Cette 3ème séquence présente les techniques de gestion de données que l'on peut embarquer dans de petits dispositifs intelligents, comme des capteurs du matériel de quantified self ou des petits objets sécurisés, disséminés dans l'environnement de l'utilisateur.
Ces techniques sont sous-jacentes aux architectures privacy by design qu'on va souhaiter implanter.

C'est une architecture qui va chercher à respecter la vie privée dès la conception. Première remarque, il **ne s'agit pas d'une architecture qui permet aux individus de cacher des secrets**.

Le privacy by design a plutôt pour but, de permettre aux individus de contrôler leurs données personnelles, depuis la collecte, jusqu'à l'usage et au partage qui en sera fait. Il s'agit aussi de se prémunir par construction de tous les usages cachés ou réalisés sans le consentement de l'individu concerné.

Comment faire ?
Il faut **réguler le cycle de vie des données de bout en bout**, depuis les sources de données jusqu'au cloud.

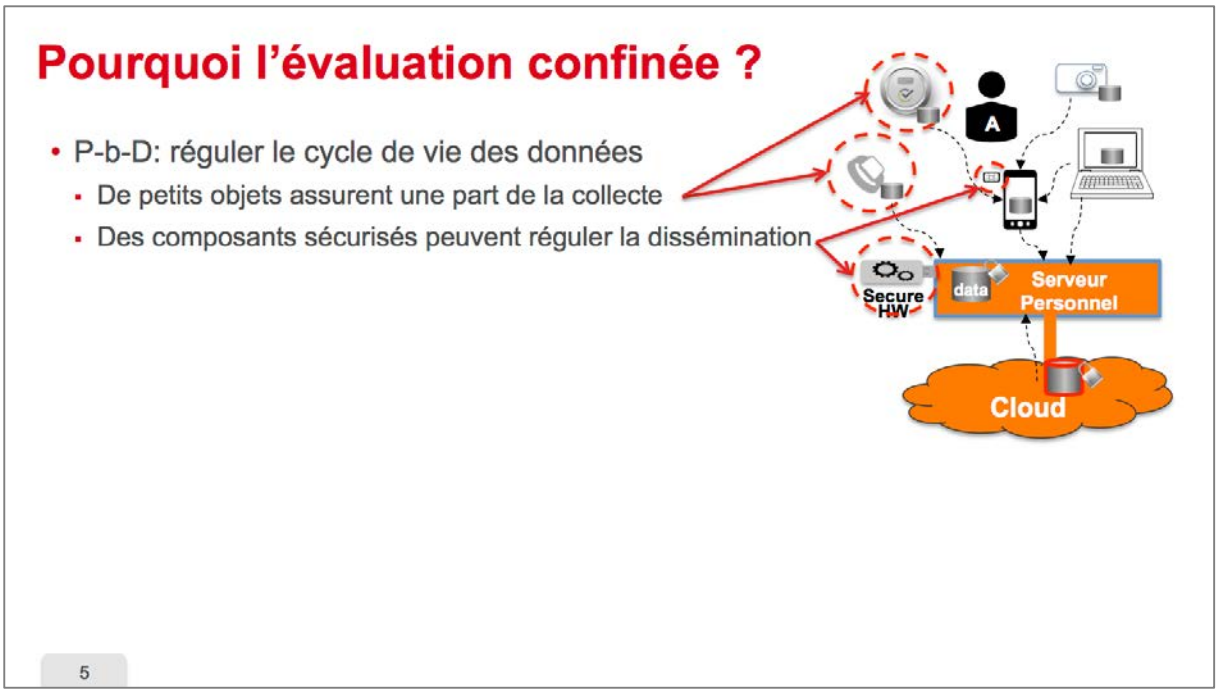

Ces techniques aident à réguler la dissémination de données :

- depuis les petits objets intelligents qui vont en assurer la collecte, les capteurs,
- depuis les petits objets sécurisés qui vont permettre d'en assurer la dissémination en offrant à l'individu des garanties de non-contournement.

