

УДК 621.391.31

# МЕТОД БОРЬБЫ С ПЕРЕГРУЗКОЙ НА SIP-СЕРВЕРЕ С УЧЕТОМ ДИНАМИЧЕСКОГО ПРИОРИТЕТА И ТЕКУЩЕЙ ФАЗЫ УСТАНОВЛЕНИЯ СОЕДИНЕНИЯ



[Е.Д. КУЗЬМИНЫХ](#)

Харьковский национальный  
университет радиоэлектроники

*Запропоновано метод боротьби з перевантаженням на SIP-сервері, в якому обслуговування викликів реалізовано за допомогою алгоритму з динамічним пріоритетом і дисципліною обслуговування LIFO в режимі перевантаження з урахуванням поточної фази встановлення з'єднання. Цей метод дозволяє підвищити ефективність роботи SIP-сервера в умовах великого навантаження.*

*A SIP-server overload control method that implement call control algorithm with dynamic priority and LIFO service discipline under overload using the current phase of the connection is proposed. This method increases the efficiency of SIP-networks under heavy load.*

*Предложен метод борьбы с перегрузкой на SIP-сервере, в котором обслуживание вызовов осуществляется по схеме с динамическим приоритетом и дисциплиной обслуживания LIFO в режиме перегрузки с учётом текущей фазы установления соединения. Этот метод позволяет повысить эффективность работы SIP-серверов в режиме высокой нагрузки.*

## Введение

Производительность серверов обработки вызовов определяется количеством вызовов, которые способен обслужить сервер в единицу времени. Когда интенсивность вызовов превышает пропускную способность сервера, он переходит в режим перегрузки, время ожидания обслуживания на сервере увеличивается. Клиент ждет ответа на запрос и, не дождавшись, отправляет повторный запрос на установление соединения. Это приводит к еще большему увеличению входной нагрузки на сервер и усугубляет перегрузку. В этой ситуации при отсутствии метода контроля перегрузки производительность сервера резко ухудшается. SIP-прокси-серверы, являющиеся основными элементами, выполняющим функции установления/поддержки/разъединения соединения в сетях IP-телефонии, могут быть подвержены резкому увеличению входной нагрузки по ряду причин: из-за сбоя на элементах сети, во время проведения телевизионных шоу или при умышленных DoS-атаках [1].

В спецификации протокола SIP [2] нет точных указаний, как реагировать на перегрузку. Протокол SIP предусматривает базовый метод управления перегрузками, который использует код ошибки 503 (Service Unavailable). В случае, если SIP-сервер не может обработать запрос из-за временной перегрузки, он отклоняет запрос с кодом ошибки 503. Это сообщение означает, что отправитель должен повторить отправку сообщения через некоторое время или направить запрос на другой

сервер. Перегруженный сервер также может добавить Retry-After заголовок в SIP-сообщение, указав время в секундах, в течение которого на сервер не следует обращаться. Отправитель прекращает отправку сообщений на этот период времени, сообщения направляются на альтернативный сервер, а отправка сообщений на перегруженный сервер возобновляется по истечении интервала времени, указанного в заголовке. Если альтернативный сервер отсутствует, и заголовок Retry-After не указан, то сервер SIP должен отправить ответ 500 (Server Internal Error) агенту пользователя. Хотя этот метод снижает нагрузку на перегруженный прокси-сервер, но приводит к перенаправлению трафика, который вызвал перегрузку, на другой прокси-сервер, который затем тоже может перегрузиться.

В режиме большой нагрузки перегруженный сервер SIP может сообщать о своем состоянии соседним серверам и просить их уменьшить нагрузку. Но на практике такие методы борьбы с перегрузкой с обратной связью не всегда реализованы. Поэтому очень важно, чтобы серверы SIP могли локально защитить свои собственные ресурсы, необходимые для обработки сообщений, за счет реализации соответствующих локальных методов борьбы с перегрузкой. Как правило, такие методы включают процедуру измерения нагрузки на систему и её сравнение с фиксированным значением. Когда пороговое значение загрузки системы достигнуто или превышено, запускается процедура борьбы с перегрузкой. Существует несколько локальных методов борьбы с перегрузкой, описанных в литературе [3-6], которые для измерения нагрузки на систему могут использовать длину очереди буфера, загрузку процессора, число активных INVITE-транзакций, среднее время задержки пакетов в буфере сервера и другие параметры. В этих методах используется стандартная схема обслуживания вызовов, предусмотренная в [2], когда в режиме высокой нагрузки все новые запросы на соединение отбрасываются ответом 503, хотя некоторые из этих запросов могут быть близки к установлению соединения.

