

Table of Contents

IPFIX flows assembly performed by rcollector2	3
<i>Introduction</i>	3
<i>Installing and upgrading</i>	3
<i>Supplied configuration files</i>	3
<i>rcollector2 command line arguments</i>	4
<i>Configuration</i>	4
<i>Статистика работы программы</i>	8

IPFIX flows assembly performed by rcollector2

Introduction

The utility is designed to complement data with auxiliary streams such as clickstream, SIP from the session stream (netflow). By default, the received data is saved to files, but it can also be saved in the SORM-3 information system database.

Installing and upgrading

1. add the VAS Experts repository as it is shown in n.1 of [DPI installation](#) manual.
2. install rcollector2:

```
yum install -y rcollector2
```

3. edit configuration files in the `/etc/rcollector2/` directory (description follows)

! Attention! It is needed to modify some startup scripts when upgrading from previous version of [rcollector](#) to rcollector2.

Supplied configuration files

1. configuration examples:

```
/etc/rcollector2/rc2flowprocess - example of executable file designed  
to handle sessions (netflow)  
/etc/rcollector2/rc2urlprocess - example of executable file designed to  
handle HTTP sessions  
/etc/rcollector2/rc2sipprocess - example of executable file designed to  
handle SIP sessions  
/etc/rcollector2/rcollector_flow.properties - example of configuration  
file used in flow mode  
/etc/rcollector2/rcollector_url.properties - example of configuration  
file used in url mode  
/etc/rcollector2/rcollector_sip.properties - example of configuration  
file used in sip mode
```

2. executable file:

```
/bin/rcollector2
```

rcollector2 command line arguments

rcollector2 uses the following command line arguments:

```
usage: rcollector2 OPTIONS
```

OPTIONS:

- -h, -help display brief help.
- -fCONFIG, -config-file=CONFIG configuration file.
- -mMODE, -mode=MODE mode of operation. Available modes: flow, urlget, sipget
- -uidUNIQUEID, -uniqueid=UNIQUEID unique processing point number.
- -ifINFILE, -infile=INFILE input file.
- -ofOUTFILE, -outfile=OUTFILE output to a file.
- -asnASN, -localasn=ASN comma separated list of local autonomous systems
- -oufOUTFILTER, -outfilter=OUTFILTER output records according to the dpi protocol id to a file. Format to use: <outfile>,<protocol>,...<protocol>|[next filter]. Example: telnet.dump,22,23
- -tdUSEFILTER, -tordb=USEFILTER path to the file containing IP addresses of the TOR network. By default /var/data/tor/ip.db.gz is used.
- -sdbDIR, -sessiondb=DIR path to the session data directory. By default /var/db/rcollector is used.
- -outmailFILE, -outfilemail=FILE output file intended to store data about mail connections in sipget mode.
- -outftpFILE, -outfileftp=FILE output file intended to store data about ftp connections in sipget mode.
- -outimFILE, -outfileim=FILE output file intended to store data about im connections in sipget mode.
- -dhINTEGER, -depth=INTEGER search depth to find files containing session data.
- -sdrt, -session-db-read-thread use multiple threads when loading session data.

⚠ Attention! In some cases, for example, when OS cache being flushed frequently, this option can significantly increase the load time of session data. When using this option, 2 streams are created for reading data by default. **Examples of executable files presented above use this option.**

- -v, -version display the program version.

Configuration

The program parameters are specified in the .properties file. Configuration file named rcollector_MODE.properties in /etc/rcollector2/ directory is loaded by default, where MODE is the chosen operating mode. flow mode corresponds to **flow**; urlget mode corresponds to **url**; and the sipget mode - to **sip**.

⚠ When inserting data into the database, the following parameters **have to be** specified in the configuration file:

- db.host
- db.port
- db.user

- db.pass
- db.name
- db.telco_code
- db.bad_rows_dir
- db.validation_error_path

When data is inserted into the database, output files are not created. If there is no connection to the database, output files will be created according to the command line arguments. During operation, a file can be created in the directory as provided by **db.validation_error_path** option, which contains brief information about the data being discarded since it fails test that is used to detect the presence of the required fields. The file name matches the name of the input file with the **.err** extension.

cachedb parameter

This parameter allows you to configure the way of handling files containing session data.

- max_reader_threads - the maximum number of threads starting at the same time to read session data from files. An integer from 0 to 6.

