

Orchestration Euclid

P. Casenove

Chef de projet Segment Sol Euclid

Mission Euclid

Comprendre l'origine de l'accélération de l'expansion de l'Univers

- Propriétés et nature de la Matière Noire et de l'Energie Sombre
- A l'aide de 2 condes cosmologies:
 - Géométrie de l'Univers (Weak Lensing)
 - Historique de sa formation (Cluster de galaxies)

Mission nominale de 6 ans

- Relevé WIDE de 14500 deg²: environ 29k observations
- 3 champs DEEP de 50 deg² + Calibrations : 16k observations
- 20 observations par jour
- Télescope:
 - Miroir M1 de 1.2m de diamètre
 - Imageur dans le visible de 600M pixels : VIS
 - Spectrophotomètre infrarouge de 70M pixels : NISP
- Données de télescope Sol requises pour compléter les données
- Trois Data Releases durant la mission:
 - Tir + 2 ans: 2500 deg², Tir + 4 ans: 7500 deg²
 - 14 mois après la fin de la mission: relevé complet, DR3
- Date du tir en cours de consolidation suite à bascule Ariane 6.2



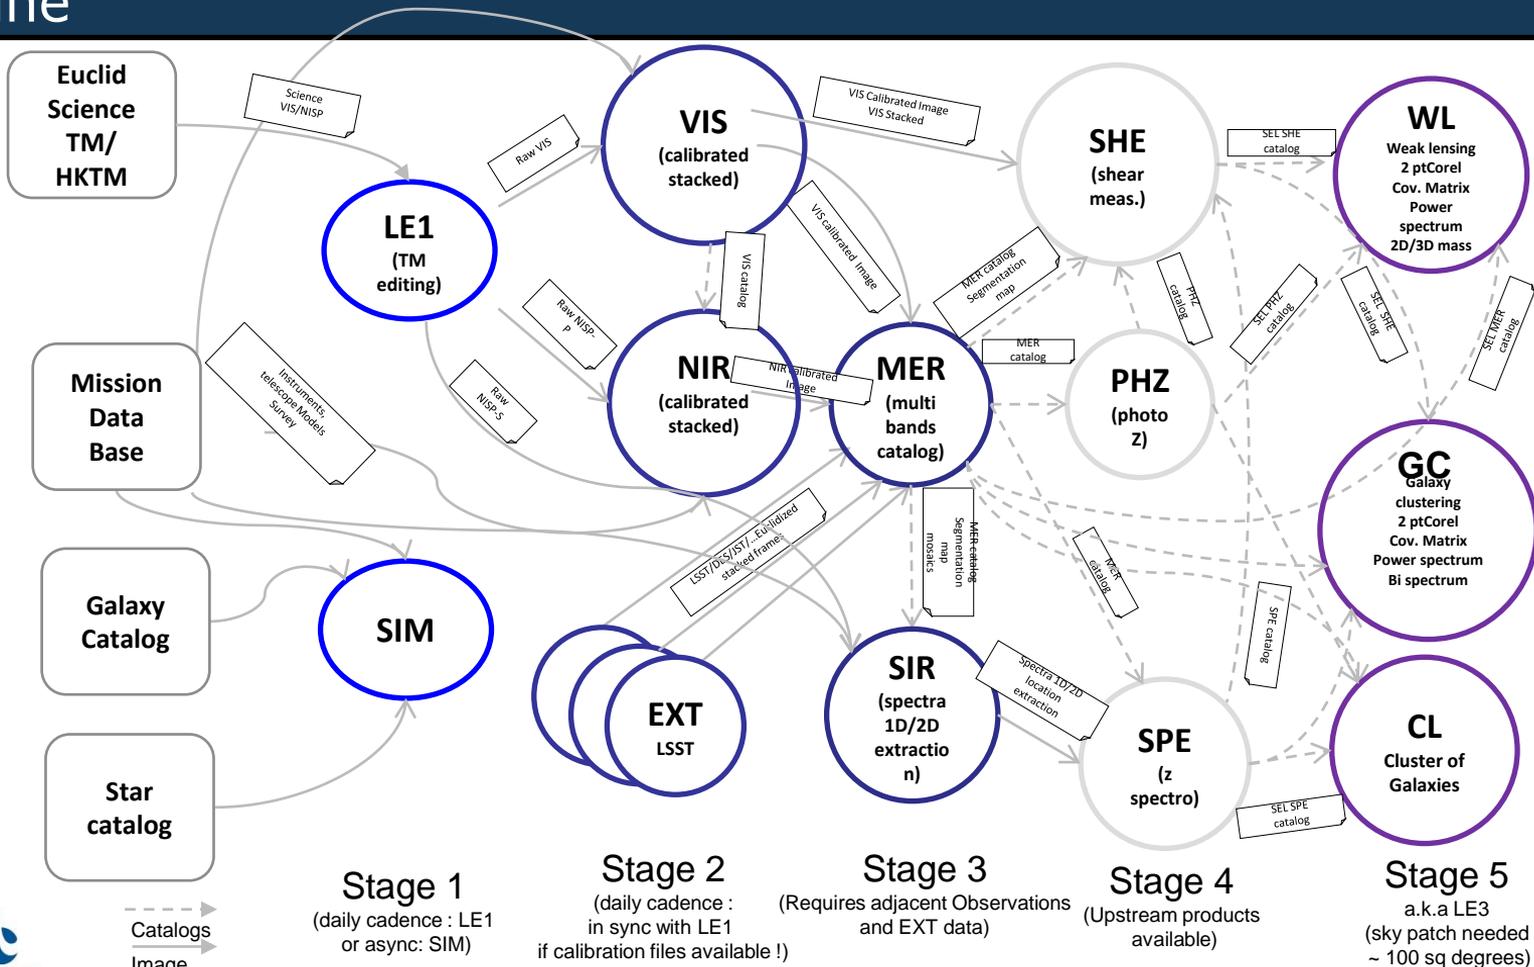
Architecture du segment sol

- ❑ Concepts clés du Scientific Ground Segment (SGS)
 - Composé de datacenters (SDC) répartis dans 9 pays différents
 - Les mêmes pipelines doivent tourner dans tous les SDCs
 - Le processing et les données sont distribuées: chaque SDC est aussi un nœud de stockage des données produites
 - Déplacer le code au plus près des données: minimiser les transferts de fichiers en entrée des pipelines

- ❑ Un système d'archive centralisé (Euclid Archive System)
 - Un repository central des metadata (DPS) : indexe, inventorie et localise toutes les données produites
 - Un Distributed Storage Service (DSS) dans chaque SDC qui enregistre les sorties et permet le transfert de fichiers inter-SDC
 - Un modèle de données centralisé (Euclid Common Data Model) définissant les interfaces entre les pipelines

- ❑ Infrastructure Abstraction layer (IAL): en charge de garantir l'exécution des pipelines sur tous les SDCs
 - Quelle que soit l'architecture SDC sous-jacente

