



L'utilisation des agents IA et des serveurs MCP dans un contexte client



Aperçu de la présentation

1. Présentation de Necko
2. Présentation des agents IA et des MCP
3. Introduction au Cloud AWS et au Serverless
4. Présentation de l'IA sur AWS
5. Démonstration - Compose ton PAE avec un agent
6. Conclusion et contacts

Présentation de Necko



Nous accompagnons les entreprises dans leur voyage vers le cloud

Nous leur offrons:

- une expertise pointue sur les services et les produits AWS (mais aussi GCP et Azure)
- du développement software
- des services de consultance


Notre offre de services



Foundation



Migration



Optimisation

En quelques mots

- Startup fondée en 2017
- Basée à Mons
- Partenaire cloud AWS depuis 2017, premier partenaire wallon du cloud AWS
- AWS Advanced Partner, unique en Wallonie
- AWS WAR Partner
- Expertise spécifique AWS



- AWS Lambda Delivery
- AWS CloudFormation Delivery
- Well-Architected Partner Program



Prix Mercure 2018
Ville de Mons
Jeune Entreprise



Inno pépites 2018
LME
Catégorie entreprise IT



AWS Service Delivery
AWS Lambda
AWS CloudFormation

WAR: Well Architected Framework



L'équipe

- 18 collaborateurs (pour le moment... On recrute 😁)
- Profils architectes et développeurs
- Plus de 100 certifications AWS



Nos clients



Agentic AI

Les Agents IA

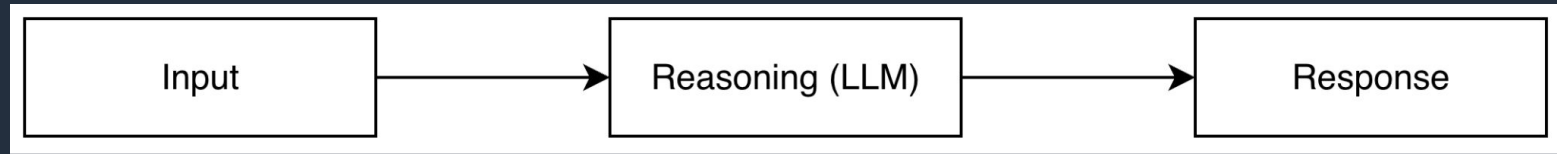
“A language model can answer questions.

An agent can do things.


The agent loop is what makes that difference possible”

- Strands Agents Documentation

Les Agents IA



Les Agents IA



Les Agents IA en entreprise

Ce qui change pour les entreprises

Avant	Avec l'agentic AI
- Tâches simples - Le LLM répond, l'humain agit	- Tâches complexes et contextuelles - Humain en superviseur, agent en exécution - Intégration d'outils

Les Agents IA

Les composants clés :

- Le LLM - moteur de raisonnement
 - Décide quelle action prendre à chaque étape
- La mémoire
 - In-Context : Ce qui est dans le prompt courant
 - Externe : Vector store (RAG)
 - Éphémère : Résultat des étapes précédentes

Les Agents IA

- Les outils
 - Fonctions que l'agent peut appeler : API, database, calculatrice, etc.
 - C'est ce qui donne à l'agent un effet sur le monde réel
- Les patterns de raisonnement
 - ReAct (reason and act)
 - CoT (chain of thought)
 - ReWOO (reason without observation)

Agents simples VS Multi-agents


Agent simple :

- Un LLM + ensemble d'outils + une boucle
- Adapté pour des tâches ciblées et bien définies

Multi-agents :

- Des agents individuels qui collaborent
- Des LLM et outils différents pour chaque sous-agent

Frameworks



Et plein d'autres...

