

Исследование причин аварийного завершения заданий на суперкомпьютере “Ломоносов-2”

Соболев Сергей Игоревич

*Лаборатория параллельных информационных технологий
НИВЦ МГУ имени М.В. Ломоносова*

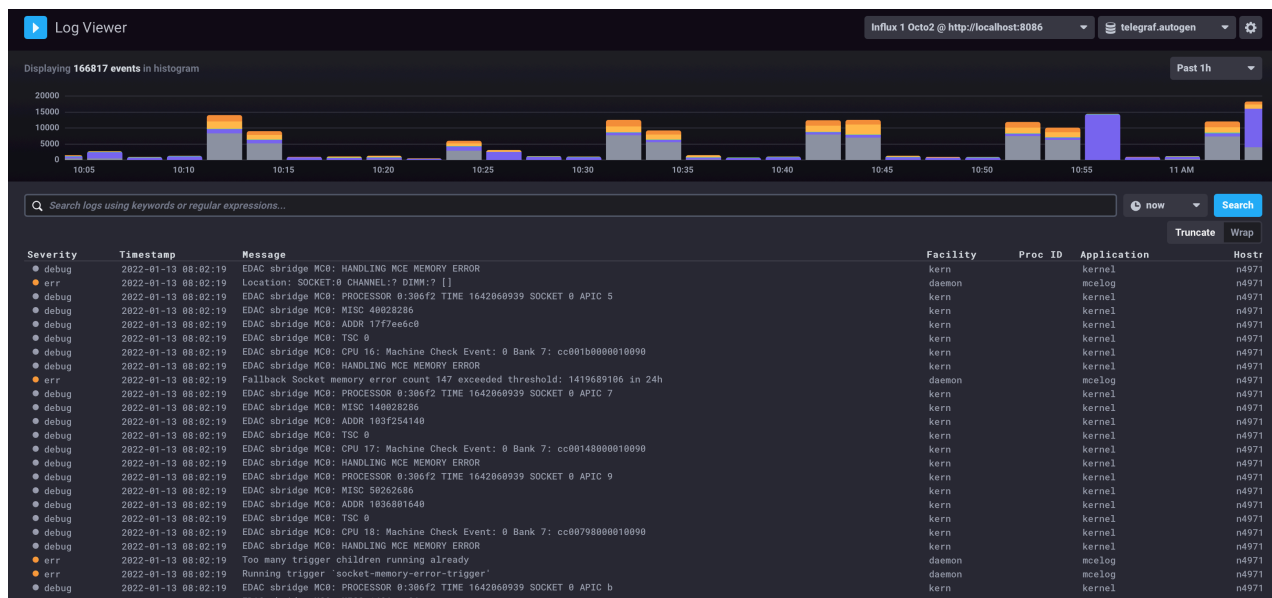
О проекте

- Грант РФФИ “Разработка методов сохранения, реконструкции и анализа структурно-функциональных свойств суперкомпьютерных систем”
- Задача проекта – сохранение множества данных о состоянии компонентов суперкомпьютера, позволяющих оценить корректность их работы и влияние на работу суперкомпьютера в целом
- Основной объект – суперкомпьютер “Ломоносов-2”



Системные журналы “Ломоносова-2”

- Раньше сохранялись в файловой системе (узлы -> сервер)
- Налажено сохранение в InfluxDB (rsyslog+Telegraf)
- ~200 000 записей в час:
 - ▶ 81% – вычислительные узлы
 - ▶ 19% – служебные серверы



Модуль Log Viewer системы визуализации Chronograf



Простейший анализ

hostname	syslog.count_message
n49712	354 K
n52603	290
n52413	287
n52601	286
n52602	285
n52604	284
n50408	116
n53121	37
n53117	37
n51024	36
n49026	36
n53723	33
n50515	32
n53122	31
n52414	30
n50727	29
n52626	28
n50510	28


Узлы – записи за сутки

hostname	syslog.count_message
oss07	54 K
service-09	2 K
mon02	972
oss08	667
oss11	459
oss01	426
access-02	334
service-02	192
service-01	96
oss12	56
oss03	55
mds01	45
oss06	36
oss09	33
oss10	30
oss02	30
access-01	30
oss05	26
mds02	26


Серверы – записи за сутки




Поиск причин аварийного завершения заданий



Число задач со статусом FAILED по месяцам 2021 г.