Pipeline



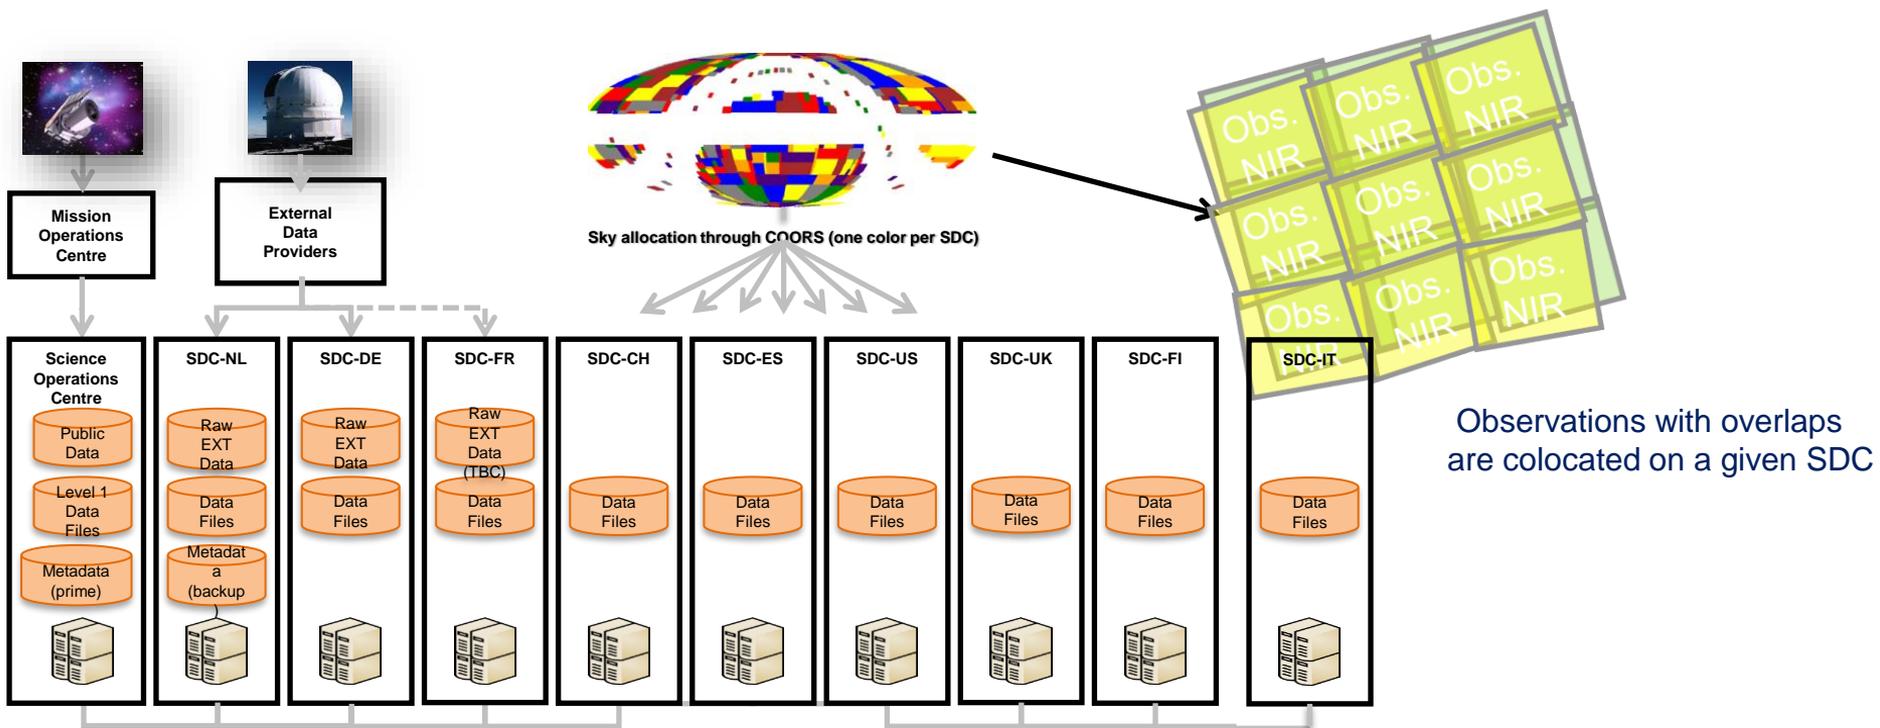
Distribution des données

- ❑ Première orchestration au niveau du SGS complet
- ❑ Distribution faite à priori, basée sur le relevé de la mission
 - Chaque observation/tuile est assignée à un SDC primaire + Secondaire
 - Certains SDCs sont en charge des ingestions des données des télescopes Sols
 - Informations de distributions stockées dans l'EAS

- ❑ Règles de distribution