Strands Agents

- Open source SDK
- Léger
- Model agnostic
- Model-driven
- Intégrations avec des **outils**

Strands Agents



```
from strands import Agent
from strands_tools import calculator

agent = Agent(tools=[calculator])
response = agent("Combien fait 1337 * 42 ?")
```

Les outils (Tools)

Définition

- Mécanisme élémentaire pour étendre les capacité d'un agent
- Une fonction qu'il peut décider d'appeler pour interagir avec le monde extérieur

Les outils (Tools)

Un outil est composé de trois éléments :

- Nom : identifiant unique
- Description : Texte en langage naturel
- Schéma : structure des paramètres d'entrée/sortie (en JSON)

Les outils (Tools)

Comment le LLM “choisit” un outil:

- Le LLM ne voit pas le code de l'outil
- Il voit uniquement le nom, la description en texte et le schéma
- Il génère une utilisation de tool de la forme:

```
{  
  tool: search_products,  
  parameters: {  
    query: chaise ergonomique,  
    limit: 5  
  }  
}
```

Les outils (Tools)



```
from strands import tool
```

```
@tool
```

```
def get_order_status(order_id: str) -> dict:
```

```
    """
```

```
    Retourne le statut d'une commande client.
```

```
    Utilise cet outil quand l'utilisateur demande où en est sa commande.
```

```
    Args:
```

```
        order_id: L'identifiant unique de la commande (format ORD-XXXX)
```

```
    """
```


```
    return db.query(f"SELECT status FROM orders WHERE id = '{order_id}'")
```


Les outils (Tools)

Avant MCP :

- multiplication des frameworks agent
 - multiplication des tools
- > connecteur custom pour chaque framework et chaque tools

Les outils (Tools)




Model Context Protocol

- Introduit par Anthropic en 2024
- Protocole ouvert qui standardise l'accès aux outils

MCP - Architecture

3 acteurs :

- Host (application)
- MCP client
- MCP server



MCP - Capacités

3 types de capacités qu'un serveur peut exposer :

- Tools - ce que l'agent peut faire
- Resources - ce que l'agent peut lire
- Prompts - templates réutilisables

MCP - Implémentation

```
from mcp.server.fastmcp import FastMCP

mcp = FastMCP("Serveur CRM")

@mcp.tool()
def get_customer(customer_id: str) -> dict:
    """
    Retourne les informations d'un client.
    Utilise cet outil pour récupérer le profil d'un client par son ID.
    """
    return crm_db.find(customer_id)

@mcp.resource("crm://customers/list")
def list_customers() -> str:
    """Liste tous les clients actifs"""
    return crm_db.get_all_active()

if __name__ == "__main__":
    mcp.run() # démarre le serveur en mode stdio par défaut
```

```
from strands import Agent
from strands.mcp import MCPClient

# Connexion au serveur MCP local
mcp_client = MCPClient(
    transport="stdio",
    command=["python", "crm_server.py"]
)

# Les outils MCP sont automatiquement découverts et injectés
with mcp_client:
    agent = Agent(
        tools=mcp_client.list_tools(), # get_customer, etc.
        system_prompt="Tu es un assistant CRM..."
    )
    response = agent("Donne moi le profil du client C-1042")
```

MCP - Dans un contexte client

- Permet de centraliser les outils et la connaissance
 - La documentation interne
 - La logique métier
- Permet de changer de provider sans tout réécrire

AWS Cloud

Qu'est ce que le Cloud ?

Le cloud computing est la mise à disposition de ressources informatiques à la demande via Internet, avec une tarification en fonction de votre utilisation.

source: <https://aws.amazon.com/fr/what-is-cloud-computing/>


Origine de AWS

Amazon débute avec la vente de livres, puis standardise son infrastructure face à la diversification.

En 2002, ses ingénieurs développent des services réutilisables, aboutissant à S3, SQS et EC2.


AWS est lancé en 2006 et devient, dès 2010, un leader du cloud.

Depuis 2015, AWS génère plus de bénéfices qu'Amazon Commerce, avec ~20% du CA et 50% à 70% des profits.