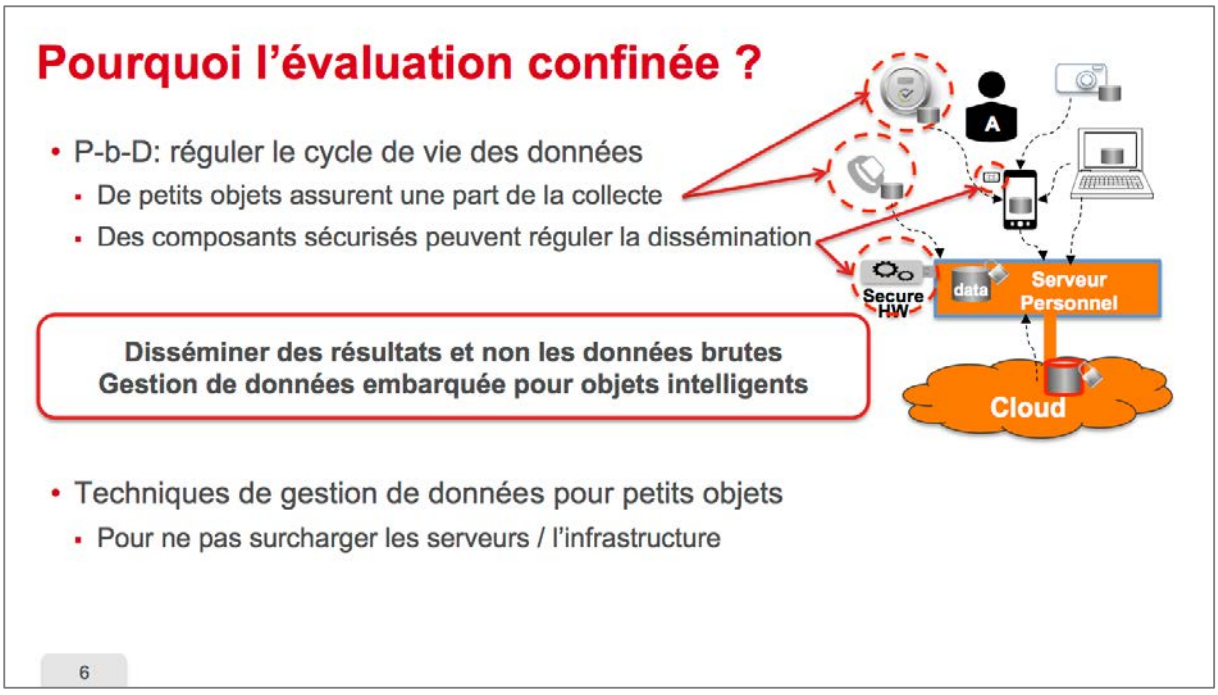

Ces objets intelligents doivent être à même, de **calculer des résultats** autorisés et de **les extraire pour les transmettre à l'extérieur** plutôt, que de transmettre systématiquement toutes les données brutes collectées.
Cela passe par l'intégration de techniques de gestion de données au sein de ces dispositifs. Il y a une littérature importante sur la question. Aussi, pour d'autres raisons. Donc en particulier, parce que dans d'autres contextes, on a aussi besoin de ne pas transmettre toutes les données collectées à l'infrastructure pour ne pas surcharger les serveurs ou les réseaux de communication.

