

# Identification des checks les plus consommateurs à l'aide de la commande `shinken-scheduler-export-data`

## Sommaire

- Économiser des CPUs en identifiant les checks les plus consommateurs
- Création du tableau récapitulatif sur la consommation totale des temps CPU des royaumes respectifs
  - Consolidation des données: utilisation d'un tableau croisé dynamique
  - Création du tableau croisé dynamique
  - Sélection des commandes en tant que lignes de notre tableau
  - Obtenir la consommation CPU totale par check
    - Passer du nombre de lignes avec "cpu\_time" à une vraie somme des temps CPU
    - Rendre le titre de la colonne explicite
  - Obtenir la répartition de la consommation CPU par check
    - Passer la seconde colonne en somme de temps, comme la première
    - Passer du nombre total de temps CPU consommé à la répartition de la consommation CPU par check
    - Rendre le titre de la colonne explicite
  - Obtenir la répartition de la consommation CPU moyenne pour une exécution (en s)
    - Passer du nombre total de temps CPU consommé à la consommation CPU moyenne pour une exécution de check
    - Rendre le titre de la colonne explicite
- Analyse des résultats
  - Analyse du cas présent: quel check doit être optimisé en priorité pour économiser du CPU?
    - Quel check est le plus consommateur?
    - Exercice d'exemple: quel check optimiser afin de limiter la consommation CPU à un seul CPU?

## Économiser des CPUs en identifiant les checks les plus consommateurs

Lorsque l'on souhaite réduire la consommation CPU de sa supervision, optimiser ses commandes de vérification est une étape primordiale. En effet, les commandes de vérification sont la plupart du temps la première source de consommation CPU de la supervision. L'objectif de cette page est de permettre l'identification des commandes dont l'optimisation aura le plus d'influence sur la consommation CPU.

Pour cela, nous allons extraire des informations issues de la commande `shinken-scheduler-export-data` afin d'avoir:

- **le temps CPUs utilisés par chaque commande sur l'ensemble des royaumes**

Dans notre exemple. Nous avons un cas simplifié avec 3 checks:

- **check-host-alive:**
  - check par défaut pour la vérification des hôtes
- **dump-check-example-1:**
  - check d'exemple
- **dump-check-example-2:**
  - check d'exemple

Sur une installation réelle, il y aura plus de commandes, mais l'analyse restera la même vu que le principe sera de trouver les plus consommateurs.

On a besoin d'un dump de données avec en option une prévision de la charge sur une période, disons par exemple 1 heure. Il suffit alors de lancer la commande comme ceci:

```
shinken-scheduler-export-data --export-type=identify-most-consuming-checks --simulate-scheduling-for-X-seconds=3600
```

L'importation du fichier .csv généré est décrit dans la page suivante : [shinken-scheduler-export-data - export des données du Scheduler](#)



Avec ce lancement les noms ( *hôte, check, commandes et royaumes* ) seront présents dans l'export. Il est tout à fait possible de faire l'analyse sur un export en `--anonymous`, des hash des noms des commandes seront utilisés au lieu des noms finaux.

Le client pourra lancer un export avec les noms en parallèles afin de faire le lien avec les commandes une fois l'analyse effectuée.

# Création du tableau récapitulatif sur la consommation totale des temps CPU des royaumes respectifs

## Consolidation des données: utilisation d'un tableau croisé dynamique

On va devoir procéder à une consolidation des nombreuses données de checks obtenues afin d'obtenir un résultat exploitable.

- Pour cela on va utiliser la fonctionnalité d'Excel : **le tableau croisé dynamique**.
- Un tableau croisé dynamique dans un outil de analyse de données qui vous permet de créer une vue synthétique et facile à lire d'une grande quantité de données ( *ici nos exécutions de checks* ).

