Kwollect

Une solution de monitoring des métriques environnementales et de performance

Simon Delamare[1] Lucas Nussbaum[2]

[1]LIP / CNRS

[2]LORIA / Université de Lorraine

JCAD 2020

Introduction

- Monitoring des infrastructures IT
  - De plus en plus de capteurs, IoT
  - Problématique centrale de la consommation énergétique
  - Comprendre l'effet du logiciel sur l'environnement, et inversement
- Grid'5000/SILECS
  - Une plateforme pour la réalisation d'expérience à destination de la communauté système distribués, réseau, HPC, IA...
  - Mesures environnementales et de performances :

    Important pour la compréhension des résultats

    Parfois au centre de la réalisation de l'expérience
- Présentation de la solution Kwollect : Pourquoi, comment, retour d'expérience

  ... et introduire quelques technos intéressantes

Section 1

Contexte

Motivation

Encore un outil de monitoring ? Besoins :

- Focus sur l'environnemental :
  - Température ambiante (relevée par la BMC type iDRAC, le capteur sur le PDU)
  - Consommation électriques des composants (CPU, GPU sur la BMC) ou à la prise

    $\Rightarrow$ *SNMP, IPMI*
  - Pour Grid'5000, *Wattmetre* à 50 mesures par seconde
- Haute fréquence
- Conservation longue durée et sans perte
- Pour les utilisateurs (*pas uniquement pour les admin*)
  - Intégré avec le *job scheduler*
  - Customisable

Outils existants

Les historiques : *Munin, Ganglia, Cacti, Collectd...*

Les modernes : *Prometheus, Influx TICK, Graphite...*

- Parfois liés à une solution de stockage non adaptée (RRD, Prometheus TSDB)
- Parfois uniquement « push » ou uniquement « pull »
- Souvent orienté « métriques internes aux nœuds » $\Longrightarrow$ support SNMP, IPMI, etc. en retrait
- Rarement prévu pour la haute fréquence, pour s'intégrer avec un *job scheduler*

Kwollect

Nouvel outil de monitoring des données orientées time-series

Focus : utilisateurs des infrastructures, métriques environnementales, haute fréquence

- Réutilisation de briques logicielles « sur l'étagère »
  - Peu de code maison
  - PostgreSQL au cœur

Section 2

Choix de conception

Solution pour le stockage

S'affranchir des contraintes de RRD, HDF5 $\Longrightarrow$ Une base de donnée !

Solution pour le stockage

S'affranchir des contraintes de RRD, HDF5 $\Longrightarrow$ Une base de donnée !

/ !\ Besoin de haute performance lors de la manipulation de données *time-series*

- InfluxDB, OpenTSDB, ClickHouse ?

Solution pour le stockage

S'affranchir des contraintes de RRD, HDF5 $\Longrightarrow$ Une base de donnée !

/ !\ Besoin de haute performance lors de la manipulation de données *time-series*

- InfluxDB, OpenTSDB, ClickHouse ?

  $\Longrightarrow$ PostgreSQL ! (avec l'extension TimescaleDB)

TimescaleDB

Pourquoi PostgreSQL ?

- SQL : syntaxe, cohabitation avec des données classiques
- Écosystème : clients, outils, savoir-faire, communauté, robustesse

Mais... pas optimisé pour les *time-series*

- Beaucoup de données $\Longrightarrow$ Grosses tables
  $\Longrightarrow$ Pas en RAM (les indexes) $\Longrightarrow$ Faibles perfs
- Solution : partitionnement (= on découpe les tables en sous-tables).
  Mais doit être réalisé par l'admin de la DB

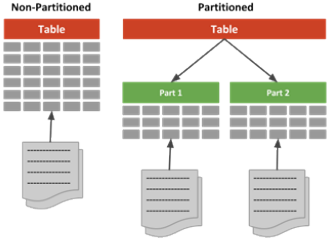

(source : oracle-base.com)

TimescaleDB

Pourquoi PostgreSQL ?

