

Guide Pratique

OpenClaw : Memoire et Contexte MEMORY.md, Compactions et Long-terme

Architecture memoire pour agents IA en production

Mars 2026

Sommaire

1. Fenetre de contexte vs memoire persistante
 2. MEMORY.md — la memoire long-terme
 3. Les daily notes — logs bruts quotidiens
 4. Les compactions — distiller la memoire
 5. Memoire partagee vs memoire isolee
 6. Recherche semantique en memoire
 7. A l'echelle : 15 agents, 6 mois de memoire
 8. Anti-patterns a eviter
- Conclusion

L'IA n'a pas de memoire native — mais un agent operationnel en a besoin. BOTUM documente son architecture de memoire : MEMORY.md, daily notes, compactions et gestion a l'echelle d'un reseau de 15 agents en production.

1. Fenetre de contexte vs memoire persistante

La confusion la plus frequente : confondre la fenetre de contexte avec la memoire. Ce sont deux choses fondamentalement differentes.

La fenetre de contexte est la quantite d'information qu'un modele peut traiter en une seule session. Elle est volatile (s'efface a la fin de chaque session) et elle sature (les informations les plus anciennes disparaissent silencieusement quand le contexte se remplit).

La memoire persistante, c'est ce qui reste entre les sessions. C'est un artefact de votre infrastructure, pas du modele. Elle ne se cree pas seule.

- Decisions prises les semaines precedentes
- Preferences exprimees par les utilisateurs
- Erreurs deja documentees
- Contextes clients et historiques de projets

■ Selon Gartner 2025, 71% des echecs de deploiement d'agents IA sont lies a une architecture de memoire inadeguate plutot qu'aux capacites du modele.

2. MEMORY.md — la memoire long-terme

Dans l'architecture OpenClaw, MEMORY.md est le fichier de memoire consolidee. Il contient ce qui doit persister au-dela des sessions individuelles.

Ce qu'on y met

- Les regles immuables de l'agent
- Les informations cles sur l'organisation
- Les decisions importantes et leur rationale
- Les erreurs documentees a ne plus repeter
- Les integrations et leurs particularites

Regles de curation

- Taille maitrisee : viser 2 000 a 5 000 tokens maximum
- Sections stables organisees par domaine
- Principe d'ecriture active : rien n'entre sans que quelque chose sorte
- Versioning Git : chaque modification est un commit

“Ce fichier est lu au debut de chaque session principale. C'est l'injection de contexte qui permet a l'agent de se souvenir.”

3. Les daily notes — logs bruts quotidiens

Les daily notes (memory/YYYY-MM-DD.md) sont les journaux de bord de l'agent. Chaque jour a son fichier. On y capture en temps reel ce qui se passe.

Quand ecrire

- Apres chaque action significative (email envoye, script execute, configuration modifiee)
- Quand une regle implicite a ete appliquee (pour la rendre explicite)
- Quand un comportement inattendu a ete observe
- Quand une decision a ete prise qui pourrait etre questionnee plus tard

Ce qu'on capture

- Le quoi (action precise), le pourquoi (contexte), le resultat
- Les heuristiques utilisees pour trancher une ambiguïté
- Les references (numero de ticket, identifiant client, URL concerne)
- Les signaux d'alerte qui meritent attention

■ *Les daily notes ne sont pas ecrites pour etre lues en session courante. Leur valeur n'est pas immediate : elle est dans l'accumulation.*

4. Les compactions — distiller la memoire

La compaction est l'operation de distillation : on prend un volume de daily notes et on en extrait ce qui merite de survivre dans MEMORY.md.

Quand compacter

- Quand la fenetre de contexte approche de la saturation (>40% d'utilisation)
- Periodiquement, independamment de l'utilisation (hebdomadaire ou mensuel)
- Avant d'aborder un nouveau domaine ou projet
- Quand MEMORY.md devient lui-meme trop lourd

Protocole BOTUM en 4 etapes

1. Relecture des daily notes de la periode
2. Extraction des candidats a la persistance (regles, decisions, erreurs documentees)
3. Mise a jour de MEMORY.md avec fusion et deduplication
4. Commit Git avec message descriptif — les daily notes restent dans l'archive

Tests pour decider quoi garder

- Test de permanence : cette information sera-t-elle encore pertinente dans 3 mois ?
- Test de frequence : cet element sera-t-il consulte souvent ou c'est un evenement unique ?
- Test de derivabilite : peut-on retrouver cette info ailleurs si necessaire ?
- Test de regle : cet evenement revele-t-il une regle generale applicable a d'autres situations ?