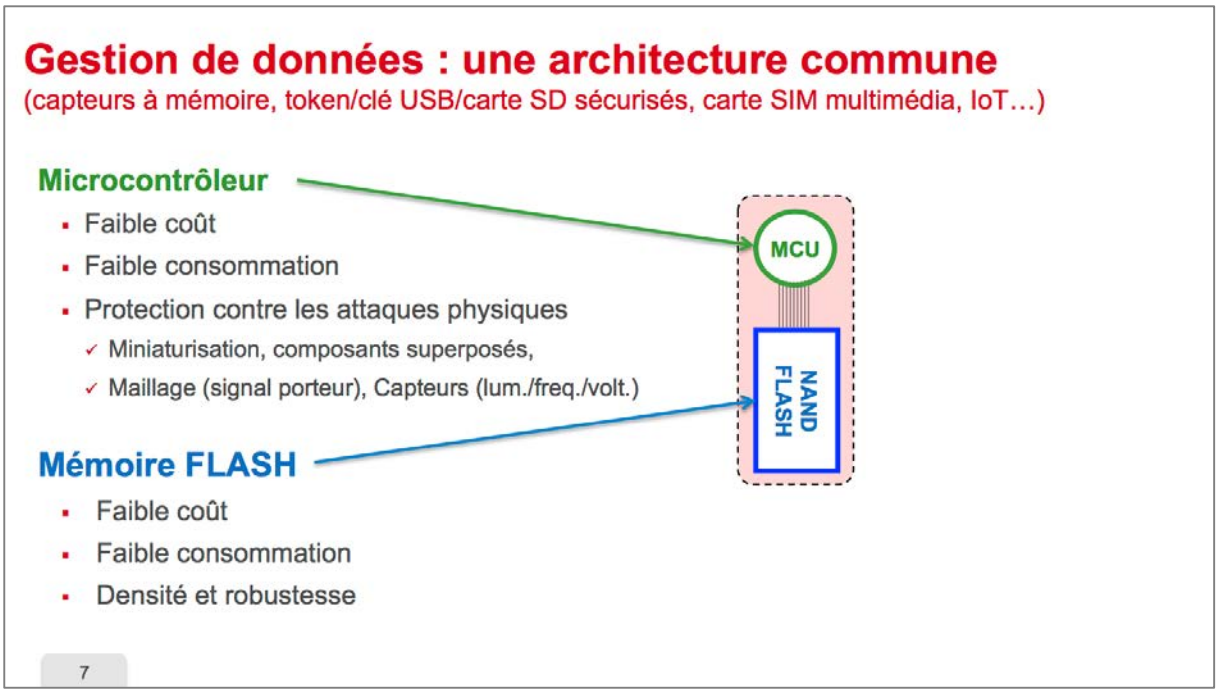

Du point de vue de la gestion de données, tous les objets intelligents partagent une même architecture qui soit petit capteur, token sécurisé, carte SIM du téléphone portable, ou carte SIM future génération à grande mémoire.
Tous disposent d'un **microcontrôleur** qui va pouvoir réaliser les traitements et d'une **mémoire de type NAND FLASH** qui assure le stockage.
Ces choix architecturaux sont liés :

- au **faible coût** et à la **faible consommation** de ces 2 composants,
- au fait que le microcontrôleur peut être protégé contre les attaques physiques dans le cas d'objets sécurisés,
- à la densité et robustesse des mémoires Flash.

