

Pipeline RAG

- [Mode deckbuilding](#)
- [Flux d'ingestion \(PDF → Qdrant\)](#)
- [Flux d'une question \(RAG complet\)](#)
- [Pause / reprise après quota Claude](#)
- [Vision inline \(Claude lit les PNG au moment Q\)](#)

Mode deckbuilding

Mode deckbuilding

📅 Dernière mise à jour : 2026-05-10

Depuis 2026-04-24 (Axe 2 Phase 1), un 4e intent `'deckbuilding'` s'ajoute à `'rules' | 'synergy' | 'meta'`. Il déclenche un pipeline dédié pour produire des **decklists structurées exécutables** (60 cartes MTG, 40+12+3 Riftbound, 60+sideboard FAB) là où le RAG classique produisait de la prose d'analyse.

Flux (

`src/services/rag/deckbuilding/)`

1. Classification (`classify.ts`)

Haiku retourne `'deckbuilding'` quand la question exige une **liste exhaustive avec un nombre de cartes précis** ("decklist complète", "40 + 12 runes", "avec sideboard").

À distinguer de `synergy` qui reste une discussion d'archétype en prose.

Ordre de priorité : `deckbuilding > meta > synergy > rules`.

2. Dispatch (`answer.ts`)

Early-return vers `askDeckbuilding()` juste après résolution de l'intent. Le retrieval standard est jeté, `askDeckbuilding` relance son propre retrieval avec `intent='synergy'` forcé.

3. Spec Haiku (`deckbuilding/spec.ts`)

Un appel Haiku produit un `DeckSpec` (Zod) structuré :

- format
- tailles (mainboard, sideboard, runes, battlefields, equipment)
- max copies (généralement 4 MTG, 3 Riftbound, etc.)
- rôles cibles (`creatures`, `spells`, `lands`, `equipment` ...)
- anchor cards (cartes obligatoires)

Fallback defaults par jeu si Haiku renvoie un JSON invalide :

- MTG Standard : `60 + 15, max 4`
- Riftbound : `40 + 0 + 3 + 12r + 3bf`
- FAB CC : `60 + 0, max 3`

4. Anchor cards

Les fresh + sticky mentions (@-cartes de l'Axe 1) deviennent **obligatoires** dans la decklist. Le prompt Opus a une règle stricte « tu DOIS inclure ces cartes ». Log warning serveur si une anchor est absente de la réponse finale.

5. Retrieval synergy

`retrieveChunks()` est appelé avec `intent='synergy'` → déclenche l'expansion mécanique (`retrieve/synergy-expansion.ts`). `retrieveChunks` accepte `'deckbuilding'` mais le mappe vers `'synergy'` en interne (fallback safe).

6. Prompt Opus spécialisé (`prompt-deckbuilding.ts`)

`DECKBUILDING_SYSTEM_PROMPT` impose :

- total exact par section
- max copies non-basiques (basic lands FR/EN whitelists)
- anchor cards obligatoires
- pool strict (uniquement cartes du contexte)
- format markdown par rôles : `### Créatures (24) + 4× [[card:Nom]]`

7. userPrompt assemblage

Ordre des blocs :

1. `SPEC DU DECK` (JSON Haiku)
2. `CARTES OBLIGATOIRES (ANCHORS)` (anchors fresh + sticky)
3. `CARTES CITÉES PAR LE JOUEUR (ce tour)` (full)
4. `CARTES ÉVOQUÉES DANS LA CONVERSATION` (sticky abrégées)
5. `DECKLISTS DE TOURNOI` (mainboard + sideboard complets, jusqu'à 5)
6. `POOL DE CARTES ÉLIGIBLES` (organisé par rôle, cap 30 par rôle)
7. `CARTES CANDIDATES` (chunks `[CARD]` + `[META]`, pas `[BASE]` / `[EXT]`)

8. Génération Opus

`promptStream(DECKBUILDING_SYSTEM_PROMPT, userPrompt, 'opus')` streamé. Post-processing : `autoWrapCardMentions` + `buildWrapAliases` + enrichissement `extraCards`.