Source:
<https://aws.amazon.com/blogs/aws/lots-of-bits/>

Cloud vs On-Premises



Amazon Web Services

- Pas de frais initiaux
- Paiement à l'utilisation
- Accélération du Time to Market et Agilité
- Scaling automatique
- Infrastructure self-service




AWS leader depuis 15 ans

Figure 1: Magic Quadrant for Strategic Cloud Platform Services



AWS Infrastructure Globale





39 launched Regions
each with multiple Availability Zones

123 Availability Zones


700+ CloudFront POPs
and 13 Regional edge caches

Source : <https://aws.amazon.com/about-aws/global-infrastructure/>

Région divisée en Availability Zone




Serveurs virtuels dans le cloud



AWS Elastic
Cloud Compute
(EC2)

- Stockage modulable
- Disponibilité
- Démarrage rapide
- Instance différents
- Payez à l'utilisation

De on-premise vers serverless




Source:

<https://aws.amazon.com/blogs/industries/fsi-service-spotlight-amazon-elastic-container-service-ecs-with-aws-fargate/>

Managed service = Serverless

- Coût à l'utilisation
- Garantie de fiabilité
- Alerting: une alerte = erreur dans la logique
- Petit services



Autre services AWS

- plus de 200 services
 - **Calcul** : EC2, Lambda, Auto Scaling.
 - **Stockage** : S3 (objet), EBS (bloc), EFS (fichier).
 - **Base de données** : RDS (relationnel), DynamoDB (NoSQL), Aurora.
 - **Réseau** : VPC, Route 53, Direct Connect.
 - **IA & Machine Learning** : SageMaker, Bedrock (IA générative).
 - **Développement** : CodePipeline, CodeCommit


Gestion des identités et des accès



AWS IAM

- Gestion accès AWS
 - Utilisateur
 - Service
- Peut être fédérée avec d'autres systèmes (Microsoft Active Directory)

Database pour documents



Amazon
DynamoDB

- NoSQL
- Interface JSON
- Accès en ms

Database relationnelle serverless



Amazon
Aurora
Serverless V2

- SQL
- Scale to zéro
- Accès en ms
- Petite soeur: Aurora DSQL

S3: Simple Storage Service



Amazon S3

- Stockage de fichiers
- Max 5 Pb/fichier
- Scale (jusqu'à 55000 requêtes/s)


Appel de fonction



AWS Lambda


- Déclenché par un évènement
 - Cron
 - par action sur S3, Dynamo...
- Scaling automatique
- Exécute du code
- Coût = € x secondes x mémoire alloué

Orchestration de services



AWS Step
Functions

- Machine à états
- outil de visualisation de workflow




Infrastructure as Code

Objectif: Décrire l'infrastructure sous forme de code

Avantages:

- Vue détaillée de l'implémentation
- Facile à redéployer la même infrastructure
- Permet de versionner le code (Git)
- Déploiement automatique
- Tests et vérifications automatique

Créer et gérer des ressources à l'aide de modèles



AWS
CloudFormation

- Template au format Yaml
- Rollback en cas de problèmes
- Suivi du *drift*
- Permet de faire un *diff*
- *Managé par AWS*

AWS Cloud Development Kit

```
const table = new Table(this, id: 'table', props: {
  partitionKey: {
    type: AttributeType.STRING,
    name: 'id'
  }
});
const role = new Role(this, id: 'role', props: {
  assumedBy: new ServicePrincipal(ServicePrincipals.LAMBDA)
});
table.grantReadData(role);
```



- Génère du CloudFormation
- Simplifie les liens entre les ressource
- Debuggable
- Permet de créer des packages réutilisables

L'IA sur AWS

Vue d'ensemble

Services AWS

- APIs Serverless
 - Rekognition
 - Transcribe
 - Polly
 - Textract
 - ...
- Machine learning
 - Sagemaker
- IA Générative
 - AWS Bedrock



