



PROJET ILAAS

Olivier WONG -- Université de Rennes
Thibault LE MEUR -- Centrale Supélec Paris Saclay

D'OÙ ÇA VIENT
À QUOI ÇA RESSEMBLE
QUI ON EST
COMMENT ON FAIT ?
PREMIERS DC CONNECTÉS
COMMENT REJOINDRE OU UTILISER

PROJET ILAAS ... QU'EST-CE QUE C'EST ?

D'OÙ ÇA VIENT ? EXPÉRIMENTATIONS EN 2023 PUIS 2024 : IA GÉNÉRATIVE

◆ Aristote, CentraleSupélec

Brique Aristote-Dispatcher utilisée pour mutualiser les accès aux GPU en gérant des priorités

- Développée dans le cadre du projet Aristote lors du choix d'utilisation de modèles supérieurs à 8b


<https://github.com/CentraleSupélec/aristote-dispatcher>

- Objectif : mutualiser les ressources de calcul sur différents usages et pour différents "clients"

◆ RAGaRenn, Université de Rennes

Solution de confiance pour expérimenter l'intérêt du RAG pour les personnels volontaires

- Déploiement de briques open-source: OpenWebUI, ollama, vLLM...
- Hébergement local : datacenter régional labellisé Eskemm Data
- Observations sur les usages (qualitatif & quantitatif)



D'OÙ ÇA VIENT ? CONSTATS PARTAGÉS MI-2024

◆ **Soutenabilité**

Équilibre budgétaire et sobriété numérique : impact environnemental de l'inférence selon usages

◆ **Résilience**

Qualité de service, lissage des pics, gestion des indisponibilités

◆ **Confiance**

Niveau de confiance partagé, sécurisation raisonnable, facilite l'émergence de nouveaux services

◆ **Souveraineté**

Ouvrir les choix possibles, améliorer la robustesse






MUTUALISER LES INFRASTRUCTURES NUMÉRIQUES DES PARTENAIRES POUR LES METTRE À DISPOSITION D'UTILISATEURS BÉNÉFICIAIRES

Objectif du projet ILAAS



Photo de [Luisa Brimble](#) sur [Unsplash](#)

A QUOI ÇA RESSEMBLE ? (VUE D'ENSEMBLE)



QUI ON EST ?

◆ Consortium ouvert, évolutif

- ◆ Phase 1 : Université de Rennes (porteur), Université Reims Champagne Ardennes, Université Paris I Panthéon Sorbonne, Université de Lille, Centrale Supélec Paris Saclay
- ◆ Phase 2 intéressés : Université de Nantes, Université d'Angers, Université Paris Cité, Université de Lorraine, Université Cote d'Azur, Université de Strasbourg, Université de Haute-Alsace, Université d'Orléans, Université de Tours, Université Marie et Louis Pasteur, BRGM, UPJV, CY Cergy Paris Université, Polytechnique, EHESS,...

[INSEREZ LE NOM DE VOTRE ETABLISSEMENT ICI]

◆ Partenaires potentiels

- ◆ autres DC labellisés
- ◆ mésocentres (lien Mesonet)
- ◆ fournisseurs de cloud souverains

◆ MESR (DGRI & DGESIP) : financeur et bénéficiaire

◆ Tiers (entités publiques) : bénéficiaires d'un accès à la fédération

COMMENT ON FAIT ?

- ◆ Objectifs partagés : confiance, souveraineté, soutenabilité, résilience
 - ◆ Expérimentation itérative
 - ◆ Phases ouvertes selon établissements & collègues souhaitant s'investir
- ◆ Projet en plusieurs phases
 - ◆ Phase 1 : fin 2024 – début 2025 : expérimenter des usages, dégager des métriques de dimensionnement
 - Déploiement logiciel : aristote-dispatcher
 - Travaux : tableaux de bord, facturation au token, authentification, découplages applicatifs (en lien avec CRISolid)
 - Achat et intégration des GPU : intégrés avec l'existant, exposés en fédération
 - Préparation de l'industrialisation phase 2 : API, mesures (soutenabilité / facturation / modèle économique)
 - ◆ Phase 2 : mi-2025 : augmenter l'échelle, industrialiser
 - On en discute... Pour l'instant : support, formation, documentation ; usages & impacts ; consolidation de la puissance de calcul ; modèle économique & circuit financier
 - ◆ Phase 3 : à déterminer : sortir de l'expérimentation, selon stratégie & financements

COMMENT ON FAIT ?