9. Pool exhaustif + decklists d'inspiration (Phase 2, 2026-04-24)

- `fetchEligibleCards()` (`deckbuilding/pool.ts`) scroll Qdrant avec filtre structurel :
 - MTG : `card_mtg_legal_formats` + post-filtre `card_mtg_color_identity ⊆ spec.colors`
 - FAB : `card_legal_heroes`
 - Riftbound : sans filtre Qdrant (collection mono-format) + post-filtre `card_domains ⊆ spec.domains`
- `fetchInspirationDecklists()` : hybrid search (dense+sparse) sur `meta_type='tournament_deck'` filtré par `meta_format` — jusqu'à 5 decklists similaires (infra : MTGTop8 pour MTG, RiftboundStats pour Riftbound, fabtcg.com pour FAB)
- `selectRoleCandidates()` : pré-filtre chaque rôle de la spec à **cap 30 par rôle**, priorité aux cartes déjà vues dans les decklists d'inspiration
- TM / Ark Nova : pas de champs structurels → retombent silencieusement sur Phase 1 (retrieval synergy seul)
- `scrollAllPoints()` accepte `opts.filter` et `opts.withVector` (défaut true — Phase 2 passe `false` pour économiser ~120 MB sur MTG 30k cartes)

10. Validation structurelle + retry auto (Phase 3, 2026-04-24)

- `parseDeckResponse()` : extrait les cartes par section (main / sideboard / runes / battlefields) via regex stricte avec `x/x/X` obligatoire — les lignes de prose ne matchent pas
- `validateDeck()` :
 - Total exact par section

- Max copies non-basiques (basic lands whitelist FR/EN : Plains/Island/Swamp/Mountain/Forest/Wastes + Plaine/Île/Marais/Montagne/Forêt)
- Anchor cards présentes (≥ 1 copie)
- Cartes inconnues du catalogue → warning non bloquant
- Si validation échoue : `formatRetryPrompt()` construit nouveau `userPrompt` listant les issues + contraintes strictes
- Opus relancé jusqu'à **2 retries** (3 tentatives max)
- Pendant retry : token séparateur visible streamé pour transparence — `done.fullAnswer` écrase le content côté frontend, l'utilisateur final voit uniquement la version corrigée
- Si après 3 tentatives la decklist reste invalide : on garde la dernière + warning log serveur (pas d'échec total)

11. Frontend

Aucun changement. Le rendu markdown gère titres + listes + `Nx [[card:X]]` (texte standard). `CardZoomModal` fonctionne automatiquement.

Hors scope Phases 1/2/3

- Pas de composant `<DeckListView>`
- Pas d'export `.dec` ni bouton Copier
- Pas de badge de validation côté frontend (verdict logué serveur, pas exposé via `done`)
- Pas de support TM / Ark Nova (pas d'équivalent format/archétype dans leurs données)

Helpers exportés

`autoWrapCardMentions`, `buildWrapAliases`, `renderFullCard`, `renderShortCard` sont exportés depuis `answer.ts` pour réutilisation par `deckbuilding/ask.ts`.

Flux d'ingestion (PDF → Qdrant)

Flux d'ingestion (PDF → Qdrant)

📅 Dernière mise à jour : 2026-05-10

Source de vérité : `ARCHITECTURE.md` § "Flux d'ingestion".