Для улучшения эффективности работы SIP-сервера в режиме высокой нагрузки был разработан метод борьбы с перегрузкой на SIP-сервере с учётом текущей фазы установления соединения и динамическим приоритетом. В первой части статьи рассмотрен алгоритм обслуживания вызовов на SIP-сервере согласно этому методу. Во второй части статьи произведена оценка предложенного алгоритма на примере метода на основе двухпозиционного регулирования BBC (Bang Bang Control) [6] по параметрам производительности сервера: времени установления соединения и пропускной способности сервера. В третьей части статьи произведена оценка предложенного алгоритма по параметрам скорости реакции на перегрузку и скорости восстановления после перегрузки.

## **I. Метод борьбы с перегрузкой на SIP-сервере**

Основываясь на указанных в [1, 7] принципах управления перегрузкой, был предложен метод борьбы с перегрузкой на SIP-сервере, который учитывает фазу установления соединения и приоритет пользователя. Данный метод представлен в

виде блок-схемы алгоритма обслуживания вызовов на SIP-сервере (рис.1), который отличается от стандартного алгоритма введением блока классификатора и введением детерминированной схемы маркировки сообщений.




Рис. 1. Блок-схема алгоритма обслуживания вызовов на SIP-сервере

Шаг 1. Каждое новое сообщение поступает на SIP-сервер в блок обработки. Этот блок содержит буферную память, классификатор сообщений и модуль обработки. Буферная память условно разделена на две части для поступающих на сервер сообщений и сообщений-таймеров (рис. 2. и 3). В нормальном режиме работы SIP-сервер принимает сообщения на обслуживание в порядке поступления их в очередь по принципу FIFO, а сообщения в буферной памяти для таймеров стоят в порядке истечения таймеров. Поступающие на сервер сообщения проходят через блок контроля перегрузки. Блок на основе заранее заданных критериев принимает решение о постановке сообщения в очередь или об отклонении сообщения. По завершению обслуживания производится отправка сообщения дальше по сети и одновременно с этим происходит установка таймера в буферную память. По истечении таймера сообщения ставятся в очередь на повторную отправку.

В режиме перегрузки сообщения сначала попадают на классификатор (рис. 2), в котором они разделяются по типу транзакций на INVITE и не-INVITE и распределяются в очереди в зависимости от приоритета.




Рис. 2. Блок классификатора сообщений

В режиме перегрузки сообщения с большим приоритетом имеют большую вероятность быть обслуженными. Для выбора сообщения из очереди будем использовать динамический приоритет, так как статический может привести к недообслуживанию очередей низкого приоритета. Для выбора очереди используем два параметра, которые рассчитываются для каждой очереди:

- количество ожидающих запросов в очереди ( $N_i$ );
- коэффициент значимости очереди ( $U_i$ ).

Тогда приоритет очереди можно определить как  $N_i \times U_i$ . Коэффициент значимости очереди выбирается в зависимости от важности сообщений, находящихся в этой очереди. Значение этого коэффициента может быть получено из статистических данных, описывающих запросы пользователей. Учитывая длину очереди на получение приоритета, мы снижаем длительность ожидания в обслуживании сообщений из очередей с более низким приоритетом.

Кроме того, в режиме перегрузки сообщения, принадлежащие не-INVITE транзакции, обслуживаются по принципу FIFO (First In – First Out). Если сообщение принадлежит INVITE-транзакции, то в этом случае учитывается текущая фаза установления соединения. Если это запрос на новое соединение (фаза 1), то сообщение отклоняется кодом 503. Если запрос INVITE уже обрабатывается сервером (фаза 2 и 3), сообщения поступают в начало очереди и обслуживаются по принципу LIFO (Last In First Out). Дисциплина обслуживания LIFO обеспечивает лучшую пропускную способность и меньшую задержку в очереди в режиме перегрузки по сравнению с FIFO [8, 9].