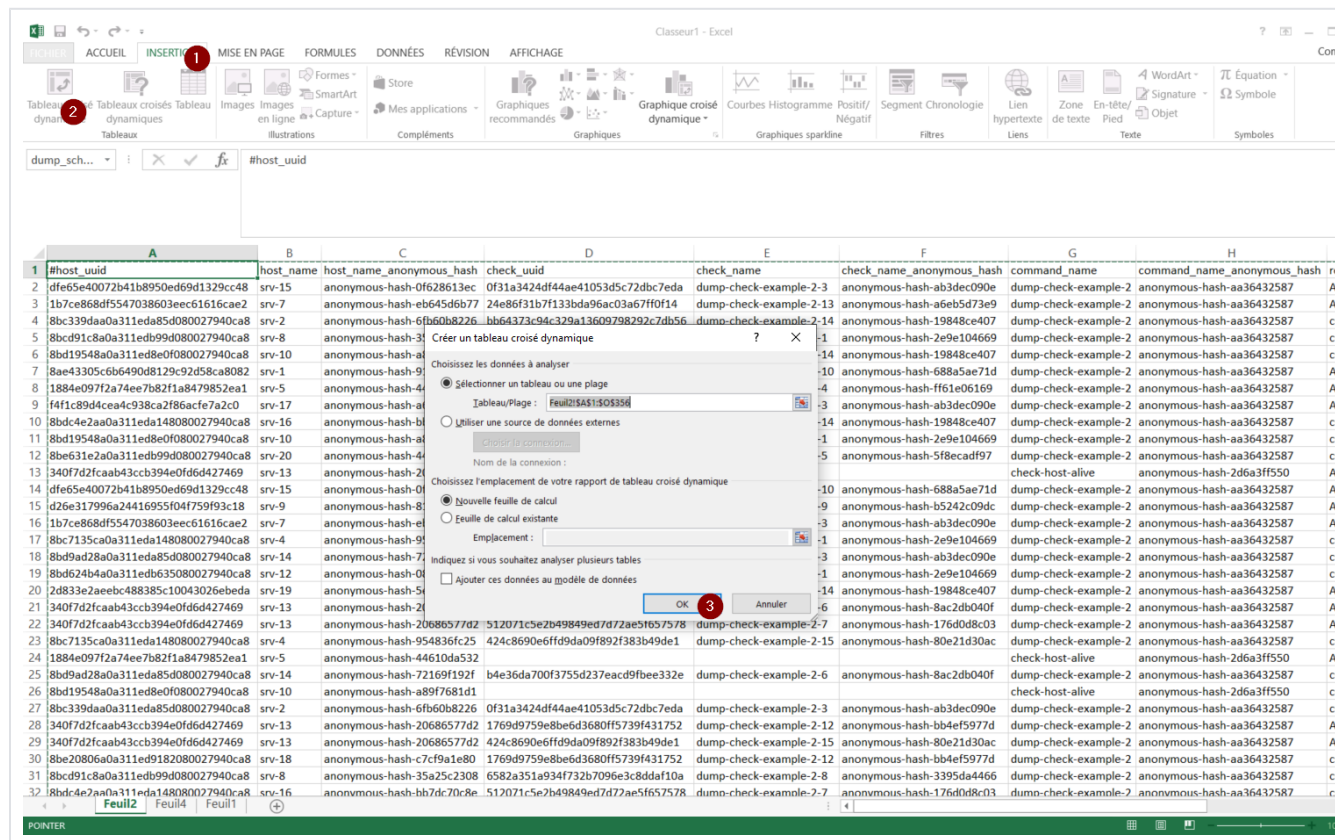
On y choisit les données à inclure, comment les organiser et comment les synthétiser, filtrer, classer et totaliser les données en fonction de nos besoins

Afin de pouvoir faire une analyse complète, notre objectif sera ici d'obtenir dans notre tableau:

- **la consommation CPU totale par check,**
- **la répartition de la consommation CPU par check par rapport au autres,**
- **et enfin la consommation CPU moyenne pour une exécution pour chaque check**

## Création du tableau croisé dynamique

La création du tableau récapitulatif passe par la création d'un **Tableau croisé dynamique**. Depuis votre Feuille d'importation des données, il faut cliquer sur **Insertion Tableau croisé dynamique**, et valider :



## Sélection des commandes en tant que lignes de notre tableau

Arrivé sur la nouvelle feuille, Excel demande quelles lignes sélectionner, dans le bloc de droite nommé "Champs de tableau croisé dynamique".

