



UNIUNEA EUROPEANĂ



Instrumente Structurale  
2014-2020

**Centru Cloud si Big Data pentru Participarea la Cloud-ul European pentru Stiinta Deschisa**

## **Realizarea de servicii si aplicatii informatice pentru analiza datelor de monitorizare a sistemului laser de la ELI-NP**

Alecsandru Chiroșca

DFCTI@IFIN-HH

Proiect cofinatat din Fondul European de Dezvoltare Regionala prin Programul Operational Competitivitate 2014-2020  
Pentru informatii detaliate despre celelalte programe cofinantate de Uniunea Europeana, va invitam sa vizitati [www.fonduri-ue.ro](http://www.fonduri-ue.ro)

*"Continutul acestui material nu reprezinta in mod obligatoriu pozitia oficiala a Uniunii Europene sau a Guvernului Romaniei"*



## INTRODUCERE

- Soluția a apărut din necesitatea de a furniza o platformă care să permită analiza datelor colectate de sistemul de diagnoză a Beam Delivery System de la ELI-NP.
- Deoarece o mare parte a acestor data sunt sensibile, accesul trebuie limitat folosind o strategie de tip RBAC.
- Procesul de analiză al datelor nu este unul standardizat și trebuie permisă folosire mai multor limbaje de programare în analiză (R, Python, Julia, C/C++).
- Volumul de date este unul extensiv, sistemul de diagnoză furnizând în medie 24,35 Gb/oră de funcționare (12.55 Tb de date brute per lună) în implementarea actuală.
- Soluția implementată trebuie să permită ingestia, preprocesarea și analiza datelor științifice colectate.
- Este necesară implementarea soluțiilor de Machine Learning pentru analiza preliminară a datelor.

## Arhitectura

- Implementarea folosește un sistem de orchestrare a containerelor de tip kubernetes (k8s).
- Serviciile interne sau externe sunt implementate folosind metodologia High Availability (inclusiv pentru cluster-ul k8s).
- Marea majoritate a serviciilor folosesc o bază de date relațională pentru stocarea setărilor.
- Soluția de stocare folosită pentru aplicația noastră creează un DataLake bazat pe un sistem compatibil AWS S3 și o bază de date NOSQL pentru stocarea metadatelor aferente datelor ingerate. Datele sunt păstrate într-o formă cât mai apropiată de forma în care sunt furnizate de ELI-NP.
- Ingestia datelor științifice este asigurată printr-o serie de DAG-uri rulate folosind orchestrarea asigurată de Apache Airflow.
- Analiza datelor este realizată în mod programatic folosind Jupyter Notebook și VSCode Server.
- Orchestrarea serviciilor de Machine Learning este asigurată de platforma MLflow.
- Contextul de securitate este furnizat de o instanță HA a serverului OIDC Keycloak



kubernetes



PostgreSQL

MINIO

mongo  
DB



mlflow



KEYCLOAK

## Arhitectura

Table 1.: Pilot infrastructure hardware details

App.	Type	Count	CPU cores	RAM	Storage
Storage	bare-metal	1	20 (Xenon Gold 5115)	128 Gb	130 Tb
Master	virtualized	2	8 (Xenon Gold 5115)	16 Gb	35 Gb
Worker	baremetal	1	16 (E5-2650 v2)	64 Gb	465 Gb
Worker*	baremetal	2	32 (E5-2670)	64Gb	465 Gb