- SQL : syntaxe, cohabitation avec des données classiques
- Écosystème : clients, outils, savoir-faire, communauté, robustesse

Mais... pas optimisé pour les *time-series*

- Beaucoup de données $\Longrightarrow$ Grosses tables
  $\Longrightarrow$ Pas en RAM (les indexes) $\Longrightarrow$ Faibles perfs
- Solution : partitionnement (= on découpe les tables en sous-tables).
  Mais doit être réalisé par l'admin de la DB

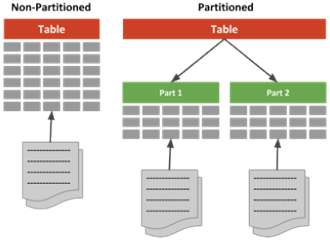

(source : oracle-base.com)

TimescaleDB

- Auto partitionnement sur des périodes de temps
- Les données insérées / accédées le sont généralement sur la partition la plus « récente »
- Cette partition est suffisamment petite pour tenir en RAM $\Longrightarrow$ Performances++
- Également : compression, agrégation de données, nouvelles opérations temporelles, ...

Stockage des métriques dans la BDD PostgreSQL

Une table “metrics” qui stocke tout :

- Format des métriques ($\approx$ Prometheus) :

```
  Column   |           Type           |
-----------+--------------------------+
timestamp  | timestamp with time zone |
device_id  | text                     |
metric_id  | text                     |
value      | double precision         |
labels     | jsonb                    |
```

Des constructions SQL (vues, fonctions) pour gérer toute la « logique » de Kwollect :

- Métriques liées à **plusieurs devices**
- **API** utilisateur
- Intégration au **job scheduler**
- Activation de métriques **à la demande**

API avec PostgREST

- Service qui permet d'interagir avec une base PostgreSQL via une API Rest
  - Permet de faire l'équivalent des requêtes SQL SELECT, INSERT, etc. avec HTTP
  - Contrôle d'accès utilise les utilisateur de la BDD
- Une API gratuite pour Kwollect !
  - requête :

```
$ curl 'http://kwollect.host:3000/rpc/get_metrics?devices=node-1,node-2&start_time=2020-01-06T13:35:00&end_time=2020-01-06T14:35:00'
```


```
{"timestamp":"2020-09-11T20:58:49.40357+02:00","device_id":"node-1","metric_id":"bmc_gpu_power_watt","value":42,"labels":{"gpu": "0"}},
{"timestamp":"2020-09-11T20:58:49.40357+02:00","device_id":"node-1","metric_id":"bmc_gpu_power_watt","value":44,"labels":{"gpu": "1"}},
{"timestamp":"2020-09-11T20:58:49.40357+02:00","device_id":"node-1","metric_id":"bmc_node_power_watt","value":648,"labels":{}},
{"timestamp":"2020-09-11T20:58:49.40357+02:00","device_id":"node-1","metric_id":"bmc_temp_ambient_celsius","value":21,"labels":{}},
{"timestamp":"2020-09-11T20:58:50.08682+02:00","device_id":"node-1","metric_id":"network_ifaceout_bytes_total","value":2654766193,"labels":{
{"timestamp":"2020-09-11T20:58:50.08682+02:00","device_id":"node-1","metric_id":"network_ifacein_bytes_total","value":3883940842,"labels":{"
```


  - insertion :

```
$ curl http://kwollect.host:3000/rpc/insert_metrics \
  -H "Authorization: Bearer $TOKEN" \
  -H 'content-type: application/json' \
  -d '{"timestamp": "2020-01-06 14:00:00", "device_id": "node-1", "metric_id": "example_metric", "value": 42}'
```

Autres fonctionalités

- Intégration avec le job scheduler
- Métriques à la demande

Autres fonctionalités

- Intégration avec le job scheduler
- Métriques à la demande

⇒ Facile, avec PostgreSQL :

```
CREATE OR REPLACE VIEW metrics_by_job AS
 SELECT metrics.*,
    scheduler_jobs.start_time,
    scheduler_jobs.stop_time,
    scheuler_jobs.job_id
   FROM scheduler_jobs, metrics
   WHERE metrics."timestamp" > scheduler_jobs.start_time
       AND (scheduler_jobs.stop_time IS NULL
            OR metrics."timestamp" < scheduler_jobs.stop_time)
       AND metrics.device_id = scheduler_jobs.node
```