Dans notre cas, il faut faire glisser le champ **command\_name** ( ou bien **command\_name\_anonymous\_hash** si on a une version anonyme de l'export ) vers le bloc "Lignes" :

The screenshot shows the Microsoft Excel interface with the PivotTable Tools ribbon active. The PivotTable is set up with 'command\_name' as the row labels and 'cpu\_time' as the values. The PivotTable fields list on the right shows 'command\_name' selected under 'LIGNES' and 'cpu\_time' selected under 'VALEURS'. Red circles with numbers 1, 2, and 3 highlight the 'command\_name' field in the list, the 'LIGNES' section, and the 'Étiquettes de lignes' label respectively.

Ceci permet de définir nos lignes dans la colonne A avec l'ensemble de nos commandes.

## Obtenir la consommation CPU totale par check

A chaque commande, il faut lui assigner une ( *ou plusieurs* ) "Valeurs". Pour cela, on fait glisser le champ "cpu\_time" vers le bloc "Valeurs" afin d'avoir pour chaque royaume son champs **cpu\_time** associé :

The screenshot shows an Excel spreadsheet with a PivotTable. The PivotTable is located in cells A3:M7 and has the following data:

Étiquettes de lignes	Nombre de cpu_time
check-host-alive	20
dump-check-example-1	2
dump-check-example-2	315
<b>Total général</b>	<b>337</b>

The PivotTable Field List on the right is titled "Champs de tableau croisé d...". It shows the following fields:

- #host\_uid
- host\_name
- host\_name\_anonymous\_hash
- check\_uid
- check\_name
- check\_name\_anonymous\_hash
- command\_name**
- command\_name\_anonymous\_hash
- realm
- realm\_anonymous\_hash
- check\_interval
- retry\_interval
- cpu\_time**

The "cpu\_time" field is currently set to "Valeurs" (Values) in the "VALEURS" section. A blue arrow points from the "cpu\_time" field in the list to the "Valeurs" section, and a red circle highlights the "Valeurs" dropdown. Another red circle highlights the "Nombre de cpu\_time" cell in the PivotTable.

A noter que, par défaut, Excel prend le nombre d'occurrences du champ **cpu\_time** comme "**Valeur**", ce qui n'est pas ce qui est souhaité ( "**Nombre de cpu\_time**" ).

### Passer du nombre de lignes avec "cpu\_time" à une vraie somme des temps CPU

Une modification des "**Paramètres des champs de valeurs**" est nécessaire sur "**Nombre de cpu\_time**" qu'il faut changer en Somme pour donner au final "**Somme de cpu\_time**" :

Options du tableau croisé dynamique : Champ actif : command\_name, Paramètres de champs, Descendre dans la hiérarchie, Monter dans la hiérarchie, Grouper la sélection, Dissocier, Grouper le champ, Insérer un segment, Insérer une chronologie, Filtrer les connexions, Actualiser, Changer la source de données, Actions, Outils OLAP, Graphique croisé, Suggestions de tableaux croisés dynamiques, Liste des champs, Boutons +/-, En-têtes de champ.

