



Spring AI et RAG : Développer des Applications Génératives

Lien :

<https://innov-systems.com/formation/spring-ai-et-rag-developper-des-applications-generatives>

 DURÉE
3 jours (21h)

 RÉFÉRENCE
DEV332

 CATÉGORIE
**Java et Développeur
Java**

OBJECTIFS DE LA FORMATION

À l'issue de cette formation, vous serez capable de :

- ✓ Comprendre les concepts fondamentaux de l'intelligence artificielle générative et ses usages en entreprise
- ✓ Construire une application intégrant des modèles de langage via Spring AI
- ✓ Maîtriser la gestion avancée des prompts et du contexte conversationnel
- ✓ Implémenter le RAG (Retrieval Augmented Generation) avec une base de données vectorielle
- ✓ Déployer et optimiser une solution en local avec Ollama ou en production avec un fournisseur Cloud
- ✓ Concevoir des scénarios pratiques incluant le stockage, la recherche contextuelle et l'intégration de fonctions métiers

POUR QUI ?

- ✓ Développeurs back-end et full-stack
- ✓ Architectes logiciels
- ✓ Chefs de projets techniques
- ✓ Ingénieurs en systèmes d'information



Programme détaillé

1 / POSITIONNEMENT ET FONDEMENTS

- Différences entre IA conventionnelle et IA générative
- Domaines d'application concrets et limites actuelles
- Panorama des modèles disponibles (OpenAI, Mistral, Llama, Claude, etc.)

2 / PREMIERS PAS AVEC SPRING AI

- Présentation de l'écosystème Spring AI
- Installation et configuration d'un projet avec Spring Boot
- Connexion à un modèle LLM hébergé dans le Cloud
- Exécution d'un premier prompt avec le ChatClient

3 / STRUCTURATION ET PARAMÉTRAGE DES PROMPTS

- Introduction au prompt engineering
- Gestion des paramètres et des rôles (system, user, assistant)
- Conversion des réponses en objets Java grâce à JSON Schema
- Bonnes pratiques pour fiabiliser les réponses des modèles

4 / CONVERSATIONS ET MÉMOIRE

- Utilisation de ChatMemory pour conserver le contexte
- Stratégies de gestion des conversations multi-tours
- Exemple pratique : chatbot persistant avec Spring AI

5 / INTÉGRATION DE MODÈLES LOCAUX AVEC OLLAMA

- Présentation d'Ollama et installation
- Revue des modèles disponibles localement

- Intégration dans une application Spring AI
- Avantages et limites de l'approche locale face au Cloud

6 / OPTIMISATION ET CALLBACKS MÉTIER

- Implémentation de fonctions callback depuis un LLM
- Cas pratiques : automatisation de tâches métiers via Spring AI
- Bonnes pratiques de sécurité et de contrôle des réponses

7 / INTRODUCTION AU RAG (RETRIEVAL AUGMENTED GENERATION)

- Pourquoi les LLMs ont besoin de contexte externe ?
- Cas d'usage du RAG : FAQ, support client, recherche documentaire

8 / BASES DE DONNÉES VECTORIELLES ET INDEXATION

- Définition d'un vecteur et principe de l'embedding
- Génération d'embeddings avec un modèle compatible Spring AI
- Recherche par similarité : fonctionnement et démonstration

9 / MISE EN PRATIQUE AVEC SPRING AI

- Utilisation de SimpleVectorStore
- Introduction à pgvector et intégration avec PostgreSQL
- Exploration des bases vectorielles du marché (Pinecone, Weaviate, Milvus)
- Atelier pratique : implémentation d'un mini-RAG avec Spring AI

10 / CONCLUSION ET MISE EN PRODUCTION

- Stratégies de déploiement (local vs Cloud)
- Optimisation des coûts et des performances
- Bonnes pratiques d'architecture pour intégrer l'IA générative dans une SI existante
- Perspectives d'évolution de Spring AI et des LLMs

Approche pédagogique

- ✓ Support Ecrit et Projection
- ✓ Exposés Interactifs, Podcasts et Vidéos
- ✓ Brainstorming et Jeux de Rôle
- ✓ Cas Pratiques et Labs inclus pour leur impact opérationnel
- ✓ Test de Validation des Acquis des Connaissances

Prochaines dates programmées

 21 au 23 Oct. 2026

 Distanciel

 Autres dates possibles sur demande. Contactez-nous pour organiser une session intra-entreprise.

Réservation & Renseignements

 **Téléphone** : +212 522 247 210
 **Email** : contact@innov-systems.com
 **Web** : <https://www.innov-systems.com>

Document généré le 05/10/2026 — Réf : DEV332
Innov Systems — Tous droits réservés