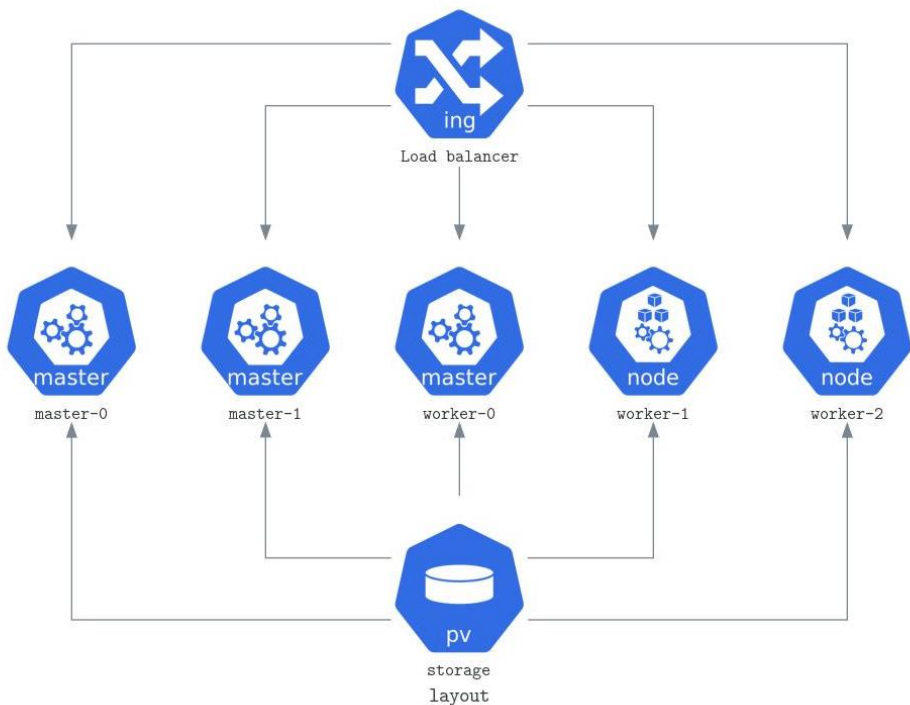
\* One of the workers is also registered as a master node

Table 2.: Full dataset parameters


Freq [Hz]	Record count	Total [Gb]	Average [Mb]	Sample count*
0.17**	13255	1.961	0.148	578
1	120321	52.375	0.435	47374
10	928124	4620.846	4.979	85626
<b>Total</b>	1061700	4675.182	4.403	133578

\* Samples taken from the fileset for statistical purposes

\*\* due their reduced size only a small subset was considered for the statistics



Cluster Layout



Orchestrarea serviciilor

## Agregarea datelor

```

_id: ObjectId('64ac6d84eb8e7702aa1cbca3')
front: "LA"
arm: null
amp: "A3"
device: "Camera"
file: "s3://eli-np-data/2022-07-01/LA_CameraComputer01-Recorder_60s_snapshot_..."
interval: ""
date: "2022-07-01"
timestamp: "09-34-00-000"
timestamps: "09-34-00"
data_group: "LA_A3_32-Camera_1-Camera-1"

```



```

_id: ObjectId('64bd0d93b58f6c3186bdf416')
  rec: Object
    date: "2022-07-01"
    timestamps: "07-33-00"
    interval: ""
  frontend: "LA"
  amp: "A3"
  arm: "31"
  Camera: Array (1)
    0: Object
      group: "LA_A3_31-Camera_1-Camera-1"
      file: "s3://eli-np-data/2022-07-01/LA_CameraComputer02-Recorder_60s_snapshot_..."
      timestamp: "07-33-00-000"
      state: false
  EnergyMeter: Array (3)
    0: Object
      group: "LA_A3_31-Atlas100_1-EnergyMeter-1"
      file: "s3://eli-np-data/2022-07-01/LA_DeviceComputer07-Recorder_60s_snapshot_..."
      timestamp: "07-33-00-000"
      state: true
      valid: false
    1: Object
      group: "LA_A3_31-EM_1-EnergyMeter-1"
      file: "s3://eli-np-data/2022-07-01/LA_DeviceComputer08-Recorder_60s_snapshot_..."
      timestamp: "07-33-00-000"

```

Utilizarea agregării permite structurarea datelor într-un mod inteligibil pentru utilizator facilitând astfel procesul de analiză al datelor.

De exemplu, în figurile de pe acest slide am transformat o înregistrare bruta (fig de sus) într-o structură de date care poate fi procesată în mod facil.

## Algoritmi de Machine Learning

Odată structurate datele acestea pot fi procesate în mod automat folosind algoritmi de Machine Learning. De exemplu, deoarece datele numerice (Energy meter, Spectrometer) pot fi procesate în mod direct, imaginile spot-ului laser la ieșirea sistemului de amplificatori specifici laserilor de mare putere instalați la ELI-NP nu mai permite o astfel de analiză. Deși a fost aplicat un efort considerabil pentru identificarea unor algoritmi determinați pentru analiză și aceștia din urmă necesită evaluare manuală.

În aplicația noastră a fost dezvoltat un algoritm de ML de tip Convolutional Auto Encoder (CAE) care să folosească procesul de Unsupervised Learning pentru identificarea anomaliilor din imaginile spot-ului laser folosind reconstrucția specifică acestei clase de algoritmi.