Étiquettes de lignes	Somme de cpu_time
check-host-alive	0,309
dump-check-example-1	10,04
dump-check-example-2	69,698
<b>Total général</b>	<b>80,047</b>

Paramètres des champs de valeurs  
 Nom de la source : cpu\_time  
 Nom personnalisé : Somme de cpu\_time  
 Synthèse des valeurs par : Afficher les valeurs  
 Résumer le champ de valeur par : Choisissez le type de calcul que vous souhaitez utiliser pour résumer données du champ sélectionné  
 Somme (2)  
 Nombre, Moyenne, Max, Min, Produit  
 Format de nombre, OK (3), Annuler

Champs de tableau croisé d...  
 Choisissez les champs à inclure dans le rapport :  
 #host\_uid  
 host\_name  
 host\_name\_anonymous\_hash  
 check\_uid  
 check\_name  
 check\_name\_anonymous\_hash  
 command\_name  
 command\_name\_anonymous\_hash  
 realm  
 realm\_anonymous\_hash  
 check\_interval  
 retry\_interval  
 cpu\_time  
 Faites glisser les champs dans les zones voulues ci-dessous:  
 FILTRES :  
 COLONNES :  
 LIGNES : command\_name  
 VALEURS : Somme de cpu\_time

On obtient alors la somme en temps ( secondes ) consommée par chaque commande.

### Rendre le titre de la colonne explicite

Le titre de la colonne n'étant pas des plus lisible pour notre analyse, on le change en double cliquant dessus, et le renomme alors "Consommation CPU totale par check (en s)" :

Options du tableau croisé dynamique : Champ actif : Somme de cpu\_time, Paramètres de champs, Descendre dans la hiérarchie, Monter dans la hiérarchie, Grouper la sélection, Dissocier, Grouper le champ, Insérer un segment, Insérer une chronologie, Filtrer les connexions, Actualiser, Changer la source de données, Effacer, Sélectionner, Déplacer le tableau croisé dynamique, Champs, éléments et jeux, Outils OLAP, Graphique croisé, Suggestions de tableaux croisés dynamiques, Liste des champs, Boutons +/-, En-têtes de champ.

Étiquettes de lignes	Consommation CPU totale par check (en s)
check-host-alive	8,296
dump-check-example-1	1302,262
dump-check-example-2	4135,312
<b>Total général</b>	<b>5445,87</b>

Paramètres des champs de valeurs  
 Nom de la source : cpu\_time  
 Nom personnalisé : Consommation CPU totale par check (en s) (2)  
 Synthèse des valeurs par : Afficher les valeurs  
 Résumer le champ de valeur par : Choisissez le type de calcul que vous souhaitez utiliser pour résumer données du champ sélectionné  
 Somme (3)  
 Nombre, Moyenne, Max, Min, Produit  
 Format de nombre, OK (3), Annuler

Champs de tableau croisé d...  
 Choisissez les champs à inclure dans le rapport :  
 #host\_uid  
 host\_name  
 host\_name\_anonymous\_hash  
 check\_uid  
 check\_name  
 check\_name\_anonymous\_hash  
 command\_name  
 command\_name\_anonymous\_hash  
 realm  
 realm\_anonymous\_hash  
 check\_interval  
 retry\_interval  
 cpu\_time  
 scheduled\_epoch  
 scheduled\_state  
 is\_simulated  
 Faites glisser les champs dans les zones voulues ci-dessous:  
 FILTRES :  
 COLONNES :  
 LIGNES : command\_name  
 VALEURS : Somme de cpu\_time

Notre première valeur est obtenue: **la consommation CPU totale par check**.

## Obtenir la répartition de la consommation CPU par check

S'il est possible de trier par rapport au temps absolu consommé par un check et donc avoir les plus consommateurs, il peut être également très intéressant d'avoir leur pourcentage par rapport à la consommation totale.

Ceci en facilitera grandement la lecture, et il sera ainsi possible de savoir de quel ordre de grandeur une optimisation sera bénéfique pour la consommation.

