

Formation Formation Kyutai Helium : IA générative souveraine

Présentation

Kyutai Helium permet de déployer une IA générative souveraine pour le chat, l'assistance interne et la recherche documentaire, tout en gardant la maîtrise des données. La formation vous guide pour passer rapidement du POC à un usage opérationnel on-premise ou cloud privé.

Au cours de cette formation, vous apprenez à installer, configurer et exploiter Helium pour des cas concrets : agent conversationnel, FAQ augmentée, rédaction assistée, et analyse de documents. L'accent est mis sur la sécurité, la gouvernance et la qualité des réponses (prompting, garde-fous, évaluation).

L'approche est 100% pratique : démos guidées, ateliers pas à pas, jeux de tests et scénarios métier. Vous repartez avec une instance fonctionnelle, des prompts réutilisables, une checklist de déploiement et un plan d'industrialisation (monitoring, logs, mises à jour, bonnes pratiques d'usage).

Objectifs

- Installer et démarrer une instance Helium en environnement maîtrisé.
- Configurer modèles, paramètres d'inférence et limites d'usage.
- Concevoir des prompts robustes et des gabarits orientés métier.
- Mettre en place des garde-fous (politiques, filtrage, traçabilité).
- Évaluer et améliorer la qualité (tests, métriques, itérations).

Public visé

- Développeurs et ingénieurs logiciel
- Data/ML engineers et MLOps
- Architectes et responsables infrastructure/sécurité
- Chefs de projet technique / innovation

Pré-requis

- Notions de base en IA générative et LLM
- Connaissances Linux (shell, services, fichiers)
- Compréhension des concepts API et HTTP
- Notions de sécurité (réseau, accès, secrets)

Pré-requis techniques

- Machine avec 16 Go RAM minimum (32 Go recommandé)
- Linux ou macOS ; Windows possible via WSL2
- Accès administrateur, terminal, et un éditeur de code
- Outils : Docker (recommandé), Git, curl
- Connexion réseau pour récupérer dépendances et images (si autorisé)

Programme de formation Formation Kyutai Helium : IA générative souveraine

[Jour 1 - Matin]

Comprendre Kyutai Helium et les enjeux d'une IA générative souveraine

- Positionner Helium : cas d'usage, limites, différences vs LLMs cloud
- Clarifier les notions clés : modèle, token, contexte, latence, coût
- Identifier les exigences de souveraineté : localisation des données, contrôle, traçabilité
- Définir un cadre d'usage en entreprise : données autorisées, confidentialité, responsabilités
- Atelier pratique : Cartographier 3 cas d'usage internes et leurs contraintes (données, risques, ROI).

[Jour 1 - Après-midi]

Prise en main et prototypage : du prompt au workflow reproductible

- Structurer des prompts efficaces : rôle, objectif, contraintes, format de sortie, critères de qualité
- Mettre en place des gabarits : prompts paramétrables, variables, checklists de validation
- Réduire les erreurs : hallucinations, ambiguïtés, sur-confiance, biais de formulation
- Évaluer les résultats : jeux d'exemples, critères d'acceptation, itérations rapides
- Atelier pratique : Construire un mini-workflow "rédaction + relecture + synthèse" avec prompts versionnés.

[Jour 2 - Matin]

RAG et données internes : connecter Helium à une base documentaire

- Comprendre le principe RAG : chunking, embeddings, recherche, génération
- Préparer les documents : nettoyage, découpage, métadonnées, gestion des versions
- Définir une stratégie de recherche : top-k, filtres, seuils, citations et sources
- Mettre en place des tests de pertinence : questions types, couverture, taux d'erreur
- Atelier pratique : Concevoir un pipeline RAG sur un corpus interne (FAQ/Procédures) avec critères de qualité.

[Jour 2 - Après-midi]

Mise en production souveraine : sécurité, gouvernance et exploitation

- Déployer en environnement contrôlé : isolation, accès réseau, gestion des secrets
- Sécuriser les usages : contrôle d'accès, journalisation, prévention des fuites de données
- Mettre en place une gouvernance : politiques de prompts, validation, gestion des incidents
- Suivre la performance : latence, taux d'échec, qualité perçue, coûts d'infrastructure
- Atelier pratique : Rédiger un plan d'exploitation (runbook) et une charte d'usage pour un assistant interne.

Sociétés concernées

Cette formation s'adresse à la fois aux particuliers ainsi qu'aux entreprises, petites ou grandes, souhaitant former ses équipes à une nouvelle technologie informatique avancée ou bien à acquérir des connaissances métiers spécifiques ou des méthodes modernes.

Positionnement à l'entrée en formation

Le positionnement à l'entrée en formation respecte les critères qualité Qualiopi. Dès son inscription définitive, l'apprenant reçoit un questionnaire d'auto-évaluation nous permettant d'apprécier son niveau estimé sur différents types de technologies, ses attentes et objectifs personnels quant à la formation à venir, dans les limites imposées par le format sélectionné. Ce questionnaire nous permet également d'anticiper certaines difficultés de connexion ou de sécurité interne en entreprise (intraentreprise ou classe virtuelle) qui pourraient être problématiques pour le suivi et le bon déroulement de la session de formation.

Méthodes pédagogiques

Stage Pratique : 60% Pratique, 40% Théorie. Support de la formation distribué au format numérique à tous les participants.

Organisation

Le cours alterne les apports théoriques du formateur soutenus par des exemples et des séances de réflexions, et de travail en groupe.

Validation

À la fin de la session, un questionnaire à choix multiples permet de vérifier l'acquisition correcte des compétences.

Sanction

Une attestation sera remise à chaque stagiaire qui aura suivi la totalité de la formation.