут опрошены без получения требуемого ответа.

Повышение безопасности работы РСОД посредством оптимального размещения используемых системой массивов данных подразумевает необходимость учета при этом взаимосвязей массивов друг с другом, а также других особенностей резервирования данных в вычислительных сетях [3]. Помимо этого при поиске оптимального размещения резерва необходим также учет и других параметров ВС, таких, как топология сети, трафик запросов различного типа, надежность функционирования каналов связи и отдельных компьютеров и т.д.

Сформулируем задачи оптимального резервирования взаимосвязанных массивов данных в РСОД.

3. Задачи резервирования взаимосвязанных массивов

Рассмотрим ВС, состоящую из N узлов, на базе которой работает РСОД. В системе при решении J различных задач используется M массивов данных. При этом каждая из задач системы может решаться в нескольких различных узлах сети и использует несколько различных массивов данных. Пусть W_j это количество решений в РСОД задачи j ($j=1-J$), которое выполняется за некий момент времени (например, час, сутки, неделя, месяц, квартал и т.п.).

Пусть ψ_{jn} это переменная такая, что $\psi_{jn}=1$, если задача с номером j решается в n -м узле сети; x_{nm} - объем резерва массива

m , который размещен в n - м узле сети, L_m – размер m -го массива данных в байтах; U_{jm} - среднее число информационных запросов задачи j к m -му массиву данных, а V_{jm} это среднее число запросов на модификацию m - го массива данных, которые возникают при решении задачи j .

Сделаем предположение, что задача в системе успешно решена только в том случае, если на все запросы, возникающие в процессе ее решения ко всем необходимым для решения массивам данных, получены ответы. В этом случае вероятность $P_{nj}(X)$ решения задачи j в узле n ВС при распределении резерва $X=||x_{nm}||$ будет равна:

$$P_{nj}(X) = \sum_{m=1}^M [\rho_{nm}(X)]^{U_{jm}} \beta_{nm}^{V_{jm}}$$

В данной формуле $\rho_{nm}(X)$ - это вероятность получения ответа на информационный запрос, выданный в узле сети n к массиву m . Значение данной вероятности зависит от того, какая используется дисциплина обработки запроса, и определяется по соответствующей формуле, приведенной в таблице 2 в работе [3]; $\beta_{nm}(X)$ - это вероятность успешной обработки запроса на обновление m - го массива данных, выданного в узле n сети. Предположим, что значение этой вероятности равно вероятности события, заключающегося в обновлении, по крайней мере, одного из массивов данных, размещенного в одном из узлов сети с резервом, с последующим получением подтверждения об успешном обновлении массива. С учетом сделанного предположения вероятность успешной обработки запроса на обновление массива данных будет равна:

$$\beta_{nm}(X) = 1 - \prod_{i=1}^N [1 - r_{ni} P_i(x_{im}) r_{in}]$$

Здесь $P_i(x_{im})$ - вероятность успешной обработки запроса в узле i , который содержит размещенный в нем резерв объемом x_i , а r_{ni} – надежность канала связи между узлами n и i сети (при этом будем считать, что $r_{ni} = r_{in}$).

Пусть $T_{nj}(X)$ это суммарное время ожидания ответов на все запросы, выданные в узле n сети при решении задачи j . Это время будет равно:

$$T_{nj}(X) = \sum_{m=1}^M \{U_{jm}t'_{nm}(X) + V_{jm}t''_{nm}(X)\}$$

Здесь $t'_{nm}(X)$ - время получения ответа на запрос к массиву m , который был сформирован в узле n ; время $t''_{nm}(X)$ - это время обработки запроса на модификацию данных массива m , в соответствии с запросом, выданным в узле n .

Стоимость функционирования РСОД – $S(X)$ в течение рассматриваемого периода времени состоит из стоимости хранения резерва в узлах сети и стоимости решения всех задач системы и, следовательно, будет равна:

$$S(X) = \left\{ \sum_{j=1}^J W_j \sum_{n=1}^N \varphi_{jn} \left[V_{jm} \sum_{i/x_{im} \neq 0} ZP_{ni}(x_{im}) + \right. \right. \\ \left. \left. + U_{jm} \min_{i/x_{im} \neq 0} ZP_{ni}(x_{im}) \right] + L_m \sum_{n=1}^N S_n x_{nm} \right\}$$

Здесь:

$ZP_{ni}(x_{im})$ - величина средних производительных затрат на обработку запроса, посланного из узла n на обработку в узел i , которая равна:

$$ZP_{ni}(x_{im}) = 2D_{ni} + E_i(x_{im})h_i;$$

S_n - стоимость хранения одного бита информации в узле n сети в течение рассматриваемого периода времени;