Il faut rajouter une seconde fois le champ "cpu\_time" dans les valeurs, ce qui rajoute une nouvelle colonne :

The screenshot shows an Excel PivotTable with the following data:

Étiquettes de lignes	Somme de cpu_time	Nombre de cpu_time
check-host-alive	0,309	20
dump-check-example-1	10,04	2
dump-check-example-2	69,698	315
<b>Total général</b>	<b>80,047</b>	<b>337</b>

The PivotTable Fields task pane on the right shows the following configuration:

- Champs de tableau croisé d... Choisir les champs à inclure dans le rapport:
- command\_name (checked)
- cpu\_time (checked)
- command\_name\_anonymous\_hash (unchecked)
- realm (unchecked)
- realm\_anonymous\_hash (unchecked)
- check\_interval (unchecked)
- retry\_interval (unchecked)

The 'VALEURS' area contains:

- Somme de cpu\_time
- Nombre de cpu\_time

## Passer la seconde colonne en somme de temps, comme la première

Ensuite il faut passer, comme pour la colonne précédente, d'un calcul en **Nombre** à un calcul en "Somme de cpu\_time" :

The screenshot displays an Excel PivotTable with the following data:

Étiquettes de lignes	Somme de cpu_time	Nombre de cpu_time
check-host-alive	0,309	20
dump-check-example-1	10,04	2
dump-check-example-2	69,698	315
<b>Total général</b>	<b>80,047</b>	<b>337</b>

The 'Paramètres des champs de valeurs' dialog box is open, showing the source 'cpu\_time' and a custom name 'Somme de cpu\_time2'. Under 'Résumer le champ de valeur par', the 'Afficher les valeurs' tab is active, and 'Somme' is selected from the list. The right-hand pane shows the field list with 'command\_name' in the 'LIGNES' area and 'cpu\_time' in the 'VALEURS' area.

## Passer du nombre total de temps CPU consommé à la répartition de la consommation CPU par check

Le changement dans cette étape consiste à changer l'affichage dans le menu "Afficher les valeurs" en choisissant "% du total général" pour obtenir la Répartition de la consommation CPU par check :

Classeur1 - Excel

OUTILS DE TABLEAU CROISÉ DYNAMIQUE

FICHIER ACCUEIL INSERTION MISE EN PAGE FORMULES DONNÉES RÉVISION AFFICHAGE ANALYSE CRÉATION

Options du tableau croisé dynamique

Champ actif: Somme de cpu\_time2

Descendre dans la hiérarchie Monter dans la hiérarchie

Paramètres de champs

Champs, éléments et jeux

Graphique croisé dynamique

Suggestions de tableaux croisés dynamiques

Liste des champs

Boutons +/-

En-têtes de champ

C3

Somme de cpu\_time2

	A	B	C	D	E	F	G	H	I	J	K	L
1												
2												
3	Étiquettes de lignes	Somme de cpu_time	Somme de cpu_time2									
4	check-host-alive	0,309	0,39%									
5	dump-check-example-1	10,04	12,54%									
6	dump-check-example-2	69,698	87,07%									
7	Total général	80,047	100,00%									
8												
9												
10												
11												
12												
13												
14												
15												
16												
17												
18												
19												
20												
21												
22												
23												
24												
25												
26												
27												
28												
29												
30												
31												
32												
33												

Paramètres des champs de valeurs

Nom de la source : cpu\_time

Nom personnalisé : Somme de cpu\_time2

Synthèse des valeurs par : Afficher les valeurs

Afficher les valeurs

% du total général

Champ de base : host\_name, host\_name\_anonymous\_hash, check\_uid, check\_name, check\_name\_anonymous\_hash

Élément de base :

Format de nombre

OK Annuler

Champs de tableau croisé d...