 - Nombre d'observations/tuiles assignées est fonction de la taille (# cores, stockage) du SDC
 - Linéarisation de la distribution dans le temps : éviter de longues périodes sans réception de données
 - Minimiser la copie des données entre les SDC au niveau de la PF MER

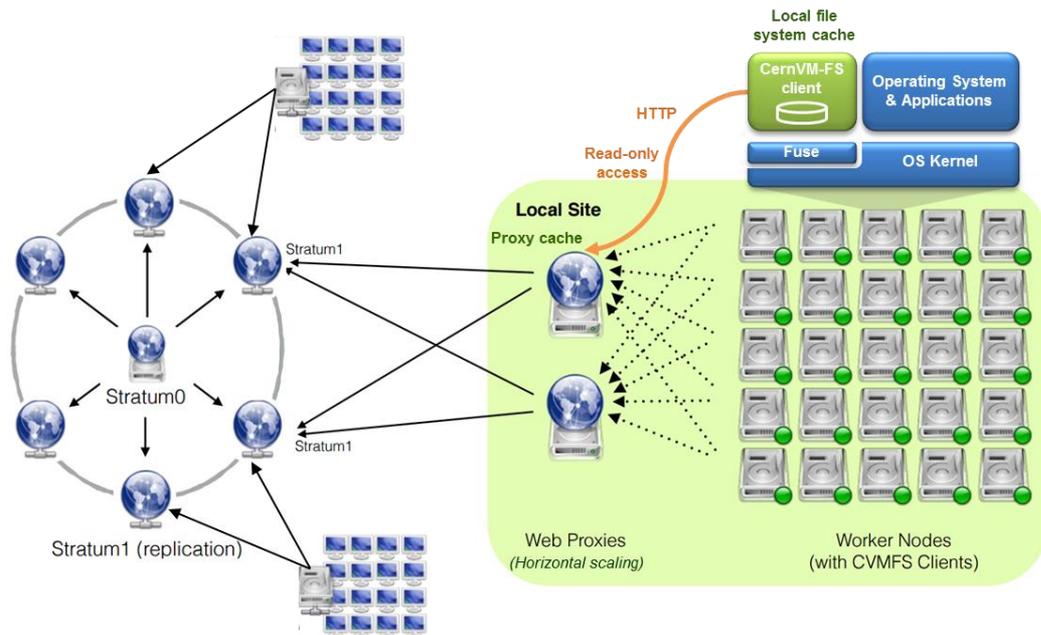
- ❑ Et des contraintes opérationnelles...
 - Mise à jour / changement du survey du télescope
 - Maintenances planifiées des SDCs
 - Objectif de faire la distribution sur les 2/3 mois à venir