Шаг 2. Блок мониторинга ресурсов служит для определения состояния сервера по загрузке ресурсов и является индикатором перегрузки. Ресурсы, по которым может проводиться мониторинг состояния сервера, могут быть различными, например, загрузка ЦП, задержка в очереди буфера, текущая длина очереди в буфере и т.п. Пример развернутого блока мониторинга ресурсов представлен на рис. 3. Процесс определения перегрузки на SIP-сервере определяется методами борьбы с перегрузкой.




Рис. 3. Блок мониторинга ресурсов

Шаг 3. После того как нагрузка превысила пороговое значение, SIP-сервер переходит в состояние перегрузки и меняет порядок обслуживания сообщений, учитывая приоритет обслуживания. В классификаторе происходит разделение сообщений, и запросы на установление новой сессии отклоняются ответом 503 или 500 для конечных узлов согласно RFC 3261. Процесс отклонения сообщений зависит от метода борьбы с перегрузкой и реализуется пробалистической схемой маркировки сообщений. Но, как показано в [10], детерминированная схема имеет лучшую производительность, чем пробалистическая, имея меньший коэффициент вариации значения вероятности отказа в обслуживании. В этом алгоритме переменная  $r$  имеет начальное значение, равное 0. Решение принять или отклонить сообщение принимается по алгоритму на рис. 4, где  $f$  – вероятность приёма сообщения на обслуживание. Учёт фазы установления соединения и использование динамического приоритета при обслуживании очередей позволит увеличить пропускную способность сервера SIP; смена порядка обслуживания сообщений с FIFO на LIFO позволит сократить время установления соединения; использование детерминированной схемы управления отказами позволит уменьшить затраты ресурсов сервера на отказы в режиме перегрузки. Одновременное использование перечисленных методов для борьбы с перегрузкой на сервере SIP позволит повысить эффективность работы сервера.




Рис. 4. Алгоритм маркировки сообщений

## II. Исследование производительности SIP-сети при использовании метода БП BBC

В качестве основных показателей производительности SIP-сети для оценки методов борьбы с перегрузкой на сервере SIP были выбраны показатели времени установления соединения и пропускной способности сети, которая характеризуется долей установленных соединений. Для исследования эффективности этих методов было выбрано 4 алгоритма обслуживания вызовов на SIP-сервере:

- 1) обслуживание по принципу FIFO в нормальном режиме и в режиме перегрузки;
- 2) обслуживание по принципу LIFO в нормальном режиме и в режиме перегрузки;
- 3) приоритетное обслуживание сообщений Prio с учётом фазы установления соединения по принципу FIFO в нормальном режиме и по принципу LIFO в режиме перегрузки;
- 4) при отсутствии метода борьбы с перегрузкой, т.е. все сообщения обслуживаются всегда в порядке FIFO, а при переполнении буфера сообщения отбрасываются без генерации ответа 503.

Моделирование проводилось раскрашенными сетями Петри [11] на модели SIP-сети, описанной в статье [12]. В соответствии с выбранным алгоритмом обслуживания вызовов и выбранным методом борьбы с перегрузкой менялся блок буфера *Buffer* модели.

Эксперименты проводились для изучения временных параметров сервера в зависимости от увеличения нагрузки. Распределение задержек в сети подчинялось гамма-закону с параметрами  $\text{Gamma}(1.0, 5.0)$ , а задержки в обслуживании сообщений равнялись 2,6 мс для сообщений типа не-INVITE и 11,64 мс для сообщений типа INVITE в соответствии с данными, полученными на реальной сети. Нагрузка на сервер была нормирована таким образом, что значение условной единицы  $\rho$  было равно нагрузке, создаваемой трафиком с интенсивностью, равной пропускной способности сервера. Значения для верхнего и нижнего порогов обнаружения перегрузки были выбраны равными  $H = 80\%$  и  $L = 60\%$  соответственно. Количество экспериментов было выбрано таким образом, чтобы минимизировать дисперсию показателей производительности сети до 0,5% при доверительном интервале в 90 %.