(Jointure entre les dates de début/fin et les nœuds du job et la table metrics)

- API :

```
$ curl 'http://kwollect.host:3000/rpc/get_metrics?jobid=1234'
```

Autres fonctionalités

- Intégration avec le job scheduler

⇒ Facile, avec PostgreSQL :

```
CREATE OR REPLACE VIEW metrics_by_job AS
 SELECT metrics.*,
    scheduler_jobs.start_time,
    scheduler_jobs.stop_time,
    scheuler_jobs.job_id
   FROM scheduler_jobs, metrics
   WHERE metrics."timestamp" > scheduler_jobs.start_time
       AND (scheduler_jobs.stop_time IS NULL
            OR metrics."timestamp" < scheduler_jobs.stop_time)
       AND metrics.device_id = scheduler_jobs.node
```

(Jointure entre les dates de début/fin et les nœuds du job et la table metrics)

- API :

```
$ curl 'http://kwollect.host:3000/rpc/get_metrics?jobid=1234'
```

- Métriques à la demande

⇒ Des métriques désactivées par défaut
(ou de fréquence moins élevées)

Pour l'utilisateur :

- via l'API
- ou intégration avec le *job scheduler* :

```
# Active toutes les métriques relative aux GPUs pour ce job
$ oarsub -t monitor='.*gpu.*' -l nodes=1 ./script

# Active toutes les métriques pour ce job
$ oarsub -t monitor -l nodes=1 ./script
```

(Jointure entre le paramètre type monitor des jobs et une table promoted_metrics qui active les métriques optionelles)

Kwollector

- Kwollector : récupère des métriques et les stocke dans la BDD.
- Support de : SNMP, IPMI, exporteur Prometheus
- Python (~700 LoC), asyncio
  - Essentiellement I/O intensif

    $\Longrightarrow$ 1 seul cœur pour interroger chaque seconde 10^2 devices, avec 10^1 métriques chacun
- Accepte des fichiers de configuration du type :

```yaml
- name: idrac_power_watt
  device_id: node-1
  url: snmp://public@node-1-admin.domain.com/1.3.6.1.4.1.674.10892.5.4.600.30.1.6.1.3
  update_every: 5000
```

  (typiquement générés dynamiquement par un gestionnaire de configuration type *Ansible* ou *Puppet*)
- *kwollector-wattmetre*, pour lire et stocker les données des Wattmetre OmegaWatt

Visualisation

- Grafana : Facile avec PostgreSQL (bis)

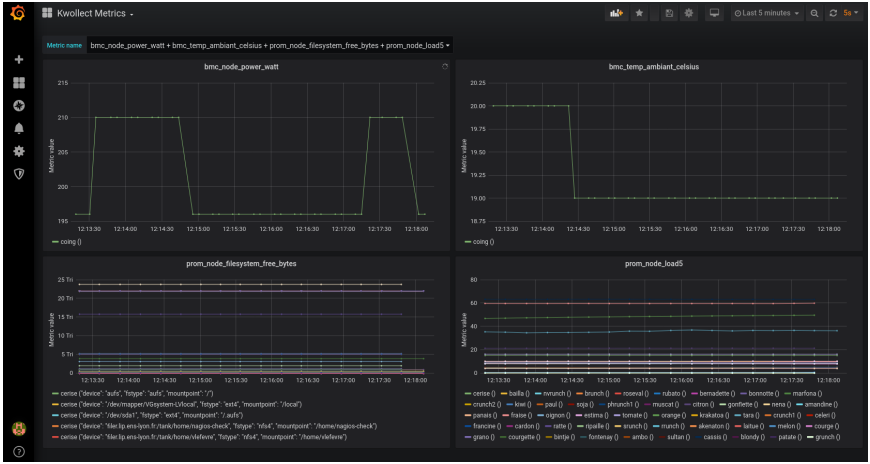

Visualisation

- Grafana : Facile avec PostgreSQL (bis)
- Dashboard (rudimentaire) spécifique Grid'5000
  - avec Jupytext, Jypyter Notebook, ipywidgets, Voila