Distribution des données



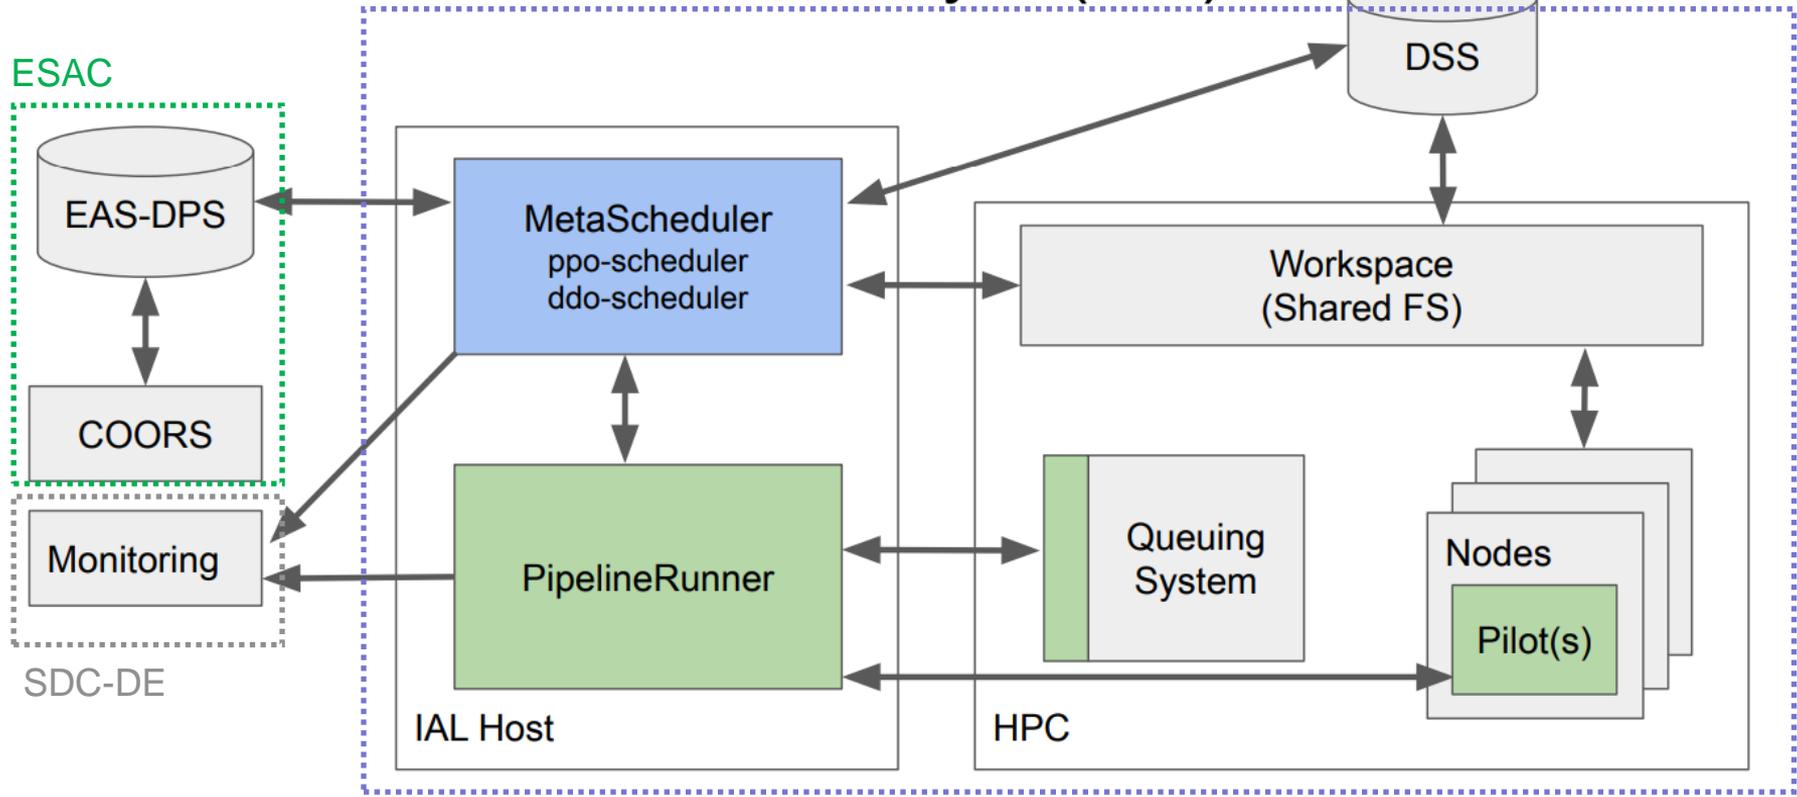
Distribution du code

- ❑ Plateforme CI/CD (basée sur Jenkins) pour builder les codes
- ❑ Distribution du code dans tous les SDCs : CernVMFS
 - Déploiement des codes sur le « Stratum 0 »
 - Publication en moins de 10 mins sur tous les SDCs vis des stratum 1 puis des proxies Squid dans chaque SDC



Infrastructure Abstraction Layer (IAL)

Par SDC



- ❑ Développement de l'IAL pris en charge par l'université FHNW à Zurich
- ❑ Historique
 - Premier prototype en 2015 (Challenge 2), première version stable en 2017 , pour le Challenge 3
 - Développement continu, avec plusieurs refactoring et livraisons majeures :
 - Release 1.5 – Juillet 2018: multi process, ajout d'une couche de persistance, refonte de la configuration
 - Release 1.7 – Octobre 2019: robustesse et correction de bugs
 - Release 2.2 – Janvier 2021 : réécriture complète, introduction d'un bus à message interne
 - Release 2.4 – janvier 2022 : passage en python 3.10
 - Release 3.0 - été 2022 : ressources dynamiques, TMPDIR, GPU, définition de pipeline macro
- ❑ Fonctionnalités principales du Pipeline Runner
 - Traduire le Pipeline Script en un Data Flow Graph
 - Soumission des jobs unitaires permettant l'exécution du flow graph
 - Interfaçage avec les DRM des SDC (Slurm, SGE, PBS, HTCondor) ou run en local
 - Supervision des jobs et notification du MetaScheduler
 - Profiling des jobs
 - Prend en charge l'orchestration d'un pipeline donné, pas celle au niveau SGS