На рис. 5 представлены соответствующие зависимости времени установления соединения в сети SIP и пропускной способности сервера от интенсивности сигнального трафика при разных алгоритмах обслуживания вызовов, используемых в методе борьбы с перегрузкой BBC, где  $\rho$  – это нормированная нагрузка на сервер. Анализ результатов показывает, что применение алгоритма обслуживания Prio с учётом текущей фазы установления соединения в режиме перегрузки даёт лучшие показатели эффективности, чем применение других. По сравнению с другими алгоритмами он в 1,4 раза уменьшает задержку установления соединения в режиме перегрузки SIP-сервера. Время установления соединения с применением методов борьбы с перегрузкой улучшается в среднем в 5-6 раз по сравнению с решениями без учета перегрузки.




Рис. 5. Зависимость времени установления соединения (а) и пропускной способности сервера (б) от входящей нагрузки

Выигрыш по пропускной способности сервера SIP в режиме перегрузки для этого алгоритма LIFO-Prio составляет 2,6 % по сравнению с LIFO, 3,8 % - по сравнению с FIFO и 38 % по сравнению с работой сервера без применения метода борьбы с перегрузкой.

### III. Оценка эффективности метода борьбы с перегрузкой при нестационарной нагрузке

Для эффективной работы методов борьбы с перегрузкой на SIP-сервере важным параметром является скорость реакции на перегрузку и скорость восстановления после перегрузки. Для оценки этих параметров был проведен эксперимент, когда на сервер подавалась нагрузка нестационарного характера. В сценарии первые 10 секунд интенсивность сигнальной нагрузки была 26 вызв/с ( $\rho = 0,7$ ), после чего интенсивность резко увеличивалась до 74 вызв/сек ( $\rho = 2$ ) и оставалась на этом уровне в течение 20 с, а затем резко падала обратно до 26 вызв/с ( $\rho = 0,7$ ). Целью данного моделирования является изучение того, как быстро алгоритмы борьбы с перегрузкой на SIP-сервере могут реагировать на внезапное появление перегрузки и внезапное прекращение перегрузки.

Результаты моделирования представлены на рис. 6. Как видно из результатов, при отсутствии метода борьбы с перегрузкой наблюдается очень медленная реакция на перегрузку. Это связано с тем, что сервер теряет сообщения, и отправитель пытается установить соединение, посылая повторные сообщения. Из-за повторных передач увеличивается время установления соединения. При использовании метода борьбы с перегрузкой повторные передачи блокируются, т.к. отправителю отсылается ответ 503, после получения которого отправитель должен прекратить все повторные передачи. Реакция на перегрузку при использовании метода двухпозиционного регулирования почти мгновенна из-за применения постоянного мониторинга загрузки длины очереди.




Рис. 6. Динамика поведения SIP-сервера при нестационарной входной нагрузке

Анализ данных показывает, что время восстановления после перегрузки при применении алгоритма FIFO составляет 1880 мс, при применении алгоритма Prio – 1100 мс. Это означает, что при применении алгоритма Prio скорость реакции на прекращение перегрузки в 1,7 раза меньше, чем при алгоритме FIFO, и в 20 раз меньше, чем при работе сервера без контроля перегрузки.

## Выводы

В работе для повышения эффективности работы методов борьбы с перегрузкой на SIP-серверах был предложен алгоритм обслуживания вызовов на SIP-сервере с динамическим приоритетом и дисциплиной обслуживания LIFO в режиме перегрузки с учётом текущей фазы установления соединения.

1. Для максимизации пропускной способности сервера при обработке сообщений клиентов, которые приносят доход оператору, было предложено использовать схему динамических приоритетов. Чтобы не было простаивающих очередей с низким приоритетом, была использована динамическая схема для выбора сообщения из очереди, основанная на длине очереди и коэффициенте значимости сообщения.