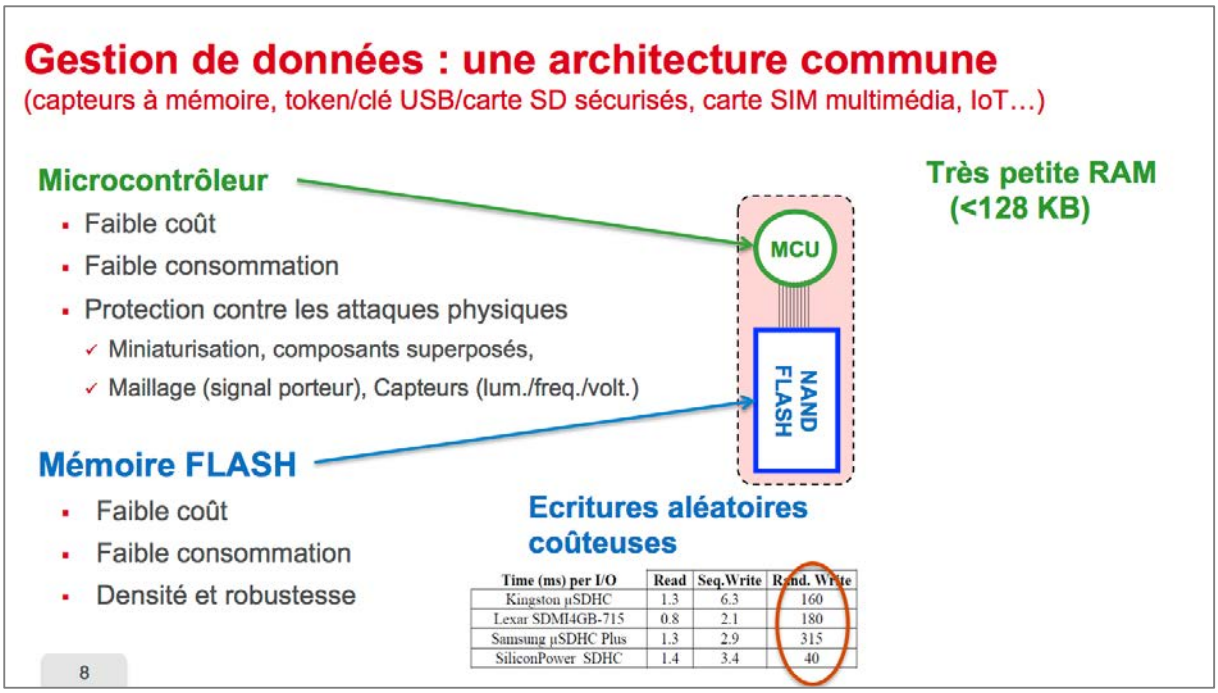

Cette architecture pose 2 contraintes techniques, qui ont un gros impact sur les techniques de gestion de données qu'on va être capable d'embarquer :

- le microcontrôleur, dispose de très, très peu de mémoire vive. Donc, quelques dizaines de ko dans la pratique.
- la mémoire flash, elle, offre des performances en écritures aléatoires, qui sont assez mauvaises. De l'ordre de la centaine de millisecondes, pour écrire quelques ko de données sur une carte SD de manière aléatoire.

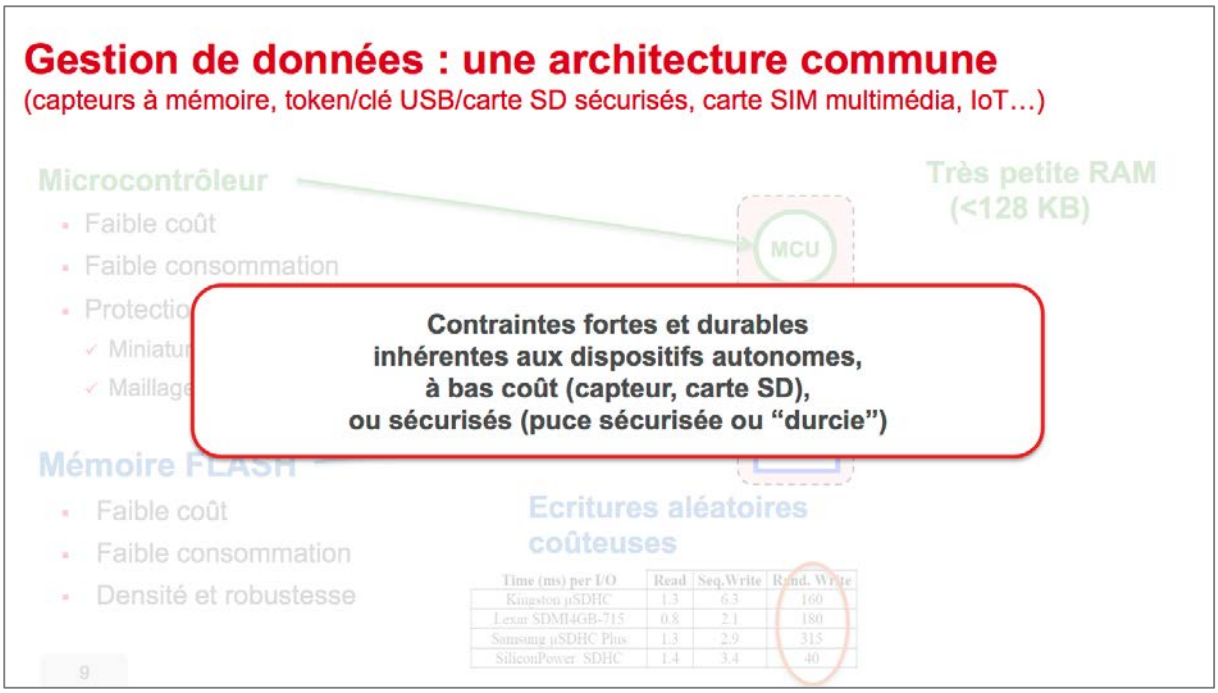

Ces contraintes sont considérées comme inhérentes à tout dispositif autonome, à très bas coût et sécurisé. Elles sont durables.
Réaliser des traitements de données dans de tels dispositifs est une tâche difficile.