Description des pipelines 1/2

- ❑ Définition d'une interface pour permettre aux développeurs de définir:
 - ❑ Leurs tâches unitaires et les ressources associées: Package Definition
 - ❑ Leur pipeline complet, appelant les différentes tâches: Pipeline Script
 - ❑ Implémentation en python

- ❑ Package Definition: décrit un ensemble d'Executable

- Nom de la commande
- Paramètres d'appel d'entrée et de sortie
- Ressources max utilisées: CPU/RAM/VMS/Walltime
- Nouveautés 2022:
 - Ressources dynamiques: en fonction des sorties de la tâche précédente, passage des ressources ajustées via un fichier JSON
 - TMPDIR: utilisation d'espaces disques temporaires pour soulager les FS partagés
 - GPU: accès à un ou plusieurs GPU sur les SDC le permettant

```
ialtest_correct_dark=Executable(command="ialtest_correct_dark",
                                inputs=[Input("image"), Input("master_dark"), Input("control_params")],
                                outputs=[Output("corrected_image"),
                                           Output("darkmap", lineage=['image', 'master_dark'])],
                                resources=ComputingResources(cores=2, ram=2.0, walltime=4.0, vms=20.0)
                                )
```

Description des pipelines 2/2

- Pipeline Script: décrit le pipeline complet
 - Implémentation sous la forme de module Python
 - Appel des tâches définies dans le Package Definition
 - Décorateur Python pour définir les tâches à paralléliser (@parallel)
 - PR déduit le nombre de jobs des sorties de la tâche
 - Décorateur Python pour définir la fonction principale du pipeline (@pipeline)
 - A venir : chainage de plusieurs pipelines – Macro Pipeline

```
from euclidwf.framework.workflow_dsl import pipeline, parallel
from ialtest_package import ialtest_correct_dark, ialtest_correct_flat,\
    ialtest_split_images, ialtest_combine_images

@parallel(iterable='image')
def correct(image, master_dark, master_flat, control_params):

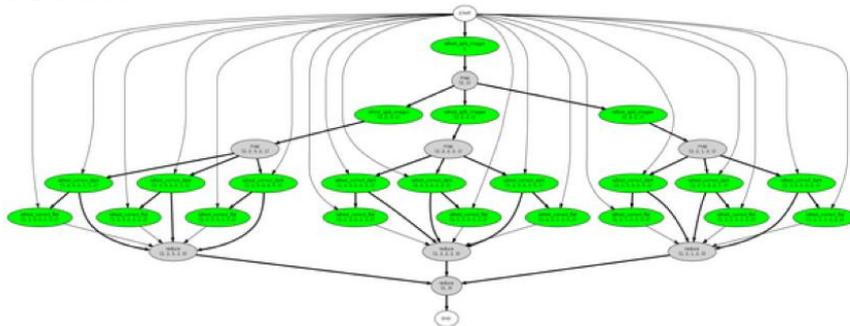
    image_dark_corr, dark_corr_quality = ialtest_correct_dark(
        image=image,
        master_dark=master_dark,
        control_params=control_params)

    image_flat_corr, flat_corr_quality = ialtest_correct_flat(
        image=image_dark_corr,
        master_flat=master_flat,
        control_params=control_params)

    return image_flat_corr, dark_corr_quality, flat_corr_quality

@pipeline(outputs=('corrected_images', 'quality'))
def parallel_split(images, master_dark, master_flat, control_params):
    images splitted = ialtest_split_images(images=images)
    images_corr_output = correct(image=images splitted, master_dark=master_dark,
        master_flat=master_flat, control_params=control_params)
    images_corr, quality = ialtest_combine_images(inputlist=images_corr_output)
    return images_corr, quality
```

- Construction du Data Flow



Concept des "Pilot Job"

❑ Origine des Pilots Jobs

- Mise en œuvre au CERN, pour l'expérimentation LHC
- Adresse la problématique des temps d'attente pour les petits jobs dans les centre de données partagés