⚠ In some cases, too many threads can slow down file downloads resulting in a general data processing slowdown.

stats parameter

This parameter sets the ability of program statistics to be sent to telegraf.

- stats.socket_path - path to the telegraf's datagram socket.
- stat.stag - tag to be specified in the rcollector_tag field when sending statistics to the telegraf.

db parameter

Данный параметр позволяет организовать вывод полученных данных в БД ИС СОРМ-3.

- db.host - адрес сервера postgresql
- db.port - порт
- db.user - имя пользователя
- db.pass - пароль пользователя
- db.name - имя БД
- db.bad_rows_dir - каталог для размещения файлов с данными в формате PGCOPY, которые были отвергнуты сервером postgresql
- db.validation_error_path - каталог для файлов с описанием причины для сброшенных входных данных
- db.copy_threads - количество потоков, которые вставляют данные в postgresql используя COPY в бинарном формате, по умолчанию 1
- db.commit_rows - количество строк в одном блоке, отправляемом на запись в бд при использовании COPY, по умолчанию 5000
- db.telco_code - идентификатор telco для записи в соответствующее поле бд
- db.lids_id - идентификатор типа источника, по умолчанию устанавливаются следующие

значения:

- для режима flow - 309
- для режима urlget - 310
- для режима sipget - 311
- db.ftp.ldds_ldst_id - идентификатор типа источника для режимов flow и sipget при вставке ftp данных, по умолчанию 307
- db.email.ldds_ldst_id - идентификатор типа источника для режима sipget при вставке email данных, по умолчанию 304
- db.im.ldds_ldst_id - идентификатор типа источника для режима sipget при вставке im данных, по умолчанию 306
- db.terminal.ldds_ldst_id - идентификатор типа источника для режима flow при вставке terminal данных, по умолчанию 308
- db.h323.ldds_ldst_id - идентификатор типа источника для режима flow при вставке h323 данных, по умолчанию 311
- db.ftp_proto - идентификаторы для определения данных как ftp и их занесение в БД, по умолчанию "20,21,69,115,152,349,574,662,989,990,3713,6620,6621,6622,65086". Для отключения необходимо указать none.
- db.ssh_proto - идентификаторы для определения данных как terminal и их занесение в БД, по умолчанию "22,23,3820,992,220". Для отключения необходимо указать none.
- db.h323_proto - идентификаторы для определения данных как h323 и их занесение в БД, по умолчанию "4569,49217". Для отключения необходимо указать none.
- db.require_subscriber_id - проверять наличие subscriber_id во входных данных, по умолчанию true. Если subscriber_id будет отсутствовать и параметр выставлен в true, то запись будет отброшена, о чем будет сообщено в информационном файле
- db.http.length.htrq_url - максимальное количество символов для поля htrq_url. По умолчанию 1024
- db.ftp.length.ftpc_server_name - максимальное количество символов для поля ftpc_server_name. По умолчанию 256
- db.ftp.length.ftpc_user_name - максимальное количество символов для поля ftpc_user_name. По умолчанию 64
- db.ftp.length.ftpc_user_password - максимальное количество символов для поля ftpc_user_password. По умолчанию 256
- db.email.length.emlc_sender - максимальное количество символов для поля emlc_sender. По умолчанию 256
- db.email.length.emlc_subject - максимальное количество символов для поля emlc_subject. По умолчанию 256
- db.email.length.emlc_reply_to - максимальное количество символов для поля emlc_reply_to. По умолчанию 256
- db.email.length.emcr_receiver - максимальное количество символов для поля emcr_receiver. По умолчанию 256
- db.email.length.mlcs_server - максимальное количество символов для поля mlcs_server. По умолчанию 256
- db.im.length.imcn_user_login - максимальное количество символов для поля imcn_user_login. По умолчанию 20
- db.im.length.imcn_user_password - максимальное количество символов для поля imcn_user_password. По умолчанию 16
- db.im.length.imcn_sender_screen_name - максимальное количество символов для поля imcn_sender_screen_name. По умолчанию 32
- db.im.length.imcn_sender_uin - максимальное количество символов для поля imcn_sender_uin. По умолчанию 256
- db.im.length.imcr_receiver_screen_name - максимальное количество символов для поля