Choisissez les champs à inclure dans le rapport :

- #host\_uid
- host\_name
- host\_name\_anonymous\_hash
- check\_uid
- check\_name
- check\_name\_anonymous\_hash
- command\_name
- command\_name\_anonymous\_hash
- realm
- realm\_anonymous\_hash
- check\_interval
- retry\_interval
- cpu\_time

Faites glisser les champs dans les zones voulues ci-dessous:

FILTRES

COLONNES

VALEURS

LIGNES

command\_name

VALEURS

Somme de cpu\_time

Somme de cpu\_time2

Différer la mise à jour de la disp... METTRE À JOU

## Rendre le titre de la colonne explicite

Comme précédemment, on change le titre par défaut en double cliquant dessus. On le renomme alors "Répartition de la consommation CPU par check" :

Tableau croisé dynamique :

Étiquettes de lignes	Consommation CPU totale par check (en s)	Somme de cpu_time
check-host-alive	8,236	0,15%
dump-check-example--1	1302,262	23,91%
dump-check-example--2	4135,312	75,93%
<b>Total général</b>	<b>5445,87</b>	<b>100,00%</b>

Paramètres des champs de valeurs :

- Nom de la source : cpu\_time
- Nom personnalisé : Répartition de la consommation CPU par check
- Synthèse des valeurs par : Afficher les valeurs
- Résumer le champ de valeur par : Moyenne

Ces deux premières colonnes nous permettent d'identifier rapidement les checks les plus consommateurs.

On a alors obtenu la seconde donnée intéressante: **la répartition de la consommation CPU par check par rapport au autres.**

La suivante, et dernière, va nous permettre d'affiner l'analyse en calculant le temps moyen de CPU par exécution de check.

### Obtenir la répartition de la consommation CPU moyenne pour une exécution (en s)

La dernière statistique qui va nous intéresser pour prioriser nos actions d'optimisation va être d'obtenir la consommation CPU moyenne pour une exécution de check.

Pour cela, il faut rajouter une dernière fois le champ "cpu\_time" dans les valeurs, exactement comme pour les deux précédentes colonnes :

Étiquettes de lignes	Consommation CPU totale par check (en s)	Répartition de la consommation CPU par check	Nombre de cpu_time
check-host-alive	8,296	0,15%	1220
dump-check-example-1	1302,262	23,91%	260
dump-check-example-2	4135,312	75,93%	19520
<b>Total général</b>	<b>5445,87</b>	<b>100,00%</b>	<b>21000</b>

## Passer du nombre total de temps CPU consommé à la consommation CPU moyenne pour une exécution de check

Pour cette colonne, il faut changer le calcul de **Nombre** à un calcul en **"Moyenne de cpu\_time"** :

## Rendre le titre de la colonne explicite

Comme pour les deux colonnes précédentes, on change le titre de la colonne en change en double cliquant dessus. On le renomme alors "**Consommation CPU moyenne pour une exécution (en s)**" :

The screenshot shows an Excel spreadsheet with a PivotTable. The PivotTable has three columns: 'Consommation CPU totale par check (en s)', 'Répartition de la consommation CPU par check', and 'Moyenne de cpu\_time'. A dialog box titled 'Paramètres des champs de valeurs' is open, showing the 'Moyenne' (Average) option selected for the 'Moyenne de cpu\_time' field. The dialog box also shows the source name 'cpu\_time' and the personalized name 'Consommation CPU moyenne pour une exécution (en s)'. The 'OK' button is highlighted with a red circle.

	Consommation CPU totale par check (en s)	Répartition de la consommation CPU par check	Moyenne de cpu_time
check-host-alive	8,296	0,15%	0,0066
dump-check-example-1	1302,262	23,91%	5,0087
dump-check-example-2	4135,312	75,93%	0,21185
<b>Total général</b>	<b>5445,87</b>	<b>100,00%</b>	<b>0,259327143</b>

On obtient alors la dernière de nos trois données d'analyse: **la consommation CPU moyenne pour une exécution pour chaque check.**

## Analyse des résultats

Le tableau final obtenu, on peut analyser afin d'identifier de la manière la plus efficace possible le ou les checks les plus consommateurs.

Il est ainsi possible de se concentrer sur l'optimisation des checks qui auront un véritable impact sur les performances de la plateforme.