Visualisation

- Grafana : Facile avec PostgreSQL (bis)
- Dashboard (rudimentaire) spécifique Grid'5000
  - avec Jupytext, Jypyter Notebook, ipywidgets, Voila

```
class KwollectDashboard:
    def __init__(self, kwollect_api_url, get_jobinfo_fn=None, get_devices_fn=None):

        self.kwollect_api_url = kwollect_api_url
        if get_jobinfo_fn:
            self.get_jobinfo_fn = get_jobinfo_fn
        if get_devices_fn:
            self.get_devices_fn = get_devices_fn
        else:
            self.get_devices_fn = self._default_get_devices_fn

        self.create_widgets()
        self.create_callbacks()

        self.data = pd.DataFrame()
        self.wip_count = 0

        threading.Thread(target=self._live_update_job).start()
        threading.Thread(target=self._wip_job).start()

        (...)
```

Visualisation

- Grafana : Facile ave
- Dashboard (rudimen
  - avec Jupytext, J

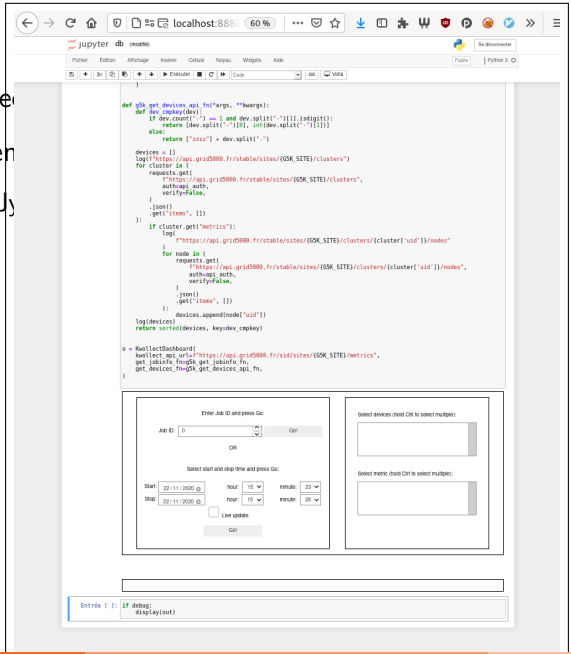

Visualisation

- Grafana : Facile avec
- Dashboard (rudimen
  - avec Jupytext, Jy

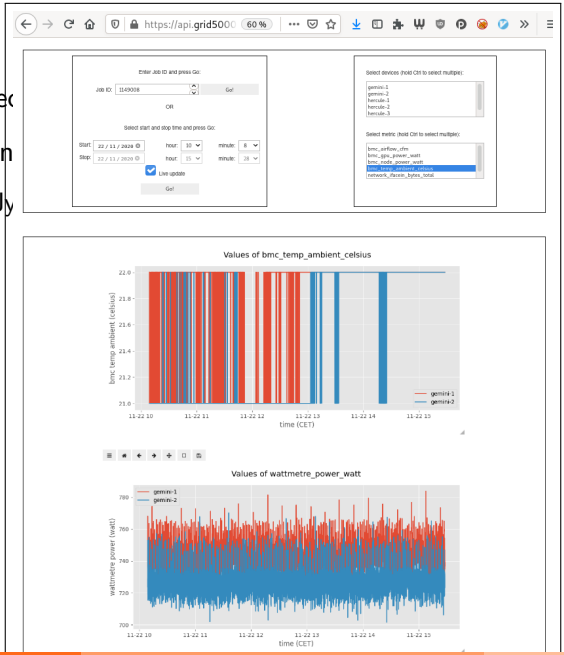

Installation

https://gitlab.inria.fr/grid5000/kwollect

1. Télécharger Kwollect

   ```
   $ pip install kwollect
   ```

   (dépot Debian également disponible)
2. Installer PostgreSQL avec TimescaleDB
3. Configurer la BDD pour Kwollect