IA Générative



AWS Bedrock

- Catalogue de modèles
 - Claude (Anthropic)
 - Mistral (Mistral AI)
 - Llama (Meta)
 - Stable Diffusion (Stability AI)
 - DeepSeek-R1
- API Serverless
- Moderation (Guardrails)
- Outils de Prompt Engineering
- Outils d'évaluation

IA Générative



AWS Bedrock

Mais aussi :

- Compréhension d'images / vidéos
- Génération d'images / vidéos
 - Stable Diffusion
 - Amazon Nova
 - Amazon Titan

Catalogue de modèles

Model catalog (219)

Discover Bedrock serverless or Marketplace models that best fit your use case. To get started using a serverless model, select it from the model catalog and open it in the playground. For Marketplace models, subscribe and deploy.

Filters

Model collection

- ☐ Serverless (54)
- ☐ Bedrock Marketplace (165)

Providers

- ☐ Amazon (8)
- ☐ Anthropic (10)
- ☐ Arcee AI (5)
- ☐ Autogluon (1)
- ☐ BRIA AI (3)
- ☐ Camb.ai (1)
- ☐ Cohere (3)
- ☐ DeepSeek (6)
- ☐ EvolutionaryScale, PBC (1)
- ☐ Google (3)

[Show 10 more](#)

Modality

- ☐ Text (132)
- ☐ Text Vision (24)
- ☐ Embedding (7)
- ☐ Multimodal (5)
- ☐ Audio (1)
- ☐ Image (1)
- ☐ Tabular (1)
- ☐ Video (1)

Spotlight

**Nova 2 Lite**
By Amazon
Image, Video, Text to Text
Serverless Cross-region inference

**Devstral 2 123B**
By Mistral AI
Autonomous Software Engineering Agents: Build AI agents that can...
Serverless

**GPT OSS Safegua...**
By OpenAI
Advanced safety reasoning; Nuanced policy interpretation; Multi-turn safety...
Serverless

Sort: Most popular< 1 2 3 4 5 6 7 8 >

**Claude Sonnet 4.6**
By Anthropic
Hybrid reasoning, adaptive thinking, efficient code generation, enhanced te...
Serverless Cross-region inference

**Claude Opus 4.6**
By Anthropic
Hybrid reasoning, adaptive thinking, efficient code generation, enhanced te...
Serverless Cross-region inference

**Claude Opus 4.5**
By Anthropic
Hybrid reasoning, extended thinking, efficient code generation, enhanced te...
Serverless Cross-region inference

**Claude Haiku 4.5**
By Anthropic
Hybrid reasoning, extended thinking, efficient code generation, enhanced te...
Serverless Cross-region inference

**Claude Sonnet 4.5**
By Anthropic
Hybrid reasoning, extended thinking, efficient code generation, enhanced te...
Serverless Cross-region inference

**Claude Sonnet 4**
By Anthropic
Hybrid reasoning, extended thinking, efficient code generation, enhanced te...
Serverless Cross-region inference

**Claude 3.7 Sonnet**
By Anthropic
Text generation, Code generation, Rich text formatting, Agentic computer use
Serverless Cross-region inference

**Claude 3.5 Sonnet**
By Anthropic
Agents, Chat optimized, Code generation, Complex reasoning analysi...
Serverless Cross-region inference

**Claude 3 Haiku**
By Anthropic
Image to text, conversation, chat optimized
Serverless

**Claude 3...**
By Anthropic
Image to text & code, multilingual conversation, complex reasoning &...
Serverless Legacy

**Llama 3.2 1B...**
By Meta
Agents, Chat optimized, Code generation, Complex reasoning analysi...
Serverless Cross-region inference

**Llama 3.2 3B...**
By Meta
Agents, Chat optimized, Code generation, Complex reasoning analysi...
Serverless Cross-region inference

