

АЛГОРИТМ АДАПТИВНОЙ БАЛАНСИРОВКИ НАГРУЗКИ КЛАСТЕРНЫХ СИСТЕМАХ

Вопросам управления нагрузкой в кластерных системах уделяется большое внимание в научной литературе, что подчеркивает важность актуальность решаемой задачи. Теоретические исследования и разработка фундаментальных основ распределения нагрузки, создание математического аппарата, моделей и методов управления для распределения нагрузки в кластерных web-серверах рассматривались в работах ученых R. Mukherjee [1], G. Banga, V. Cardellini [2], E. Casalicchio [3], Xiao Qin, Hong Jiang, Zhu, David R., Зар Ней Линг. Вопросами, связанными только с балансировкой нагрузки занимались E. Casalicchio, H.K. Lee, M. Andreolini; оптимизация производительности – T. Schroeder [4], T. Vercauteren, X. Wang; перегрузка – A. Kamra, V. Misra [5], Черкасова Л. [6]; диспетчеризация на географическом масштабе - V. Cardellini [7], P.Yu, Y.S. Hong [8].

Известные алгоритмы поиска решений для распределения запросов большинстве используют приближенные или эвристический алгоритмы, но не учитывают множества параметров, таких как производительность, объем свободной оперативной памяти, скорость выполнения вычисления, которые необходимо анализировать при реализации балансировки нагрузки (БН).




Рисунок 1 – Архитектура кластерного web сервера

Целью данной статьи является разработка адаптивного алгоритма БН, функционирование которого позволит увеличить пропускную способность web сервера, уменьшить время обработки запроса и снизить затраты на эксплуатацию.

Механизм БН играет важную роль в обеспечении пропорциональной распределения ресурсов кластерного web сервера. В общем виде архитектуру кластерного web сервера можно представить в виде (рис.1).

Эффективность системы БН зависит от алгоритма распределения запросов. Анализ литературы [1-9,11-13] показывает, что существующие алгоритмы балансировки нагрузки можно разделить на 2 основных класса: контенто-зависимые (7-ого уровня модели OSI) и контенто-независимые (4-ого уровня модели OSI) алгоритмы. В свою очередь эти классы делятся на подклассы в зависимости от учета динамики системы.




Рисунок 2 – Классификация существующих алгоритмов БН в web кластерах

С использованием разработанного авторами генератора самоподобного шума [10], выполнен анализ известных алгоритмов балансировки, с целью выявления их достоинств и недостатков. В качестве исследуемых алгоритмов выбраны четыре алгоритма каждого класса:


RR (round robin) – статический алгоритм 4-ого уровня модели OSI;

WRR (weighted round robin) – динамический алгоритм с обратной связью 4-ого уровня модели OSI;

CAP (client aware policy) – контенто-зависимый алгоритм 7-го уровня модели OSI;

LARD (locality aware policy) – контенто-зависимый алгоритм 7-го уровня модели OSI, учитывающий загрузку серверов.


Пакетажи оптимизацијају се уз помоћ вештачке интелигенције (AI).
 - RR (round robin) – испоцетнији крајеви архива
 - Pакетажи оптимизацијају се уз помоћ AI:
 • AI (locality aware request distribution) – архиви T-oro још један модел
 • AI (locality aware request distribution) – оптимизација је већа и користи AI
 • WRR (weighted round robin) – унапређенији модел
 • WRR (weighted round robin) – унапређенији модел
 • WRR (weighted round robin) – унапређенији модел
 • WRR (weighted round robin) – унапређенији модел




Пријеко 3 – Пакетажење хватањем сатија посебно са чином изабраног архива CAP

Пријеко 4 – Пакетажење хватањем сатија посебно са чином изабраног архива WR

- CAP (client aware policy) – архиви T-oro још један модел OSI. Пакетажају се сатије, а да обрађујују се сатије које су уписане у паметнији гравијер
- WR (client aware policy) – архиви T-оро још један модел OSI. Пакетажају се сатије, а да обрађујују се сатије које су уписане у паметнији гравијер



Пријеко 6 – Пакетажење хватањем сатија посебно са чином изабраног архива LARD



Пријеко 7 – Пакетажење хватањем сатија посебно са чином изабраног архива Xpectra

Пријеко 8 – Пакетажење хватањем сатија посебно са чином изабраног архива Xpectra

Пријеко 9 – Пакетажење хватањем сатија посебно са чином изабраног архива Xpectra

Пријеко 10 – Пакетажење хватањем сатија посебно са чином изабраног архива Xpectra

зации рекомендаций, представленных в [12,13] и собственных разработаний разделены по ожидаемому влиянию на сервер. В таблице 1 представлена классификация http запросов. Количество последовательных запросов, которые пользователь посыпает на web сайт, описывается нормальным распределением Гаусса, размер запрашиваемых файлов нормальным распределением, время обслуживания запроса на сервере определением Вейбула и зависит от класса запроса.