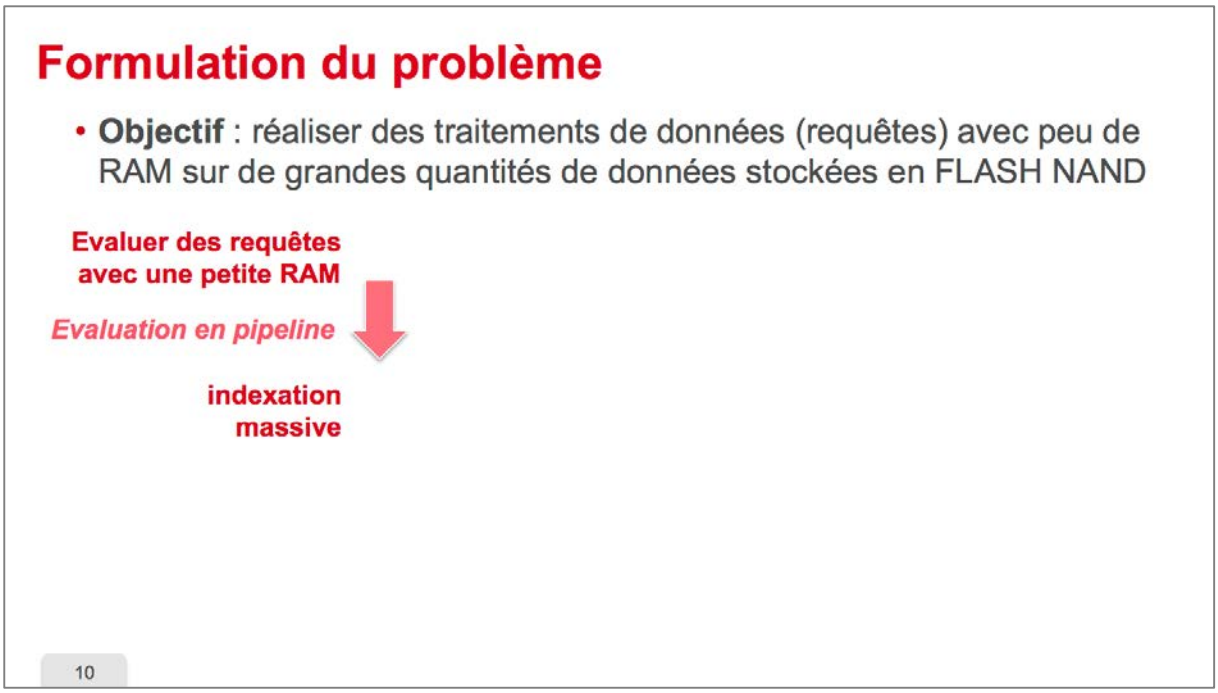

Supposons, par exemple que l'on veut calculer le résultat d'une requête avec très peu de RAM, sur de grands volumes de données stockés en mémoire flash. Que se passe-t-il ?
Première chose pour évaluer une requête avec une toute petite RAM, nous devons éviter de construire des résultats intermédiaires dans cette toute petite RAM. Cela va nous conduire à consommer les données en pipeline lors du traitement.
Pour réaliser un traitement en pipeline, il va falloir construire au préalable de très nombreux index sur les données.