- ◆ **Mutualisation & échanges**
 - ◆ GT projet toutes les 2 semaines
 - ◆ GT techniques idem
 - ◆ Plénière tous les 2 mois
- ◆ **Esprit constructif**
 - ◆ Actions constructives
 - ◆ Critiques constructives
- ◆ **Franchise**
- ◆ **Expérimentation**
 - ◆ Fournir des preuves
 - ◆ Droit à l'erreur
 - ◆ Bien + Rapide ~~VS Parfait + Lent~~



Photo de [Philippe Bout](#) sur [Unsplash](#)

COMMENT REJOINDRE OU UTILISER ?

◆ Entrer dans la fédération = contribuer


- ◆ Différentes possibilités de contribution : héberger un nœud de calcul, produire du code, aider à conduire le projet, documenter, mener des études ...
- ◆ Recensement par établissement : delta existant VS souhaité (= alimenter la demande de financement phase 2)
- ◆ Engagement au niveau de la gouvernance : VP (numérique), Directeur (DSI)
- ◆ Accord de consortium multi partenaires : à étudier avant que l'encre sèche

◆ Bénéficier de la fédération = consommer, payer


- ◆ Approbation du consortium pour accéder au(x) service(s) de la fédération
- ◆ Tout contributeur peut être consommateur en « circuit court » = les requêtes locales sont prioritaires vs celles qui sont externes
- ◆ Services actuels : Inférence LLM as a service (ILaaS)

PREMIERS DATACENTRES CONNECTÉS

Token Throughput ⓘ



Request Generation Length ⓘ



neuralmagic/Meta-Llama-3.1-70B-Instruct-FP8 ▾ +

Q Search a model

All

- OI casperhansen/llama-3-70b-instruct-awq ⓘ
- OI neuralmagic/Meta-Llama-3.1-70B-Instruct-FP8 ⓘ ✓
- OI neuralmagic/Meta-Llama-3.1-8B-Instruct-FP8 ⓘ
- OI Arena Model ⓘ

Q Temporary Chat

How can I help you today?

+ Web Search Code Interpreter

⚡ Suggested

Tell me a fun fact

about the Roman Empire

Show me a code snippet

of a website's sticky header

Give me ideas

for what to do with my kids' art

Modèle disponible à Rennes

Modèle disponible à Rennes et Lille
en partage de charge

COMMENT REJOINDRE OU UTILISER ?

◆ Moyens de communication

- ◆ Liste de diffusion (1-2 messages par mois) : ilaas@groupe.renater.fr
S'abonner : https://groupe.renater.fr/sympa/subscribe/ilaas?previous_action=info
- ◆ Espace resana dédié pour la documentation
Sur invitation : <https://resana.numerique.gouv.fr/public/perimetre/consulter/1300091>
- ◆ Rocket.chat :
Lien d'invitation : <https://rocket.esup-portail.org/invite/nydgcJ>

◆ Pages de présentation

- ◆ Atelier IA esup-portail : <https://www.esup-portail.org/wiki/x/GlByW>
- ◆ Site web (pour bientôt) : ilaas.fr, en attendant : contact@ilaas.fr

◆ Echanges synchrones durant les semaines impaires

- ◆ GT technique mardi 16h : https://rendez-vous.renater.fr/auth/ilaas-tech_9f435f-fc08eb-37656d
prochaine session : mar. 8 avril 2025 (atelier installation)
- ◆ GT projet jeudi 13h : https://rendez-vous.renater.fr/auth/ilaas-proj_c7825d-446d42-b6e721
prochaine session : jeu. 10 avril 2025 (avancement)

CE SONT RAREMENT LES RÉPONSES
QUI APPORTENT LA VÉRITÉ, MAIS
L'ENCHAÎNEMENT DES QUESTIONS.

Daniel Pennac, *La fée Carabine*