Таблица 1

Классификация http запросов по ожидаемому влиянию на сервер

Класс запроса	Пример файла	CPU требования (%)
1	Статическая информация: html	0,009-0,005
2	Динамические html страницы: php, jsp и asp	0,2-0,28
3	Информация безопасности (операция шифрования), операции поиска (требуют большое количество CPU ресурсов)	0,43-0,49
4	Мультимедиа (передача аудио и видео в реальном времени)	0,75-1,5

В качестве оценок эффективности работы алгоритмов используются:

- равномерность загруженности серверов;
- количество потерянных запросов;
- производительность серверов (пропускная способность).

Для оценки эффективности работы алгоритмов предложен интегральный критерий оптимизации системы балансировки нагрузки, основанный на загрузке ресурсов серверов обработки запросов:

$$s = \sqrt{\frac{\sum_{j=1}^N (\bar{U}(k) - U_j(k))^2}{j}}$$

где $U_j(k)$ - интегральный показатель загруженности j -ого сервера на k -м шаге;

$\bar{U}(k)$ - средняя загрузка серверов на k -м шаге;

N - количество серверов в кластере.

Результаты моделирования приведены на рисунках 7-10:




Рисунок 7 – Интегральный критерий оптимизации системы БИ

Количество потерянных запросов на каждом из 3-х серверов приведено на рисунке 8:




Рисунок 8 – Количество потерянных запросов

прогноза на каждом шаге должен меняться в зависимости от изменившегося потока. Выводы. В статье приведена детальная классификация существующих алгоритмов распределения нагрузки. Проанализирована работа и оценены основные показатели работы. Исходя из достоинств и недостатков существующих решений, предложен адаптивный балансировки нагрузки. В качестве оценки эффекта работы предложен интегральный критерий оптимизации сбалансировки нагрузки, основанный на загрузке ресурсов серверов обработки запросов.

1. R. Mukherjee, A Scalable and Highly Available Clustered Web Server in Performance Cluster Computing: Architectures and Systems, vol. 1, Rajkumar Buyya, Prentice Hall, 1999.
2. V. Cardellini, E. Casalicchio, M. Colajanni, A performance study of distributed architectures for the quality of web services, in: Proc. of the 34th Conference on System Sciences, Vol. 10, 2001.
3. E. Casalicchio, M. Colajanni, A client aware dispatching algorithm for web clients providing multiple services, in: Proc. of the 10th International Conf. on WWW, 2001, 535–544.
4. T. Schroeder, S. Goddard, B. Ramamurthy, Scalable web server clustering technology, IEEE Network (May–June) (2000) 38–45.
5. A. Kamra, V. Misra, E.M. Viehman, Yaksha: a self-tuning controller for managing performance of 3-tiered web sites, in: 12th IEEE International Workshop on Quality Service, IWQOS 2004, 2004, pp. 47–56.
6. L. Cherkasova, P. Phaal, Session-based admission control: a mechanism for peak management of commercial web sites, IEEE Transactions on Computers 51 (June 2002).
7. V. Cardellini, E. Casalicchio, M. Colajanni, Ph.S. Yu, The state of the art in load balanced web-server systems, ACM Computing Surveys (CSUR) 34 (June (2)) (2002) 263–311.
8. Y.S. Hong, J.H. No, S.Y. Kim, DNS-based load-balancing in distributed web servers, in: Fourth IEEE Workshop on Software Technologies for Future Embedded Ubiquitous Systems (WCCIA 2006), 2006, p. 4.
9. S. Sharifian, et al., A predictive and probabilistic load-balancing algorithm for cluster-based web servers, Appl. Soft Comput. J. (2010), doi:10.1016/j.asoc.2010.01.017
10. О. Бессара́б В.Н., Илья́менко Е.І., Червінський В.В. Генератор самоподобної графіка для моделей інформаційних систем. Вісник Східноукраїнського Національного Університету ім. Володимира Даля № 2 (144), 2010.
11. E. Casalicchio, I. Cardinellini. Content aware dispatching algorithms for cluster-based Web servers. Kluwer Academic Publishers. Cluster Computing 5, 2002.
12. Ebuda Sarkhan, Alf Ghoshawala. Queue Weighting Load-Balancing Technique Database Replication in Dynamic Content Web Sites. Proceedings of the 9th WSEAS International Conference on APPLIED COMPUTER SCIENCE, 2009.
13. Zhang Lin, Li Xiao-ping. A content based dynamic load-balancing algorithm for heterogeneous Web server cluster. ComSIS Vol.7, №1, Special Issue, 2010.

Поступила 15.09.2010