Соотношение числа задач FAILED и задач с другими статусами



Соотношение числа задач FAILED и задач COMPLETED

Метод анализа

- Рассматриваются задачи со статусами FAILED, COMPLETED и NODE_FAIL
- Исключается раздел test
- Из системных журналов узлов выделяются события в районе завершения задачи:
 - для длинных задач – 15 минут до завершения и 3 минуты после завершения
 - для коротких задач – 3 минуты до начала и 3 минуты после завершения
- Список событий анализируется визуально
- Частые/важные события подсчитываются отдельно

Веб-интерфейс: выбор даты

Date	Tasks Processed *	FAILED Tasks	NODE_FAIL'ed Tasks	COMPLETED Tasks	Download Data
2021-11-12	67	Total: 30 warning 9 err 4 crit 2		Total: 37 warning 12 err 5 crit 3	CSV
2021-11-13	55	Total: 18 warning 2 err 2 crit 2		Total: 37 warning 9 err 3 crit 1	CSV
2021-11-14	64	Total: 15 warning 1 err 2		Total: 49 warning 12 err 11 crit 5	CSV
2021-11-15	70	Total: 21 warning 2 err 1		Total: 49 warning 11 err 7	CSV
2021-11-16	162	Total: 48 warning 8 err 16 crit 2	Total: 5 warning 1	Total: 109 warning 19 err 15 crit 4 alert 1	CSV
2021-11-17	105	Total: 36 warning 8 err 2 crit 1		Total: 69 warning 9 err 10 crit 2	CSV
2021-11-18	93	Total: 41 warning 4 err 9 crit 3		Total: 52 warning 7 err 5 crit 1	CSV
2021-11-19	216	Total: 51 warning 11 err 2 crit 2		Total: 165 warning 19 err 100 crit 1 alert 1	CSV
2021-11-20	80	Total: 12 warning 5 err 1 crit 1		Total: 68 warning 17 err 24	CSV
2021-11-21	101	Total: 22 warning 6 err 6 crit 2		Total: 79 warning 37 err 22 crit 2	CSV
2021-11-22	142	Total: 29 warning 6 err 2 crit 2 alert 1	Total: 2 warning 2 err 1 alert 1	Total: 111 warning 36 err 21 crit 1	CSV
2021-11-23	267	Total: 44 warning 10 err 1 crit 3		Total: 223 warning 15 err 55 crit 8	CSV
2021-11-24	123	Total: 16 warning 6 err 4	Total: 17 warning 3 err 1	Total: 90 warning 16 err 3 crit 5	CSV



Фиксируемые события

- Аварийное завершение процессов пользовательского приложения (segfault)
- Аварийное завершение системных процессов orted, dimmon, xalt_submis
- Проблемы с общей файловой системой Lustre
- Превышение приложением лимита доступной оперативной памяти (out of memory)
- Аппаратные проблемы, определяемые демоном mcelog
- Превышение заданного температурного порога ядром или конструктивом центрального процессора
- Ошибки системной шины PCIe узла
- Проблемы с графическим ускорителем NVIDIA

Первые результаты

- Большинство перечисленных проблем не являются критическими
 - ▶ ... ни события с высоким уровнем важности (alert, critical)
 - ▶ ... ни даже “segmentation fault” (ORCA, NWSCHEM, VASP)
- Точную причину сбоя таким методом можно определить лишь для единичных заданий
- 100% ответа на вопрос нет :(

Интересное наблюдение

- 37 случаев аварийного завершения процессаorted (OpenMPI)
 - из них 29 - при работе GROMACS
 - но данные мы видим только в конце работы приложения...

Планы: расширение источников данных

- События из системных журналов части служебных серверов, необходимых для поддержания работы суперкомпьютера (oss и mds)
- События из буфера ядра операционной системы (dmesg)
- Счетчики сетевых ошибок

Спасибо за внимание!



26.09.2022

Исследование причин аварийного завершения заданий на суперкомпьютере “Ломоносов-2”

Слайд 13/13