Étiquettes de lignes	Consommation CPU totale par check (en s)	Répartition de la consommation CPU par check	Consommation CPU moyenne pour une exécution (en s)
check-host-alive	8,296	0,15%	0,0068
dump-check-example-1	1302,262	23,91%	5,0087
dump-check-example-2	4135,312	75,93%	0,21185
<b>Total général</b>	<b>5445,87</b>	<b>100,00%</b>	<b>0,259327143</b>

## Analyse du cas présenté: quel check doit être optimisé en priorité pour économiser du CPU?

### Quel check est le plus consommateur?

Faisons l'exercice avec notre exemple. Nous avons **3** checks ( leur temps d'exécution est extrait de la colonne "Consommation CPU moyenne pour une exécution (en s)" ) :

- **check-host-alive:**
  - check par défaut pour la vérification des hôtes, seulement **0.006s** ( 6ms ) de temps moyen d'exécution, très peu couteux car il lance principalement un simple ping
- **dump-check-example-1:**
  - check d'exemple qui consomme en moyenne **5s** de temps CPU par exécution, ce qui est **très élevé** pour un check
- **dump-check-example-2:**
  - second check d'exemple qui consomme **0.2s** ( 200ms ) de temps CPU par exécution, ce qui est **légèrement élevé** pour un check

En ne regardant que ces valeurs, et en ne se basant que sur notre première impression, on serait tenté de se dire que le check le plus consommateur est **dump-check-example-1** avec ses **5s** de temps d'exécution par check. C'est en effet un temps anormal pour un check de supervision.

Mais cette première impression est trompeuse. En effet, si on regarde mieux notre tableau on s'aperçoit que ce check ne représente qu'environ **25%** du temps CPU total consommé ( **23,91%**, colonne "Répartition de la consommation CPU par check" ). Il n'est ainsi pas le plus consommateur /prioritaire.

Le check le plus consommateur est en fait **dump-check-example-2**, avec ses plus de **75%** de temps CPU total consommé ( **75,93%** ). Il est donc intéressant de voir en priorité les gains que l'on peut faire sur ce dernier, surtout qu'avec ses **200ms** de temps d'exécution, il n'est pas léger, et donc des optimisations doivent être possibles.

Et seulement dans un second temps voir l'optimisation de **dump-check-example-1** qui avec ses **5s** de temps d'exécution doit largement avoir de quoi être optimisé.

### Exercice d'exemple: quel check optimiser afin de limiter la consommation CPU à un seul CPU?

On utilise nos données pour faire un exercice pratique et concret: on ne souhaite utiliser qu'un seul CPU pour l'ensemble de nos checks.

Dans notre cas, on avait pris un temps de simulation de **3600s=1h** pour notre extraction d'ordonnancement. La somme totale des temps d'exécutions de toutes les checks est de **5445s**, soit moins de **2h** de temps de calcul ( **7200s** ).

L'ensemble des checks consomment ainsi actuellement moins de 2 CPUs (  $5445/3600=1.5$  CPUs ).

Si l'on souhaite ne consommer qu'un seul CPU sur cette plateforme, il faut ainsi gagner  $5445-3600=1845s$  de temps de traitement. Deux possibilités s'offrent alors:

- si on se limite à optimiser le check **dump-check-example-1**:
  - l'objectif de se limiter à 1CPU est **impossible**, car il ne consomme au total que **1300s** ( *1302* ), ce qui est moins que le gain nécessaire de **1845s**,
- si on se concentre sur le check **dump-check-example-2**:
  - il est le plus consommateur, ceci demande une optimisation de  $1845/4135=45\%$  de son temps d'exécution, et ainsi passer sous les **110ms** de temps d'exécution moyen, ce qui est raisonnablement atteignable comme optimisation.



Dans notre cas, il faut donc un gain de **45%** sur le check **dump-check-example-2** afin de limiter la consommation CPU de la plateforme à 1 seul CPU.