11 étapes

```
POST /api/games/ingest [multipart : PDF + metadata]
|
1. Upload PDF → /app/pdfs/<slug>-<timestamp>.pdf
|   ↳ Choix type : base / extension / advanced_rules / faq
|
2. Extraction texte (pdfjs-dist → RawPage[])
|
3. OCR conditionnel (services/ocr/)
|   ↳ decideOCR(rawPages) : avg chars/page < OCR_AUTO_THRESHOLD ?
|   |   ↳ disabled (OCR_ENABLED=false)
|   |   ↳ no_text (0 page texte → PDF entièrement scanné)
|   |   ↳ low_text (couche texte cassée)
|   |   ↳ sufficient (skip OCR)
|   ↳ Si shouldOCR=true :
|       ↳ pdftoppm rend chaque page en PNG 300 DPI
```

- | | | └ Pool tesseract (OCR_CONCURRENCY workers, défaut 2)
- | | | └ Langues OCR_LANGUAGES (défaut fra+eng)
- | | | └ Cache JSON ocr-v1-<slug>.json (sauvé tous les 3 pages)
- | | | └ Confiance log warn si < OCR_MIN_CONFIDENCE (40)
- | | └ Réinjection texte OCR dans pipeline normal
- |

4. Découpage sémantique (chunking/chunker.ts)

- | | └ Paragraphes + overlap, fusion intelligente
- |

5. Hierarchy LLM (hierarchy.ts)

- | | └ Claude analyse le doc complet → arbre chapter > section > sub
- | | └ Chaque chunk reçoit hierarchy_path + hierarchy_level
- |

6. Contextual Retrieval B (contextual-llm.ts)

- | | └ Pour chaque chunk : Claude reçoit DOC + hierarchy_path
- | | └ Génère 1-2 phrases de contexte
- | | └ 10 SSH parallèles (pool worker)
- | | └ Cache JSON contexts-v2-<slug>.json (reprise après crash/quota)
- | | └ Le contexte préfixe le chunk avant embedding
- |

7. Embeddings TEI bge-m3 (batch 32)

- | | └ Vecteur dense 1024 par chunk (préfixé par contexte LLM)
- |

8. Upsert Qdrant (collection rules_<slug>)

- | | └ Payload : hierarchy_path, page_start/end, is_extension, contextual_text, etc.
- |

9. Progression SSE (jusqu'à 7 actes UI)

- | | └ Lecture
- | | └ [Reconnaissance optique] ← uniquement si OCR a tourné
- | | └ Découpage
- | | └ Structuration
- | | └ Analyse contextuelle
- | | └ Compréhension (embeddings)
- | | └ Archivage
- |

10. [Optionnel, extensions seulement] Détection conflits (conflict-detect.ts)

- | | └ Pour chaque chunk extension : recherche hybride dans le jeu de base
- | | └ Si similarité > CONFLICT_SIMILARITY_THRESHOLD (0.65) :
 - | | | └ Claude SSH (CONFLICT_MODEL) classifie : replaces / modifies / extends

```
|   ├── 10 SSH parallèles
|   ├── Cache JSON conflicts-v1-<slug>.json
|   └── Annotations stockées dans payload Qdrant
|       (conflict_type, conflict_base_chunk_id, conflict_summary, conflict_base_page)
|
```

11. Rendu PNG des pages (non-fatal)

```
|   ├── pdftoppm 300 DPI → /app/pdfs/images/<slug>/page-XX.png
|   ├── Idempotent : skip si déjà rendu par étape 3 (OCR)
|   └── Échec → logger.warn, ingestion reste valide
```

Patterns importants

- **Coordinator + stages** : `services/ingest/coordinator.ts` orchestre, chaque stage est un fichier dans `stages/` avec signature `(game, ..., push: EventPusher) => Promise<...>`.
- **Erreurs non-fatales** : try/catch local dans le stage ou autour de l'appel dans le coordinator (cas de `renderPdfPages`).
- **Reprise après quota** : tous les stages SSH parallèles flushent le cache JSON avant de propager `ClaudeQuotaError`. Le coordinator transforme l'erreur en `ingestStatus='scheduled'` + `scheduleIngestStart(gameId, retryAt)` (pas `'error'`).
- **Auto-OCR transparent** : pas de toggle UI. Si `OCR_ENABLED=true` (défaut) et seuil dépassé, l'OCR tourne. L'acte "Reconnaissance optique" n'apparaît dans l'UI que si l'OCR a effectivement tourné.