Fig. 2 – : Training and validation loss for CAE Network


Sistemul permite:

- Managementul parametrilor;
- Hyperparameter tuning;
- Integrarea modelelor de ML în fluxurile de analiză;
- Utilizarea unui model hibrid (in cloud sau on-premises) pentru antrenarea modelelor de ML.

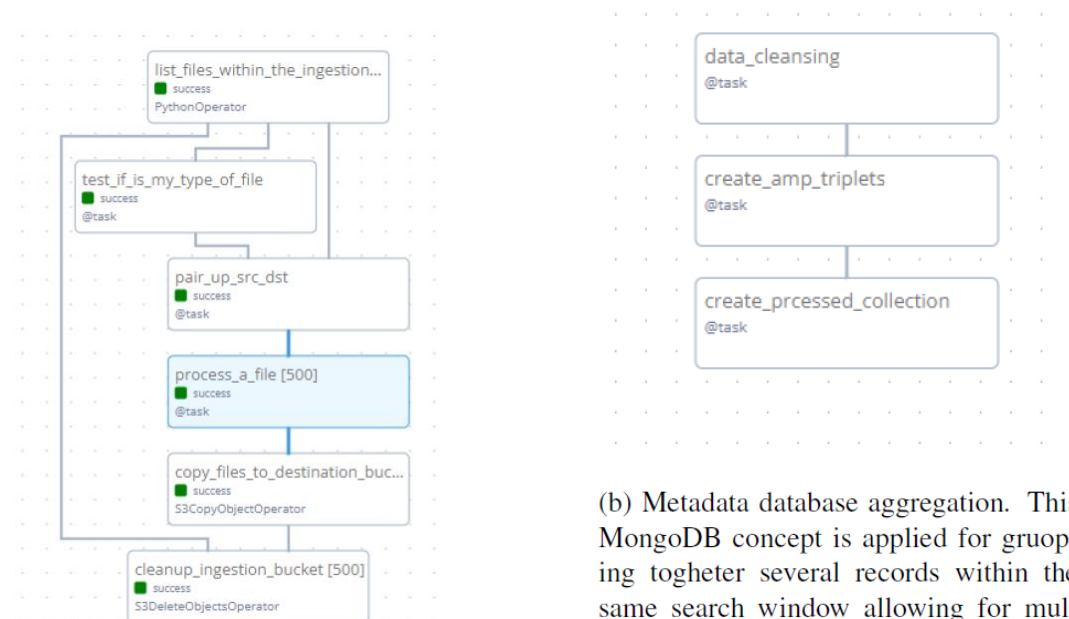
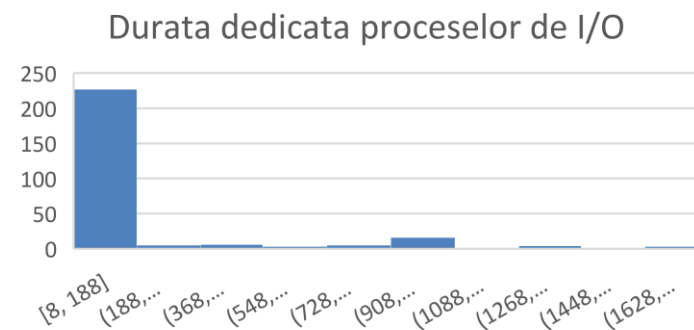
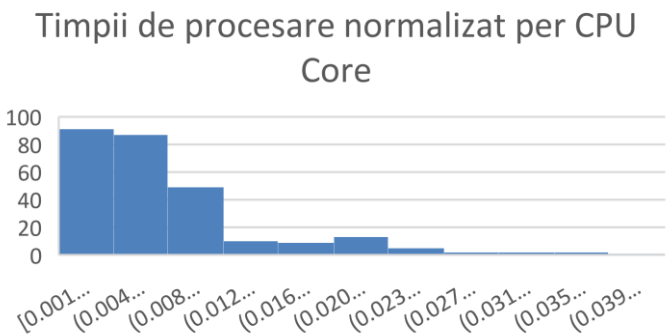
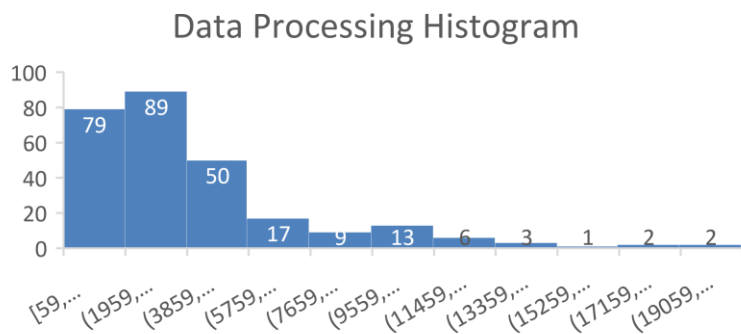
## Performanța