imcr_receiver_screen_name. По умолчанию 32

- db.voip.length.vipc_conference_id - максимальное количество символов для поля vipc_conference_id. По умолчанию 64
- db.voip.length.vipc_originator_name - максимальное количество символов для поля vipc_originator_name. По умолчанию 64
- db.voip.length.vipc_calling_original_number - максимальное количество символов для поля vipc_calling_original_number. По умолчанию 128
- db.voip.length.vipc_called_original_number - максимальное количество символов для поля vipc_called_original_number. По умолчанию 128
- db.raw.length.rawf_sni_cn - максимальное количество символов для поля rawf_sni_cn. По умолчанию 128
- db.do_content_id - флаг, позволяющий сохранять dpi session_id в полях data_content_id бд. По умолчанию false
- db.raw.sni_protocol - если указан протокол dpi (например 443 для ssl), то при наличии данных host_cn они будут добавлены в поле rawf_sni_cn таблицы raw_flows. По умолчанию выключено

Параметр csv

- csv.url.extra_data - если значение данного флага true, то в выходном файле для url будут содержаться дополнительные поля: user_agent, cookie, referal. По умолчанию выключено
- csv.raw.sni_protocol - если указан протокол dpi (например 443 для ssl), то при наличии данных host_cn они будут добавлены в выходной файл. По умолчанию выключено

Параметр nat

Данные параметры позволяют дополнить flow данными о трансляциях адресов в случае их отсутствия во входном файле.

- nat.sessions_dir - каталог для поиска файлов трансляций NAT. Для обработки берутся последние по времени создания файлы. Маска поиска файлов url_*.dump, url_*.dump.gz.
- nat.files_cnt - количество файлов, которые будут использованы для обработки. По умолчанию 1 файл.

Файл трансляций должен быть в формате csv с символом разделения табуляция и иметь следующий формат полей:

№ поля	Описание
1	Время трансляции (timestamp)
2	Протокол
3	Тип события NAT
4	IP адрес источника
5	Порт источника
6	IP адрес источника после NAT
7	Порт источника после NAT

Параметр logging

Данный параметр отвечает за настройку логирования программы.

- logging.loggers.root.level - уровень логирования
- logging.loggers.root.channel - канал для вывода сообщений
- logging.channels.fileChannel.class - класс канала вывода
- logging.channels.fileChannel.path - путь к лог-файлу
- logging.channels.fileChannel.rotation - параметр ротации
- logging.channels.fileChannel.archive - параметр имени архивных файлов
- logging.channels.fileChannel.purgeCount - количество архивных файлов
- logging.channels.fileChannel.formatter.class - класс форматировщика
- logging.channels.fileChannel.formatter.pattern - шаблон для форматировщика
- logging.channels.fileChannel.formatter.times - время

! Более подробно ознакомиться с параметрами логирования можно по ссылке [Class FileChannel](#).

Статистика работы программы

Типы полей статистических данных о работе программы.

Режим sip

- read_lines - количество прочитанных строк входного файла
- sip_bye - количество записей SIP BYE
- sip_invite - количество записей SIP INVITE
- sip_miss - количество записей, не имеющих информации в кэше соединений
- count_ftp - количество записей ftp
- bad_ftp - количество ftp записей не сохраненных в файл
- out_ftp - количество ftp записей успешно сохраненных в файл
- dup_ftp - количество дублированных ftp записей
- count_mail - количество записей mail
- bad_mail - количество mail записей не сохраненных в файл
- out_mail - количество mail записей успешно сохраненных в файл
- dup_mail - количество дублированных mail записей
- count_im - количество записей im
- bad_im - количество im записей не сохраненных в файл
- out_im - количество im записей успешно сохраненных в файл
- bad_sip - количество sip записей не сохраненных в файл
- out_sip - количество sip записей успешно сохраненных в файл
- dup_sip - количество дублированных sip записей
- work_time - время работы программы в миллисекундах

Режим url

- read_lines - количество прочитанных строк входного файла
- sess_miss - количество записей для которых нет информации в данных о сессиях
- resp_miss - количество записей для которых нет информации в данных об ответах

- resp_skip - количество отброшенных записей (эти записи ответы от серверов)
- out_lines - количество сохраненных строк в выходном файле
- work_time - время работы программы в миллисекундах

Режим flow

- read_lines - количество прочитанных строк входного файла
- marked_as_tor - количество записей, промаркированных как TOR
- out_lines - количество сохраненных строк в выходном файле
- work_time - время работы программы в миллисекундах