Ingestion planifiée

`scheduled_start_at` (ISO, max +7 jours) dans le POST :

1. Ligne `games` créée avec `ingestStatus='scheduled'` + `ingestScheduledAt`
2. PDF écrit sur disque
3. `setTimeout` armé dans `cron/ingest-scheduler.ts`
4. Au boot : `restoreScheduledOnBoot()` re-programme tous les timers en attente
5. Si date passée pendant downtime → start immédiat avec grace 1s

`DELETE /api/games/:id/scheduled` annule (clear timer + supprime PDF + supprime ligne). 409 si pas en `scheduled`.

Forums BGG (cron quotidien)

Si `BGG_FORUM_SYNC_ENABLED=true` :

1. Cron à `BGG_FORUM_SYNC_HOUR` (défaut 3h)
2. Pour chaque jeu avec `bgg_id` en BDD :
 - `getBggForumList()` trouve le forum "Rules"
 - `getBggForumThreads()` récupère threads (max 3 pages = ~150)
 - Pour chaque thread : articles concaténés (~2000 chars max)
 - Embed (dense + sparse) + upsert dans `rules_<slug>` avec `is_forum_chunk: true`
3. Rate-limit : 5s entre appels BGG

Chunks forum identifiés par `is_forum_chunk: true` + tag `[FORUM]` dans le contexte RAG. Pas de page (`page_start: 0, page_end: 0`).

Filtrage par intent (depuis 2026-04-26) : chunks `is_forum_chunk=true` exclus quand `intent ∈ {synergy, deckbuilding, meta}`. Les forums sont conçus pour clarifier des règles, pas pour discuter deckbuilding.

Flux d'une question (RAG complet)

Flux d'une question (RAG complet)

📅 Dernière mise à jour : 2026-05-10

Source de vérité : `ARCHITECTURE.md` § "Flux principal (question)". Cette page reformule pour vue rapide.

9 étapes

```
POST /api/ask/stream { gameId, question, extensions, history, cardMentions, stickyCardMentions
}
|
1. Validation Zod (askStreamSchema) – UUID, question ≤500 chars, history ≤5
|
2. Résolution extensions (IDs → noms via gamesRepo.getById)
|
3. Résolution cartes @-citées (resolveMentions) – fresh + sticky
|
4. Classification question (classify.ts via Haiku, en parallèle du retrieval)
  └─ Output: 'rules' | 'synergy' | 'meta' | 'deckbuilding'
    └─ Si timeout → fallback 'rules'
|
5. RETRIEVAL (orchestrator.ts retrieveChunks)
```

```

|
|─ Étape 0 – Embeddings question
|   |─ Question brute → TEI bge-m3 (1024 dense)
|   |─ HyDE → Haiku passage hypothétique → TEI bge-m3
|       (timeout 25s, fallback : query brute seule)
|
|─ Étape 1 – Recherches hybrides parallèles
|   |─ Pour chaque collection (base + extensions cochées) :
|   |   |─ Dense bge-m3 (cosine)
|   |   |─ Sparse BM25 natif Qdrant (keyword match)
|   |   |
|   |   |─ Fusion RRF v2 (RAG_FUSION_V2_ENABLED)
|   |   |   |─ Score =  $2/(rank\_dense+2) + 1/(rank\_bm25+2)$  ← question×2 vs HyDE×1
|   |   |   |─ Top-rank bonus : +0.05 si rank=0, +0.02 si rank ∈ {1,2}
|   |   |   |─ Dedup par pointId
|   |   |
|   |   |─ [Si intent=meta] meta-retrieval
|   |   |   |─ Recherche chunks 17Lands / MTGGoldfish / etc. (filter meta_format)
|   |   |
|   |   |─ [Si MTG/FAB/Riftbound] synergy-expansion
|   |   |   |─ decompose-query (Haiku) → JSON {couleurs, format, types, themes}
|   |   |   |─ Filters Qdrant natifs (payload matching)
|   |   |   |─ Multi-query TCG (synonymes/variantes)
|   |   |   |─ set-matcher : "Strixhaven" → "STX"
|   |
|─ Étape 2 – Reranking cross-encoder (bge-reranker-v2-m3)
|   |─ Re-classe top-50 candidats RRF
|   |─ Blending position-aware
|       |─ Top 1-3 : 75% RRF + 25% rerank (préserve exact-match)
|       |─ Top 4-10 : 60/40
|       |─ Top 11+ : 40/60