❑ Concept des Pilots Jobs

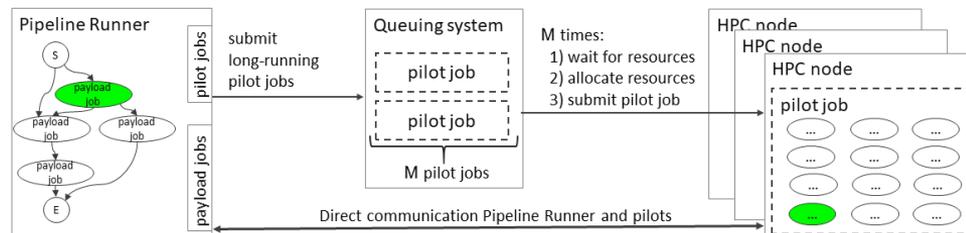
- Le Pipeline Runner réserve et soumet au DRM local un « gros » job
- Communication entre le PR et les pilots via le bus à message ZeroMQ
- Une fois ce job alloué, les PR soumet les jobs au sein de ce Pilot:
 - En fonction des ressources déclarées pour cet Executable
 - Dans la limite des ressources définies pour un pilot donné

```
# mc huge template pipelinerunner.pilots.mc_huge.maxInstances=0 to disable  
pipelinerunner.pilots.heavy.CPUcores=22  
pipelinerunner.pilots.heavy.rssInMB=66000  
pipelinerunner.pilots.heavy.walltimeInMin=10080  
pipelinerunner.pilots.heavy.maxInstances=100  
pipelinerunner.pilots.heavy.maxQueued=50
```

❑ Conséquences

- Le DRM Local ne gère que les jobs Pilot: en cas de dépassement de ressources, le Pilot est tué et tous les jobs associés
- Le Pipeline Runner doit gérer
 - Un pool de Pilot et les re-soumettre régulièrement
 - Une priorisation des jobs à soumettre au sein des Pilots

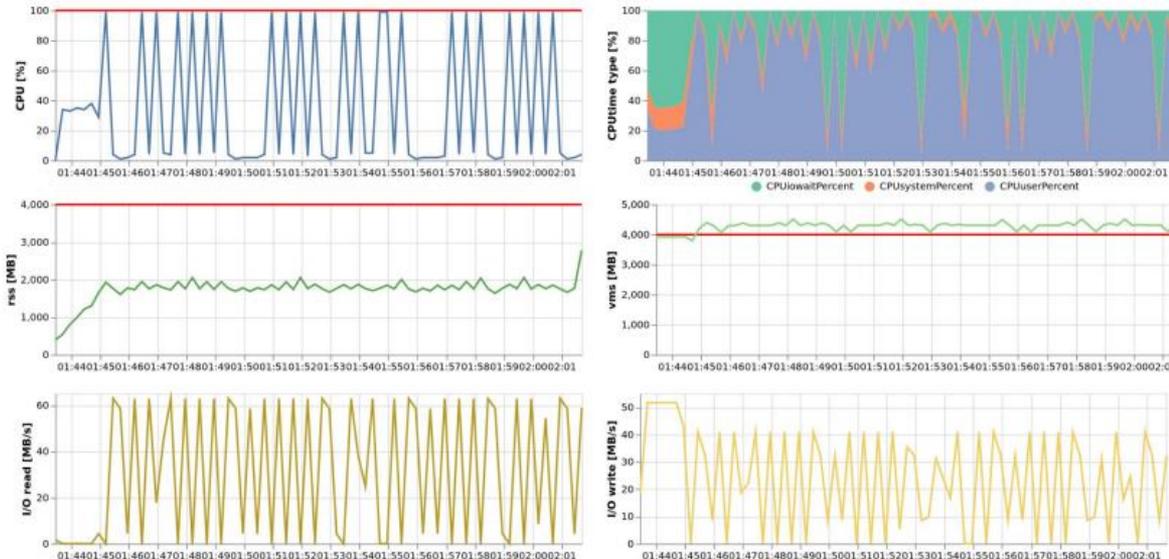
Pilot job assignment model



Planification des jobs

- ❑ Le Pipeline Runner doit gérer le scheduling des Pilots et des Payload Jobs
- ❑ Pilot Jobs
 - Ressources configurées par l'administrateur système en fonction de son DRM, de sa ferme et de ses règles
 - Pilots soumis uniquement à l'arrivée de Payload Jobs
 - Soumission de Pilots plus gros que les ressources demandées par les Payload Jobs
 - Configuration possible du nombre max de pilots soumis par passe, du nombre de pilots par file d'attente du DRM, nombre max de pilots d'un même type, ...
- ❑ Payload Jobs
 - Calcul d'un score, à partir d'une fitness function
 - Ratio de consommation CPU/RAM/VMS/Walltime par rapport au total de chaque Pilot
 - Temps d'attente dans la queue
 - Poids de chaque ratio configurable par l'administrateur système
 - Ajout de règle en provenance de l'exécution :
 - administrateur Système peut manuellement augmenter la priorité
 - Un retry d'un payload job en erreur a une priorité haute par défaut
 - La moitié des Pilots tourne en mode starving: priorité aux plus gros jobs, le reste étant complété par les plus petits jobs
 - Dans le futur: gestion de priorité au niveau système (via les PPO), à propager aux Payload Jobs

- ❑ Récupération de nombreuses métriques Systèmes durant l'exécution des Jobs
 - Implémenté en python via psutil
 - Suivi CPU/RAM/VMS/Ios, avec report des ressources demandées
- ❑ Investigation de problèmes de performances
- ❑ Données brutes centralisées dans une base ELK SGS



IHM PipelineRunner

Le Pipeline Runner implémente aussi une interface graphique d'administration

- Suivi des pipeline en cours d'exécution, ajustement des priorités
- Affichage des données de profiling