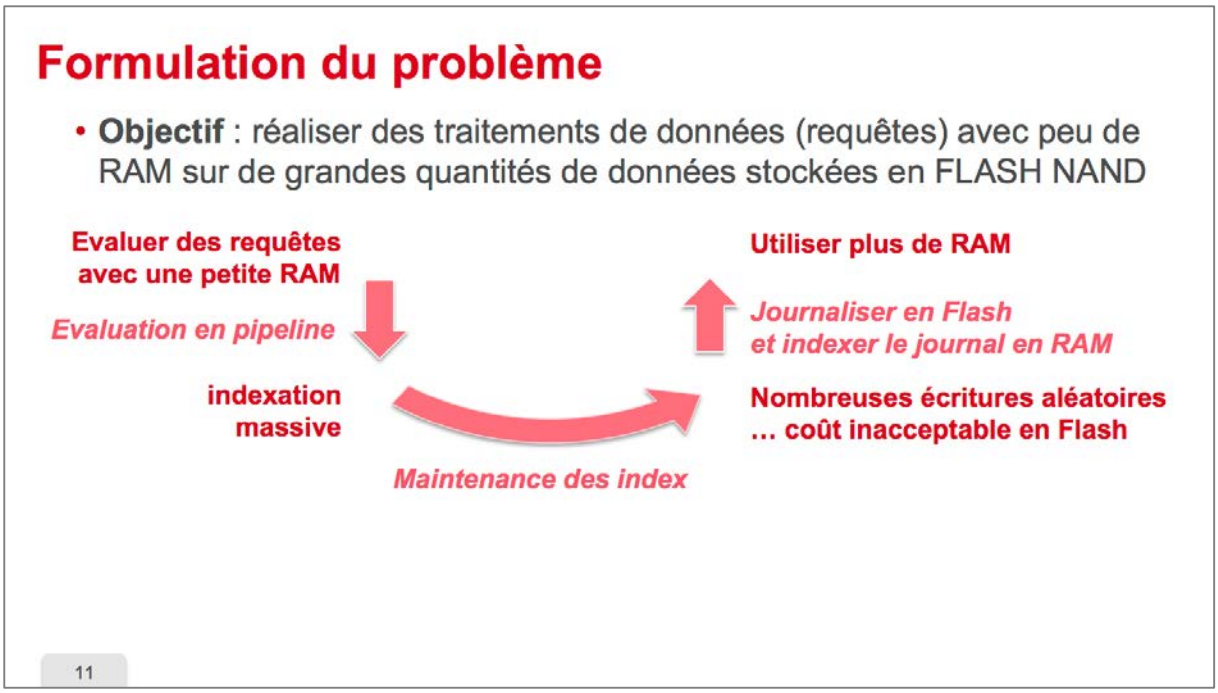

Mais maintenir ces index, au moment des insertions de nouvelles données, va générer de nombreuses écritures aléatoires dans la mémoire flash. Ces écritures aléatoires étant très coûteuses en flash, il faudrait pouvoir les compenser.