```

6. Enrichissement contexte (answer.ts)

```

|─ BGG metadata (mechanics, categories) si dispo
|─ Image PNG : 1 page max (resolvePageImageFile)
|   |─ Granularité (livret, page) – pas seulement page
|─ Cartes @-mentionnées (bloc CARTES CITÉES PAR LE JOUEUR (ce tour))
|─ Sticky cards (bloc CARTES ÉVOQUÉES DANS LA CONVERSATION, format abrégé ~100 tokens)
|─ Historique (≤5 turns)

```

```

|
7. Génération réponse Claude (claude-ssh.ts promptStream)
|   └─ Construction userPrompt (chunks + cartes + image + historique)
|   └─ SSH oracle@VM : claude -p --append-system-prompt ... --output-format stream-json
|       └─ ▲ --append (pas --system-prompt) : préserve le contrat outils (Read, etc.)
|   └─ withTimeout HYDE_TIMEOUT_MS, fallback Haiku/Opus
|       └─ Stream JSON verbose → yield tokens (event.type='assistant')
|
8. Événements SSE streamés au client
|   └─ meta – questionId (1er event, pour fallback polling)
|   └─ phase – "L'Oracle pèse votre question", "plonge dans le grimoire", etc.
|   └─ context – chunks retrouvés + scores + mentionedCards + stickyMentionedCards
|   └─ token – streaming réponse
|   └─ heartbeat – toutes les 8s (anti idle-timeout NPM)
|   └─ diagnostics – {chunks, hyde, timings, bestScore}
|       └─ done – {fullAnswer, questionId, bestScore}
|
9. Persistance (questionsRepo.updateAnswer)
|   └─ {answer, bestScore, diagnostics}

```

Optimisations notables

- **Parallélisation Qdrant** (commit `95229af`) : dense + sparse en parallèle, pas séquentiel
- `withTimeout` **partout** (8 sites) : évite blocages de boot et de RAG
- **Fusion RRF v2** : pondération question brute ×2, blending position-aware (cf. ADR-005)
- **Sticky mentions** : maîtrise tokens sur multi-tours (cap FIFO 20 / 80 si deck)
- **Vision 1 image max** : ~30s par image lue par Claude — passer à 2-3 doublait la latence pour gain marginal

Fallback connexion SSE

Si la connexion SSE casse mais qu'on a déjà reçu `meta.questionId` :

1. Le frontend bascule sur polling `GET /api/ask/:questionId` (3s × 15 = 45s max)
2. La réponse est récupérée depuis la BDD telle qu'elle a été persistée
3. L'UI affiche "L'Oracle finalise hors-ligne..." pendant la récupération
4. Si rien après 45s, erreur user-visible

Pattern réutilisable pour tout endpoint streamSSE : exposer `GET /api/<resource>/:id` retournant 200 (prêt) / 202 (pending) / 404.

Pause / reprise après quota Claude

Pause / reprise après quota Claude

“ Dernière mise à jour : 2026-05-10

Le compte Claude utilisé par la VM oracle a un quota Pro/Team (fenêtre 5h glissante). Quand il sature, on veut **mettre en pause les jobs en cours** et **reprendre auto** à l'heure de reset, sans perdre le travail déjà fait.

Détection (`services/claude-quota.ts`)

Le service parse la sortie du CLI Claude pour détecter le message de quota.