Pipeline Run Server

Pilots Jobs Runs Configuration

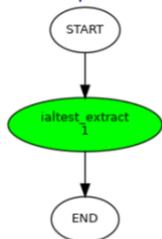
Details for Run with ID=RUN_20201006_075122_332571_Pf_SingleStep: COMPLETED ##### Tuesday, 06. October 2020 10:02AM

Run Id:	RUN_20201006_075122_332571_Pf_SingleStep
Processing Status:	COMPLETED
Submission Date:	10-06 07:51:23
End Date:	10-06 07:51:53
Duration:	30.094747
Workdir:	iaitestPF_SingleStep
Pipeline Source File:	PF_SingleStep.py
Message:	None

Tasks

TICK	PILOT	STATUS	DURATION	OUTDIR	LOGDIR	MESSAGE
1	Pilot_id_generic_heavy.20201006_074759_449877	COMPLETED	24.160559	iaitest_extract	logdir/iaitest_extract	None

Dataflow Graph



Inputs

portname	path
image	inputs/image_input1.xml
catalog_spec	inputs/catalog_spec_input2.xml

Outputs

portname	path
catalog	iaitest_extract/pectra.xml
quality	iaitest_extract/quality.xml

Lineage

Output Port	Output Product	Used Inputs
catalog	iaitest_extract/pectra.xml	[inputs/catalog_spec_input2.xml, inputs/image_input1.xml]
quality	iaitest_extract/quality.xml	[inputs/catalog_spec_input2.xml, inputs/image_input1.xml]

Pipeline Run Server

Pilots Jobs Runs Configuration

Details for Job with ID=RUN_20201006_145757_784911_Pf_ParallelSplitConsumeResources_2_2_3_2: COMPLETED ##### Tuesday, 06. October 2020 03:09PM

Payload/Job Id: RUN_20201006_145757_784911_Pf_ParallelSplitConsumeResources_2_2_3_2

Processing Status: COMPLETED

Created: 2020-10-06 15:00:53.699621

Ended: 2020-10-06 15:03:14.021789

Pilot: Pilot_id_generic_heavy.20201006_145000_220347

Retry: 0 attempts

Waittime in Min (used / requested): 2 min used of 60 requested

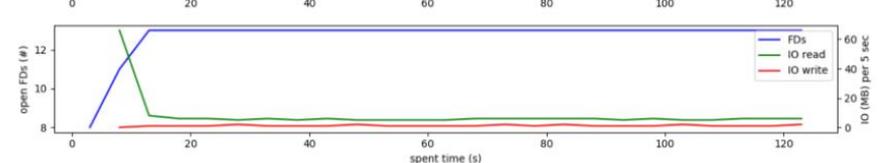
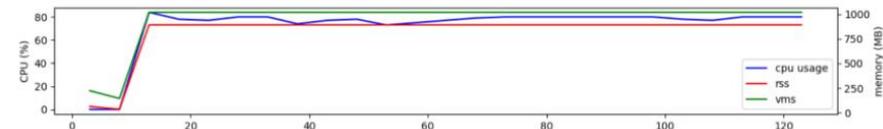
%CPU (avg. / cores requested): 72 % used of 1 requested cores

MB RSS (max / requested): 894 used of requested 1000

MB VMS (max): 1022

MB accumulated IO (read / write): 248 / 29

```
cd /home/simon/ucld-ia/workspace/iaitest/Pf_ParallelSplitConsumeResources && source /cvmfs/ucld-dev.in2p3.fr/CentOS7/EDEN-2.1/bin/activate && time E-Run -b x86_64-conda_cos6-gcc73-c2g ST_iaitestPipelines_iaitest_correct_flat --consume_cpu --consume_memory --consume_io --run_for_secs=120 --workdir=/home/simon/ucld-ia/workspace/iaitest/Pf_ParallelSplitConsumeResources --logdir=logdir/correct.iterations.3.iaitest_correct_flat_consume --image-correct.iterations.3.iaitest_correct_dark_consume/corrected_image.xml --master_flat=inputs/master_flat_input3.xml --control_params=inputs/control_params_input4.xml --corrected_image=correct.iterations.3.iaitest_correct_flat_consume/corrected_image.xml --deadmap=correct.iterations.3.iaitest_correct_flat_consume/deadmap.xml
```



Etude Moteur de workflow générique

- ❑ Etudier la possibilité de remplacer le PipelineRunner par des COTS
 - Assurer la maintenance long terme
 - Etude faite courant 2021 avec la société CS

- ❑ Périmètre de l'étude
 - Utilisation du langage CWL (Common WorkFlow Language) en remplacement du système PipScript/PkgDef
 - Moteur de workflow: comparaison avec TOIL, Airflow natif et Airflow-CWL
 - Utilisation du « Dummy Pipeline »:
 - ensemble de pipelines de test utilisant toutes les fonctionnalités du Pipeline Runner
 - utilisé pour valider le bon fonctionnement de chaque DataCenter après une montée de version du segment sol