5. Memoire partagee vs memoire isolee

Dans un reseau multi-agents, quelle information est partagee entre agents, et quelle information reste privee ?

Memoire partagee

Le workspace commun : MEMORY.md, CODEX.md, AGENTS.md. Accessible a tous les agents. C'est la memoire organisationnelle : regles communes, etat du systeme, decisions collectives.

Memoire isolee

Les repertoires d'agents (agents/nom-agent/). Chaque agent peut avoir ses notes privees, ses configurations specifiques. Ce qui reste dans ce repertoire n'est pas injecte automatiquement dans les autres agents.

Principe de separation BOTUM

- Regles qui s'appliquent a tous → workspace partage (MEMORY.md)
- Regles specifiques a un domaine → repertoire de l'agent concerne
- Logs d'execution → daily notes de l'agent, pas dans le workspace commun
- Artefacts inter-agents → repertoire dedie (handoffs/)

“Un workspace partage qui grossit sans controle devient rapidement une source de bruit — et finit par nuire a la qualite de contexte de tous les agents.”

6. Recherche semantique en memoire

Apres 6 mois de production, un reseau de 15 agents peut generer plusieurs milliers de fichiers. Deux niveaux de recherche disponibles dans OpenClaw :

Recherche textuelle

```
grep -r "mot-cle" memory/
```

Efficace pour retrouver des occurrences exactes ou des identifiants connus.

Recherche semantique

Via des requetes langage naturel sur les daily notes. L'agent lit les fichiers les plus pertinents et synthetise. Cette approche consomme des tokens — elle est reservee aux recherches importantes.

Pratiques pour garder les notes recherchables

- Toujours inclure des identifiants explicites (noms propres, identifiants systeme, URLs)
- Structurer les entrees avec des en-tetes coherents (## Decision, ## Erreur, ## Regle)
- Maintenir un index sommaire mensuel avec les decisions cles
- Pour les decisions critiques : dupliquer dans MEMORY.md avec reference vers la daily note source

7. A l'echelle : 15 agents, 6 mois de memoire

Les defis concrets rencontres par BOTUM a cette echelle :

Volume

15 agents x 6 mois = potentiellement 2 700 fichiers de daily notes. Le volume depasse rapidement la capacite de supervision humaine directe.

Degradation de la qualite

Sans entretien actif, MEMORY.md accumule des regles obsoletes, des informations contradictoires, des references a des projets termines.

Protocoles BOTUM

- Agent systeme dedie a la memoire (JARVIS) : audit hebdomadaire, compactions, resolution de conflits
- Regles de contribution : seul l'agent systeme peut modifier MEMORY.md directement
- Archivage des daily notes apres 90 jours hors du workspace actif
- Monitoring de la taille : cron journalier avec alerte si MEMORY.md depasse le seuil

8. Anti-patterns a eviter

Anti-pattern 1 : Tout mettre dans MEMORY.md

Un MEMORY.md de 20 000 tokens est un probleme de contexte permanent. Il prend de la place dans chaque session et dilue la pertinence des informations importantes.

Anti-pattern 2 : Ne jamais compacter

Les daily notes s'accumulent indefiniment. Sans compaction periodique, l'archive grossit, les recherches deviennent couteuses et la memoire long-terme reste prisonniere de la granularite brute des logs.

Anti-pattern 3 : Confondre contexte et memoire

Le contexte actif n'est pas de la memoire. Injecter massivement des fichiers dans le contexte ne remplace pas une architecture de memoire bien concue — et surcharge la fenetre de tokens inutilement.

Conclusion

La memoire agent n'est pas une fonctionnalite — c'est une infrastructure. Elle se concoit, se deploie, se maintient. Elle degrade si on ne l'entretient pas. Elle scale si on anticipe ses contraintes.

L'architecture MEMORY.md + daily notes + compactions periodiques a ete validee par BOTUM en production sur 6 mois et plus de 50 000 echanges d'agents. Simple a comprendre, robuste a l'usage.

Billet 10 : OpenClaw et les bases de donnees — comment brancher des agents sur PostgreSQL, SQLite et des APIs structurees.

Article complet : blog.botum.ca/openclaw-memoire-contexte-memory-md-compactions-long-terme

Site web : www.botum.ca • contact@botum.ca