Marqueurs supportés

```
QUOTA_MARKERS = [  
  'usage limit reached',  
  "you've hit",  
  'hit your usage limit',  
  'hit your session',  
  'rate limit reached',  
  // ...
```

⚠ Le scan se fait sur **toute** la sortie du CLI, **même quand Claude a émis du texte assistant** — certaines versions du CLI renvoient le message de quota comme une réponse assistant normale au lieu d'exiter en erreur.

Patterns d'extraction de l'heure de reset

Par ordre de priorité :

1. `|<unix_seconds>` — timestamp Unix direct (le plus fiable)
2. `reset at HH:MM AM/PM` (12h)
3. `resets at HH:MM AM/PM`
4. `try again at HH:MM AM/PM`
5. `available again at HH:MM AM/PM`
6. `reset at HH:MM` (24h, sans AM/PM)
7. **Fallback** : `+1h` si rien ne match

→ `ClaudeQuotaError` avec champ `resetAt: Date`.

Pattern à respecter partout où Claude est appelé pendant un job long

Émetteurs (`claude-ssh.ts`, `claude-local.ts`)

En fin de stream, si rien n'a été généré, appeler `throwIfQuota(stderr + streamOutput)` **avant** de yield l'erreur générique. Sinon le quota se transforme en "answer empty" silencieux.

Workers parallèles (pool SSH)

Pour `contextual-llm.ts`, `conflict-detect.ts`, etc. :

```

let quotaError: ClaudeQuotaError | null = null;

while (todoIndex < todo.length && !quotaError) {
  const task = todo[todoIndex++];
  try {
    await processTask(task);
  } catch (err) {
    if (err instanceof ClaudeQuotaError) {
      quotaError = err;
      return; // sans compter l'échec comme un fallback
              // (le chunk n'est pas en cache, sera retenté à la reprise)
    }
    throw err; // autres erreurs : propagation normale
  }
}

await Promise.all(workers);
saveCache(...); // ⚠️ TOUJOURS flusher AVANT de throw
if (quotaError) throw quotaError;

```

L'ordre `flush THEN throw` est critique : si on throw avant le flush, la reprise repart des derniers ~20 chunks au lieu de pile où on s'est arrêté.

Coordinator (`ingest/coordinator.ts`)

Dans le `catch` global :

```

catch (err) {
  if (err instanceof ClaudeQuotaError) {
    const resetAt = err.resetAt;
    const retryAt = new Date(resetAt.getTime() + 2 * 60 * 1000); // grace 2 min

    await gamesRepo.update(gameId, {
      ingestStatus: 'scheduled',
      ingestScheduledAt: retryAt.toISOString(),
    });

    scheduleIngestStart(gameId, retryAt);
  }
}

```



```
push('quota_pause', { resetAt, retryAt });

// ⚠ NE PAS passer le jeu en 'error' – ce n'est pas un échec, juste une pause
return;
}
// ...erreur générique
}
```

Frontend

L'event SSE `quota_pause` bascule le wizard d'ingestion sur le panneau `step === 'scheduled'` avec `reason: 'quota'` (au lieu de `'user'` pour la planification volontaire). La copie est dédiée :

“L'oracle se repose. Reprise prévue à HH:MM.”

L'utilisateur n'a rien à faire — le scheduler relance automatiquement.

Ajouter un nouveau marker

Si Claude change le wording du message de quota et que la détection rate :

1. Vérifier les logs serveur (`/app/data/logs/server.log`) pour voir le wording exact
2. Étendre `QUOTA_MARKERS` dans `claude-quota.ts`
3. Si le format de l'heure change, étendre aussi `detectQuotaResetTime` (les patterns regex)
4. Ajouter un test unitaire dans `claude-quota.test.ts` (ce service a déjà des tests pour les patterns existants)

Pas dans `'error'`, jamais

Le quota n'est pas un échec applicatif : c'est une pause normale prévue. Toute logique downstream (UI, monitoring, alerting) doit traiter `'scheduled' + reason='quota' ≠ 'error'`.