Задача определения резервирования M взаимосвязанных массивов данных, оптимального по критерию минимума стоимостных затрат $S(X)$ на функционирование РСОД будет иметь следующую формулировку. Необходимо найти такое оптимальное размещение резерва используемых в системе взаимосвязанных массивов данных по узлам ВС, которое обеспечит минимум стоимости функционирования системы. При этом найденное решение задачи должно соответствовать следующим ограничениям: на вероятность успешной обработки запроса в узлах сети; должно обеспечивать затраты времени на ожидание ответов на запросы не более заданного лимита; ограничение на объем резерва, размещаемого в каждом из узлов ВС. Таким образом, задача имеет формулировку, представленную ниже:

$$S(X) \rightarrow \min$$

при ограничениях:

$$P_{nj}(X) \geq \bar{P}_j;$$

$$T_{nj}(X) \leq \bar{T}_j;$$

$$\sum_{m=1}^M x_{nm} L_m \leq Q_n$$

Аналогично формулируются задачи поиска оптимального размещения в ВС резерва взаимосвязанных массивов, используемых в РСОД, при применении других критериев оптимальности решения. Например, при использовании такого критерия оптимальности размещения резерва, как максимум вероятности успешного решения всех задач системы за заданный период времени, задача будет иметь следующую формулировку:

$$P(X) = \prod_{j=1}^J \prod_{n=1}^N [P_{nj}(X)]^{w_j} \rightarrow \max$$

При следующих ограничениях:

$$S(X) \leq \bar{S};$$

$$T_{nj}(X) \leq \bar{T}_j;$$

$$\sum_{m=1}^M x_{nm} L_m \leq Q_n$$

Здесь $j=1-J$, $n=1-N$.

Для решения сформулированных задач в силу их большой размерности необходимо применять эвристические алгоритмы. Формулировки задач сделаны в предположении, что они решаются в два этапа. Целью первого этапа является определение оптимального размещения копий массива данных по узлам ВС – Γ^0 (при этом в одном узле размещается не более одной копии массива). Это размещение находится в результате решения задач с помощью известных алгоритмов [4,5,6].

В случае, если найденное на первом этапе решение не обеспечивает выполнение ограничений задачи, то выполняется второй этап решения. На этом этапе для каждого узла из множе-

ства Γ^0 решается своя задача определения оптимального объема резерва в этом узле. Для решения этих задач на втором уровне используются традиционные методы (методы решения задач распределения ограниченных ресурсов) [3].

4. Литература

1. КУЗНЕЦОВ Н.А., КУЛЬБА В.В., МИКРИН Е.А. и др.; *Информационная безопасность систем организационного управления. Теоретические основы в 2 т.* // [отв.ред. Н.А. КУЗНЕЦОВ, В.В. КУЛЬБА]; Ин-т проблем передачи информации. РАН. – М. : Наука, 2006, 427с.
2. КУЛЬБА В.В., МАМИКОНОВ А.Г., ШЕЛКОВ А.Б. *Резервирование программных модулей и информационных массивов в АСУ.* // Автоматика и телемеханика, - 1980. - № 8. – С. 133-141.
3. КУЛЬБА В.В., СОМОВ С.К., ШЕЛКОВ А.Б. *Резервирование данных в сетях ЭВМ.*// Казань, Издательство казанского университета, 1987, - 175 с.
4. MACHMOUD S., RIORDON J.S. *Optimal Allocation of Resources in Distributed Information networks.* // ACM Transactions on Database Systems, 1976, Vol.1, N.4, p. 66-78.
5. CHU W.W, *File Allocation in an Multiple Computer System.* //IEEE Transactions on Computers, 1969, Vol. C-18, N. 10, p. 885-889.
6. CASEY R.G. *Allocations of copies of a file in an Information Network.* //AFIPS Conference Proceedings, - 1972, Vol. 40. - P. 617-625.

THE REDUNDANCY OF THE INTERCONNECTED DATA ARRAYS IN

Sergey Somov, Institute of Control Sciences of RAS, Moscow, Cand.Sc., Lead Engineer (ssomov2016@ipu.ru).

Abstract: The article discusses the use of information redundancy in distributed data processing systems that operate within the compu-

ting networks, to improve the safety their operation. The article also deals with the problems of data arrays redundancy optimization in such systems taking into account arrays relationship with each other.

Keywords: distributed data processing systems, redundancy of interconnected data arrays, the data arrays redundancy optimization problem.

Статья представлена к публикации
членом редакционной коллегии ...заполняется редактором...

Поступила в редакцию ...заполняется редактором...
Опубликована ...заполняется редактором...