2. Для максимизации общей пропускной способности SIP-сервера было предложено использовать политику обслуживания сообщений LIFO при перегрузке и FIFO при нормальной нагрузке. Для уменьшения расходов ресурсов на генерацию случайных чисел было предложено использовать детерминированную схему маркировки сообщений, которые не могут быть обслужены.

3. С использованием возможностей пакета имитационного моделирования CPN Tools была проведена оценка работы сервера SIP с контролем перегрузки и без контроля по показателям среднего времени установления соединения и пропускной способности сервера.

Анализ результатов показал, что с применением методов борьбы с перегрузкой время установления соединения улучшается в 5 - 6 раз, и на 38 % увеличивается пропускная способность сервера в режиме перегрузки по сравнению с работой сервера без механизма управления перегрузкой. Кроме того, в ходе анализа установлено, что применение алгоритма Prio, который базируется на обслуживании сообщений с учётом текущей фазы установления соединения, позволяет в 1,4 раза уменьшить задержку установления соединения по сравнению с другими алгоритмами и даёт выигрыш по пропускной способности 2,6 % по сравнению с LIFO и 3,8 % - по сравнению с FIFO в режиме перегрузки SIP-сервера при расхождении значений 0,5% при доверительном интервале в 90 %.

4. В работе проведен анализ эффективности метода борьбы с перегрузкой при нестационарном характере входящей нагрузки. Это было проведено с целью установления скорости реакции на перегрузку и скорости восстановления от перегрузки. Установлено, что время восстановления после перегрузки при применении алгоритма Prio в 2-3 раза меньше, чем при применении FIFO, при нагрузке в 2 раза большей, чем пропускная способность сервера.

#### Список литературы:

1. Rosenberg J. Requirements for Management of Overload in the Session Initiation Protocol, IETF RFC 5390, December 2008. — 14 p.
2. Rosenberg J., Schulzrinne H. SIP: Session Initiation Protocol, IETF RFC 3261, June 2002.. — 269 p.
3. Ohta M. Overload Control in a SIP Signaling Network // International Journal of Electrical and Electronics Engineering 3:2. — 2009. — P. 87-92.
4. Kasera S., Pinheiro J., Loader C. and others. Robust multiclass signaling overload control // Proc. of the 13TH IEEE International Conference on Network Protocols ICNP '05. — 2005. — P. 246 – 258.
5. Shen S., Schulzrinne H., Nahum E. Session Initiation Protocol (SIP) Server Overload Control: Design and Evaluation // Principles, Systems and Applications of IP Telecommunications. Services and Security for Next Generation Networks. Lecture Notes in Computer Science. — 2008. — Vol.5310/2008. — P. 149-173.
6. Hilt V., Widjaja I. Controlling overload in networks of SIP servers // In IEEE International Conference on Network Protocols. — 2008. — P. 83–93.
7. Jenkins Ian. NGN Control Plane Overload and its Management // Proc. of MultiService Forum. — 2006. — 11 p.
8. Цыбаков Б.С., Папантони-Казакос П. Наилучшая и наихудшая дисциплины передачи пакетов // Проблемы передачи информации. — 1996. — Том 32. — Вып. 4. — С. 72-92.
9. Doshi T, Heffes H. Overload Performance of Several Processor Queueing Disciplines for the M/M/1 Queue // IEEE Trans. Commun. — 1986. — V. 34. — N.6. — P. 538-546.
10. Kasera S., Pinheiro J., Loader C., Karaul M., Hari A., LaPorta T. Fast and Robust Signaling Overload Control // Proc. of IEEE ICNP. — November 2001. — P. 323 – 331.
10. Jensen K., Kristensen L. Coloured Petri Nets: modelling and validation of concurrent systems. — Berlin: Springer-Verlag, 2009. — 213 p.
11. Кузьминых Е.Д. Оценка параметров SIP-сети с использованием раскрашенных сетей Петри [Электронный ресурс] // Проблемы телекоммуникаций. — 2012. — № 1 (6). — С. 20 – 40. — Режим доступа к журн.: [http://pt.journal.kh.ua/2012/1/1/121\\_kuzminykh\\_sip.pdf](http://pt.journal.kh.ua/2012/1/1/121_kuzminykh_sip.pdf).