Vision inline (Claude lit les PNG au moment Q)

Vision inline (Claude lit les PNG au moment Q)

“ Dernière mise à jour : 2026-05-10

Depuis 2026-04-11, la vision n'est **plus** un pipeline d'ingestion. Claude reçoit les images PNG **directement au moment de la question**, uniquement pour la page la plus pertinente du retrieval, via son outil `Read` côté VM SSH.

Zéro appel LLM vision à l'ingestion. Zéro description intermédiaire textuelle. Zéro cache d'image légendée.

Flux côté `answer.ts`

1. **Group by** `(livret, page)` : après `retrieveChunks()`, group les chunks non-forum par clé composite `(gameName, pageStart)`. Garde le meilleur score par clé.
⚠ **La granularité doit être** `(livret, page)` **et pas seulement** `page` : le retrieval mélange des chunks venant de plusieurs livrets (base + extension + ADV + FAQ), chacun dans son propre dossier PNG (`/app/pdfs/images/<slug>/`). La page 4 de HEAT et la page 4 de Heavy Rain sont deux images distinctes — grouper par page seule renvoie la mauvaise image.
2. **Sélection** : la meilleure paire `(livret, page)` par score est retenue (`MAX_INJECTED_IMAGES = 1`).
Pourquoi 1 et pas 3 : chaque image coûte ~20-30s de lecture côté Claude (Read tool sur PNG 300 DPI). Passer à 2-3 doublait/triplait la latence pour un gain marginal.
3. **Résolution du fichier** (`resolvePageImageFile()` dans `pdf-images.ts`) :

- `pdftoppm` produit un padding variable (`page-1.png` / `page-01.png` / `page-001.png` selon le total de pages)
 - Le helper lit le dossier une fois et cache `{pageNumber → filename}`
 - Cache invalidé dans `renderPdfPages` quand un nouveau rendu est lancé
4. **Injection dans le userPrompt** : sous un bloc "IMAGES DES RÈGLES", préfixé par le nom du livret pour que Claude sache quel livret il ouvre :

IMAGES DES RÈGLES :

- Heavy Rain, page 4 : `/projet/boardgame-pdfs/heavy-rain/page-04.png`

5. **Instruction SYSTEM_PROMPT** (règle 9) : Claude ouvre l'image avec son outil `Read` **uniquement** quand la question a une dimension visuelle (icônes, couleurs, symboles, schémas, plateau, tuiles...). Sinon il ignore l'image.



--append-system-prompt (PAS --system-prompt)

`claude-ssh.ts` lance Claude Code CLI avec `--append-system-prompt` et **pas** `--system-prompt`. C'est critique :

- `--system-prompt` **remplace** le system prompt par défaut de Claude Code, qui contient le contrat d'utilisation des outils (`Read`, `Bash`, etc.). Sans ce contrat, Claude garde ses outils techniquement disponibles mais n'en invoque plus aucun proactivement, et finit par halluciner une description à partir du texte seul.
- `--append-system-prompt` ajoute notre `SYSTEM_PROMPT` Oracle **par-dessus** le contrat par défaut. Donc Claude voit les chemins PNG et les ouvre réellement.

C'est un piège facile à reproduire — toujours `--append`.

Volume PNG

- Côté container backend : `/app/pdfs/images/<slug>/page-XX.png`
- Côté VM oracle : monté en read-only sous `/projet/boardgame-pdfs/<slug>/page-XX.png` (chemin contrôlé par `VISION_SSH_IMAGES_PATH`, défaut `/projet/boardgame-pdfs`)
- Le `settings.json` oracle (`/home/oracle/.claude/settings.json`) doit avoir ce chemin dans `permissions.additionalDirectories` ET dans `permissions.allow` pour que Claude puisse `Read`.

Frontend : pas de viewer PNG côté user

Le clic sur une citation `[HEAT, p.4 : "..."]` ouvre toujours **le PDF** (pas le PNG) à la bonne page via `PdfCitationViewer`. Le PNG existe uniquement pour Claude côté backend.