   ```
   $ kwollect-setup-db
   ```
4. Installer PostgREST
5. Installer Grafana, mettre en place le datasource PostgreSQL, importer le dashboard Kwollect
6. Définir quelques métriques et démarrer le service *kwollector*

Section 3

Retour d'expérience dans Grid'5000

Déploiement dans Grid'5000

- Une instance (BDD + Kwollector + ...) déployée sur chacun de 8 sites Grid'5000
- Métriques par défaut :
  - La **consommation électrique** à la prise, chaque seconde (Wattmetre et/ou PDU)
  - Les principales **métriques des BMC** : température ambiante, consommation mesurée sur l'alim., ... (SNMP ou IPMI)
  - Le trafic sur les **équipements réseau**, chaque seconde (SNMP)
  - Les principales **métriques Prometheus** (*prometheus-node-exporter* et *dcgm-exporter* pour les GPU Nvidia)
  - Des **métriques arbitraires**, poussées par l'utilisateur depuis un nœud :

```
echo 'kwollect_custom{_metric_id="my_metric", _timestamp="1606057000"} 42' \
  >> /var/lib/prometheus/node-exporter/mymetric.prom
```

- À la demande : Mesures de consommation par les Wattmetre à 50Hz, toutes les métriques des BMC, toutes les métriques des exporteurs Prometheus, etc.

Quelques grandeurs

- 1700+ équipements différents monitorés
  - 800 à Nancy, le plus gros site G5K
- 10 000 métriques par seconde
  - 4000 à Nancy
  - x10-100 avec les métriques à la demande
- Performances

  (Déploiement sur des VMs « modestes » : 4 coeurs, 16Go RAM, 500Go HDD classique)

Job	#_valeurs	durée réponse
2 noeuds, depuis 48h	2.1M	35s
2 noeuds, depuis 2h	75K	2s
33 noeuds, depuis 2h	600K	1m13s
2 noeuds, depuis 2h + métriques à demande	1M	19s

Exemple d'application

Consommation énergétique d'un noeud, mesuré sur la BMC et avec un Wattmetre

- Reboot à $10:53:15$

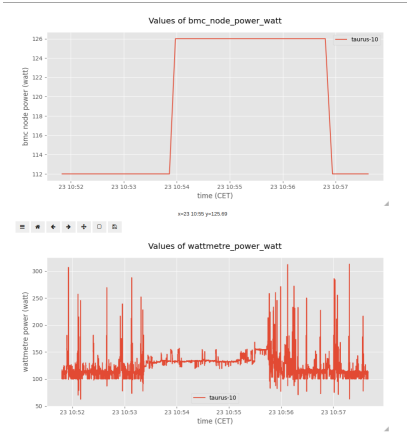

Exemple d'application

Consommation énergétique d'un noeud, mesuré sur la BMC et avec un Wattmetre

- Reboot à $10:53:15$
- Arrêt de l'exporter Prometheus à $10:58:36$

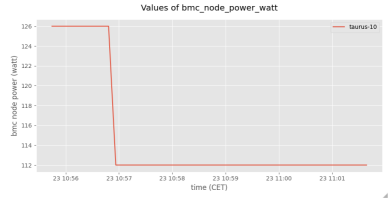

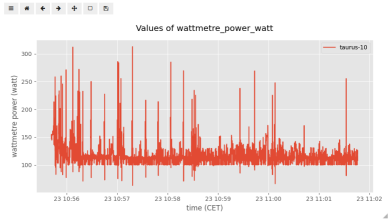

Section 4

Conclusion

Conclusion

- Kwollect : Monitoring orienté mesures environnementales et de performance, pour les infrastructures IT
  - Pour utilisateurs de Grid'5000 ou de centre de calcul $\Longrightarrow$ orienté *job*
  - Centré sur PostgreSQL, utilise aux maximum des composants logiciels existants

$\Longrightarrow$ Utile pour d'autres plateformes, dans d'autres contextes (IoT, ...)

- La suite :
  - D'avantage de métriques ! De plus en plus de capteurs...
  - Mieux identifier les limites, performances
  - Visualisation

Merci !

https://gitlab.inria.fr/grid5000/kwollect