**Nova 2 Lite**
By Amazon
Image, Video, Text to Text
Serverless Cross-region inference

**Nova Canvas**
By Amazon
Image-to-image
Serverless

**Nova Lite**
By Amazon
Agents, Chat optimized, Conversation, Math, Multilingual support, Question...
Serverless Cross-region inference

**Nova Micro**
By Amazon
Agents, Chat optimized, Conversation, Math, Multilingual support, Question...
Serverless Cross-region inference

**Nova Pro**
By Amazon
Agents, Chat optimized, Code generation, Complex reasoning analysi...
Serverless Cross-region inference

**Nova Reel**
By Amazon
Text-to-video, Image-to-video
Serverless

**Titan Text...**
By Amazon
Output vector size = 1,024 (default), 512, or 256
Serverless

**Titan Multimodal...**
By Amazon
Output vector size = 1,024 (default), 384, or 256
Serverless

Chat

ModeChat

Compare mode

ConfigurationsInfo

 **Claude 3.5 Sonnet** v1  
EU Anthropic Claude 3.5 Sonnet

▼ System prompts

Add system prompts 

▼ Randomness and diversity

Temperature1

Top P0.999

Top K250

▼ Length

Maximum length2000

Input: 56Output: 615Latency: 19102 ms

Quelles sont les dernières innovations dans le domaine des modèles de langues ? Plus particulièrement les modèles entraînés par renforcement pour produire des chatbots tels que ChatGPT.



 Voici quelques-unes des innovations récentes les plus importantes dans le domaine des modèles de langage et des chatbots basés sur l'apprentissage par renforcement :

1. Modèles de plus en plus grands et performants : Des modèles comme GPT-4 atteignent des performances impressionnantes sur un large éventail de tâches, avec des capacités de raisonnement et de génération de texte très avancées.
2. Apprentissage par renforcement à partir de retours humains (RLHF) : Cette technique, utilisée notamment pour ChatGPT, permet d'affiner les modèles en fonction des préférences humaines, améliorant ainsi leur alignement avec nos attentes.
3. Techniques d'instruction fine (InstructGPT) : Permet d'améliorer la capacité des modèles à suivre des instructions précises et à générer des réponses plus pertinentes.
4. Modèles multimodaux : Intégration de capacités de traitement d'images, de vidéos ou de sons en plus du texte (ex: GPT-4 avec analyse d'images).
5. Amélioration de la mémoire à long terme : Développement de techniques permettant aux modèles de mieux retenir les informations sur de longues conversations.
6. Réduction des biais et amélioration de la sécurité : Efforts continus pour réduire les biais inhérents aux données d'entraînement et rendre les modèles plus sûrs et éthiques.
7. Optimisation de l'efficacité computationnelle : Recherches sur des architectures plus légères et efficaces pour réduire les coûts et l'empreinte carbone.
8. Personnalisation et adaptation : Développement de techniques permettant d'adapter rapidement les modèles à des domaines ou utilisateurs spécifiques.

Write a prompt. Press Shift + Enter to add a new line. Press Enter to generate a response.


  

Run

Bedrock AgentCore

Plateforme d'infrastructure agentique
managée par AWS

Permet d'héberger les agents définis
dans n'importe quel framework



Bedrock AgentCore - Services

- Runtime
Déploiement serverless d'agents
- Memory
Mémoire persistante entre les sessions
- Identity
Gestion des identités

Bedrock AgentCore - Services

- Gateway
Connecte les agents aux outils existants / aux MCP
- Policy
Contrôle des actions autorisées pour chaque agent
- Observability
Dashboard, logs

Démonstration

Conclusion et contacts

Nous contacter



Necko Technologies



Necko Technologies



Doriane Dell'Aria

Lead Cloud Developer at Necko Technologies



Maximilien Charlier

Solutions Architect at Necko Technologies
| PhD | 15x AWS certified | IoT & LoRaWA...



Merci pour votre attention!

Posez vos questions
maintenant ou n'hésitez
pas à nous contacter !

www.necko.tech



contact@necko.tech

