

Formation Déployer Ollama et des modèles IA open source (Mistral...)

■ Durée :	2 jours (14 heures)
■ Tarifs inter-entreprise :	1 875,00 € HT (standard) 1 500,00 € HT (remisé)
■ Public :	Administrateurs systèmes et DevOps, développeurs back-end, architectes techniques, responsables ou référents IA souhaitant déployer un moteur IA en interne
■ Pré-requis :	Bonnes bases en environnement Linux (ligne de commande), notions de réseau (ports, firewall, proxy), premières notions sur l'IA générative et les API web
■ Objectifs :	Comprendre l'architecture d'Ollama et des modèles open source (Mistral...) en contexte entreprise - Savoir installer, configurer et sécuriser Ollama sur un serveur on-premise ou cloud - Être capable d'exposer un ou plusieurs modèles IA aux applications internes (API) en maîtrisant les aspects performance, monitoring et gouvernance
■ Modalités pédagogiques, techniques et d'encadrement :	<ul style="list-style-type: none">• Formation synchrone en présentiel et distanciel.• Méthodologie basée sur l'Active Learning : 75 % de pratique minimum.• Un PC par participant en présentiel, possibilité de mettre à disposition en bureau à distance un PC et l'environnement adéquat.• Un formateur expert.
■ Modalités d'évaluation :	<ul style="list-style-type: none">• Définition des besoins et attentes des apprenants en amont de la formation.• Auto-positionnement à l'entrée et la sortie de la formation.• Suivi continu par les formateurs durant les ateliers pratiques.• Évaluation à chaud de l'adéquation au besoin professionnel des apprenants le dernier jour de formation.

■ Sanction :	Attestation de fin de formation mentionnant le résultat des acquis
■ Référence :	INT102822-F
■ Note de satisfaction des participants:	Pas de données disponibles
■ Contacts :	commercial@dawan.fr - 09 72 37 73 73
■ Modalités d'accès :	Possibilité de faire un devis en ligne (www.dawan.fr, moncompteformation.gouv.fr, maformation.fr, etc.) ou en appelant au standard.
■ Délais d'accès :	Variable selon le type de financement.
■ Accessibilité :	Si vous êtes en situation de handicap, nous sommes en mesure de vous accueillir, n'hésitez pas à nous contacter à referenthandicap@dawan.fr, nous étudierons ensemble vos besoins

Comprendre Ollama et les modèles IA open source

Panorama des modèles IA open source (Mistral, LLaMA, autres) et cas d'usage en entreprise

Positionnement d'Ollama : moteur local, orchestrateur de modèles, alternative aux API cloud

Principes de base des LLM : tokens, prompts, contextes, limites de taille et coûts indirects

Choisir un modèle en fonction des besoins (génération de texte, chat, résumé, code, etc.)

Atelier pratique : prise en main d'Ollama en local sur poste de travail (installation rapide et premier prompt avec un modèle Mistral)

Préparer l'infrastructure pour un déploiement en entreprise

Préfigurer l'architecture cible : serveur unique, cluster, intégration avec les SI existants

Pré-requis matériels : CPU vs GPU, RAM, stockage, bande passante, dimensionnement de base

Environnement système : choix de la distribution Linux, gestion des utilisateurs, droits sudo

Contraintes réseau : ports, reverse proxy, SSL/TLS, prise en compte des proxies d'entreprise

Atelier pratique : définir une architecture cible et une fiche de dimensionnement pour un premier serveur Ollama d'entreprise

Installer et configurer Ollama sur un serveur

Installation d'Ollama sur un serveur Linux : étapes clés et vérifications indispensables
Gestion du service (systemd) et démarrage automatique, logs et fichiers de configuration

Configuration des options de base : ports d'écoute, répertoires de modèles, accès réseau

Mise en place d'un reverse proxy (nginx ou équivalent) pour exposer Ollama en HTTPS

Atelier pratique : installation complète d'Ollama sur un serveur de test et vérification d'accès via API depuis un poste client

Gérer les modèles Mistral et autres modèles IA

Télécharger, installer et mettre à jour un modèle Mistral avec Ollama (pull, list, remove)

Comprendre l'impact des différentes tailles de modèles (7B, 8B, 12B, etc.) sur la performance

Configurer les paramètres d'inférence : température, top-p, context window, temps de réponse

Stratégies de stockage des modèles et des caches, organisation par environnement (test, prod)

Atelier pratique : déployer plusieurs variantes de modèles Mistral, comparer leurs temps de réponse et ajuster les paramètres d'inférence

Exposer Ollama aux applications internes

Découvrir l'API HTTP d'Ollama : endpoints principaux, formats de requêtes et réponses

Intégrer Ollama dans une application interne (exemples en Python ou Node.js)

Mettre en place des clés d'API ou un proxy d'authentification pour sécuriser l'accès

Bons réflexes pour gérer les files d'attente, les timeouts et la résilience des appels

Atelier pratique : développer un petit service interne (chat ou complétion de texte) connecté à un modèle Mistral déployé sur Ollama

Sécuriser et gouverner l'usage d'Ollama en entreprise

Identifier les risques : fuites de données, prompts sensibles, dérives d'usage

Mettre en place des restrictions d'accès par réseau, authentification et journalisation

Bonnes pratiques pour l'usage de données internes : anonymisation, jeux de test, règles internes

Éléments de conformité (RGPD, confidentialité, localisation des données, journalisation des accès)

Atelier pratique : définir une politique d'usage et un document de bonnes pratiques IA pour les utilisateurs internes

Supervision, optimisation et maintenance du service Ollama

Surveiller l'activité : logs, métriques de performance, consommation CPU/GPU/RAM

Mettre en place un monitoring basique (export de métriques, tableaux de bord simples)

Planifier les mises à jour d'Ollama et des modèles tout en limitant l'indisponibilité

Stratégies de sauvegarde et de restauration : configurations, scripts, documentation technique

Atelier pratique : construire un mini plan d'exploitation (monitoring, sauvegarde, mises à jour) pour le serveur Ollama d'entreprise

Bilan et plan d'actions pour le déploiement en production

Synthèse des choix techniques et organisationnels réalisés pendant la formation

Identifier les évolutions possibles : RAG, connexion à une base documentaire, multi-modèles

Planifier un pilote interne avec un petit groupe d'utilisateurs et des cas d'usage concrets

Formaliser les prochaines étapes : responsabilités, jalons, ressources nécessaires

Atelier pratique : élaborer une feuille de route personnalisée pour passer du serveur de test à un service Ollama opérationnel en production