Table 3.: Ingestion statistics for each ingestion step

Step	Total [s]	Average [s]	Stdev [s]
List files within the ingestion bucket	349	2.08	1.02
Test if my type of file	$\ll 1$	$\ll 1$	$\ll 1$
Pair up source and destination	1044	6.21	0.86
Process one file	758130	4539.70	3630.93
Copy files to destination bucket	32230	192.99	234.52
Cleanup ingestion bucket	15362	91.99	158.74
<b>Total</b>	<b>821133</b>	<b>4916.94</b>	<b>3711.44</b>



(c) Data validation process for the ingested records



(a) Data ingestion and preprocessing DAG

(b) Metadata database aggregation. This MongoDB concept is applied for grouping together several records within the same search window allowing for multiple datasources (Energy Meters, Spectrometers or Cameras) to be correlated

## Scalabilitate

Analiza statistică a fost realizată pe un eșantion reprezentativ de date de intrare sumarizând 133578 de fișiere din care 47952 au avut dimensiunea mai mică decât cea standard (0.17Hz respectiv 1Hz).

Analiza a fost realizată pe 3 noduri de calcul cu câte 32 de nuclee CPU folosind 5 procesoare (worker) Airflow.

Pe parcursul analizei am realizat optimizările bazelor de date (RDBMS respectiv NOSQL). Pentru reindexarea bazelor, fluxurile de procesare au fost întrerupte temporar.

Pentru Procesarea Real-Time (same day results) resursele computaționale trebuie să fie scalate la noduri de procesare (8 x 32 nuclee de procesor).

Nodurile de management nu trebuie scalate, singura cerință asupra acestora fiind aceea de a păstra cvorumul minim de 3 noduri (pentru asigurarea High Availability - HA).

Sistemul de stocare necesită redimensionare pentru procesarea datelor istorice.



## Lessons Learned

- Utilizarea clusterelor permit agregarea resurselor computaționale consolidând astfel resurse disparate sub forma unui computer cu putere totală.
- Serviciile folosesc containere pentru asigurarea izolării resurselor alocate, sistemul fiind aplicat pentru spațiile alocate utilizatorilor permitând astfel alocarea resurselor direct către procesele utilizatorilor fără a fi aceștia din urmă afectați de alte procese ce rulează pe sistemul respectiv.
- Deoarece utilizatorii pot rula cod arbitrare, resursele cluster-ului sunt protejate prin politici de rețea care nu permit accesul decât la serviciile alocate acestora prin intermediul contextului de securitate.
- Utilizarea OIDC permite implementarea granulară a permisiunilor utilizatorilor și accesul la resurse.
- Sistemul de stocare este punctul critic al aplicației și este necesară redimensionarea acestuia dacă sunt păstrate datele istorice prin implementarea unei soluții distribuite în rețea care să asigure transportul datelor folosind protocoale moderne (NVMe-of/IB with RDMA, NVMe-of/TCP).
- Sistemul de Machine Learning a fost testat prin antrenarea on-premises (Arh. Nvidia Ampere 2000).
- Pentru procesele de Machine Learning există posibilitatea de a implementa o soluție de acces bazată pe RDMA peste Infiniband (de preferință cu integrarea sistemului de stocare folosind memorie non-volatilă asigurând reducerea operațiilor de copy-on-write între dispozitive).



UNIUNEA EUROPEANĂ



Instrumente Structurale  
2014-2020

## CECBID-EOSC

<https://cecbid-eosc.ifin.ro>

# VA MULTUMESC PENTRU ATENTIE !

*Bibliografia acestei lucrări se regăsește în articolul *Advances in Open Science Computing for Nuclear Physics* aflat în acest moment în proces de review.*

Conferinta de incheiere,  
28.07.2023