Description

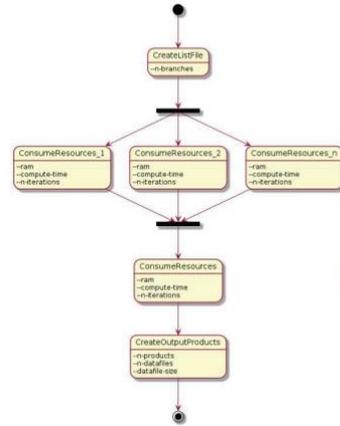
- CWL permet de décrire des commandes et de les lier ensemble
- CWL est une spécification à implémenter dans les moteurs

Implémentation

- Utilisation des formats YAML ou JSON
- Une description CWL par étape

Conclusions

- CWL permet de couvrir les différentes notions implémentées dans les Pipelines Scripts et Package Definition



```
#!/usr/bin/env cwl-runner
cwlVersion: v1.1
class: Workflow

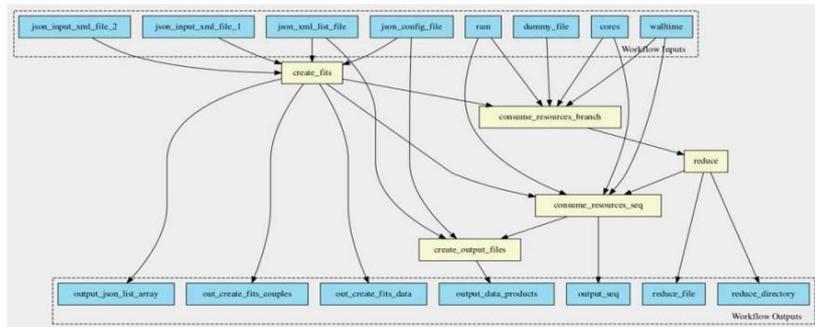
requirements:
  - $runtimeFeatureRequirement: {}
  - $softwareFeatureRequirement: {}

inputs:
  json_config_file: File
  json_sel_list_file: File
  ...
  cores: int
  ram: int
  walltime: File

steps:
  create_fits:
    run: PyCreateFitsCouple.cwl
    in:
      json_config_file: json_config_file
      json_sel_list_file: json_sel_list_file
      json_input_sel_file_1: json_input_sel_file_1
      json_input_sel_file_2: json_input_sel_file_2
    out: [output_json_list_array, out_create_fits_couples, out_create_fits_data, output_json_list_2]

  create_output_files:
    run: PyCreateOutput.cwl
    in:
      json_config_file: json_config_file
      json_sel_list_file: json_sel_list_file
      report_input_files: consume_resources_out/output_sel_out
    [output_data_products]

outputs:
  output_json_list_array:
    type: File[]
    outputSource: create_fits/output_json_list_array
  out_create_fits_couples:
    type: Directory
    outputSource: create_fits/out_create_fits_couples
  ...
  reduce_directory:
    type: Directory[]
    outputSource: reduce/reduce_directory
  output_data_products:
    type: File
```



- ❑ TOIL
 - Compatibilité complète avec CWL
 - Exécution du Dummy Pipeline sans problème majeur
 - Ajout d'étape pour garantir l'unicité des noms des fichiers/dossiers de sortie des tâches parallèles
 - Pas de triggering intégré dans TOIL → lancement à faire par un outil externe

- ❑ Airflow-CWL
 - Extension à Airflow pour supporter CWL, en retard sur les dernières version officielles Airflow
 - Pas compatible du Dummy Pipeline, sorti de l'étude

- ❑ Airflow natif
 - Migration des langages Pipeline Script / Package Definition dans le langage Airflow
 - Compatible du Dummy Pipeline

- ❑ TOIL
 - 500 workflows en parallèle sur une VM 8cpu/32G (en utilisant Mesos)
 - Migration vers CWL
 - Interfaçage de l'IAL et de TOIL à mettre en place pour maintenir l'IHM et déclencher les workflows

- ❑ Airflow natif
 - 1000 tâches de workflow lancées, mais max 16 en parallèle (problème pour Euclid)
 - Migration vers le langage Airflow
 - Interfaçage avec les DRM à développer

	TOIL-CWL	CWL-AIRFLOW	AIRFLOW
LAST RELEASE	2022-01-10	2021-09-21	2021-12-2021
HMI	NO	YES	YES
DATA CIRCULATION	YES	YES	NO
PARALLEL EXECUTION	YES	NO	NO/YES
DAG	YES	YES	YES
WORKFLOW CATALOG	NO	YES	YES
TASK CATALOG	NO	YES/NO	YES
WORKFLOW TRIGGERING	EXEC BIN	TIME/API	TIME/API
WORKER TYPE	Mesos/PBS/Slurm/HTCond or/LSF/ TORQUE/GridEngine/KUBE RNETES	CELERY/DASK/KUBERNETE S/LOCAL/SEQUENTIAL	CELERY/DASK/KUBERN ETES/ LOCAL/SEQUENTIAL
DYNAMIC RESOURCES	NO	NO	YES
PLUGINS	NO	YES	YES
SCHEDULING	NO	YES	YES
LINEAGE	NO	NO	YES Can be bind https://openlineage.io/