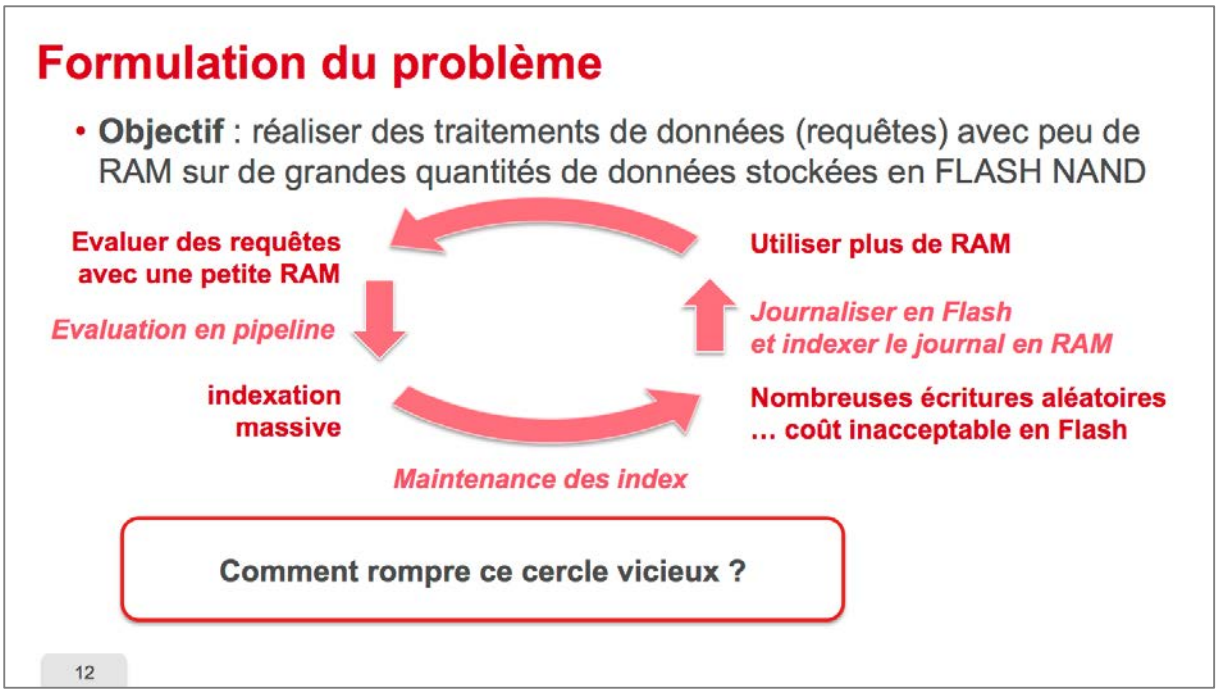

Donc, les techniques habituelles journalisent ces mises à jour et les indexent en ram. Mais tout ça nécessite bien plus de RAM.
Donc un cercle vicieux s'établit car ces contraintes sont en fait extrêmement conflictuelles.

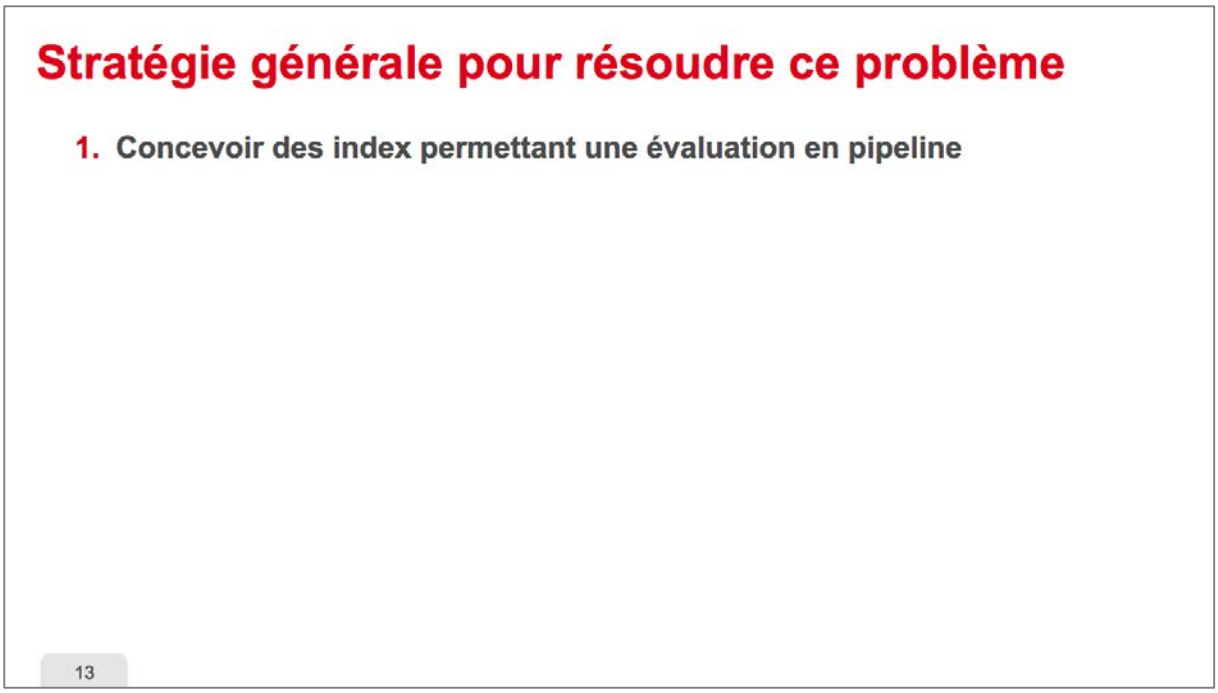

Les techniques de l'état de l'art se basent sur 3 principes pour résoudre ce problème. C'est-à-dire qu'il va falloir construire les index pour éviter de générer des résultats intermédiaires en RAM pendant l'exécution.

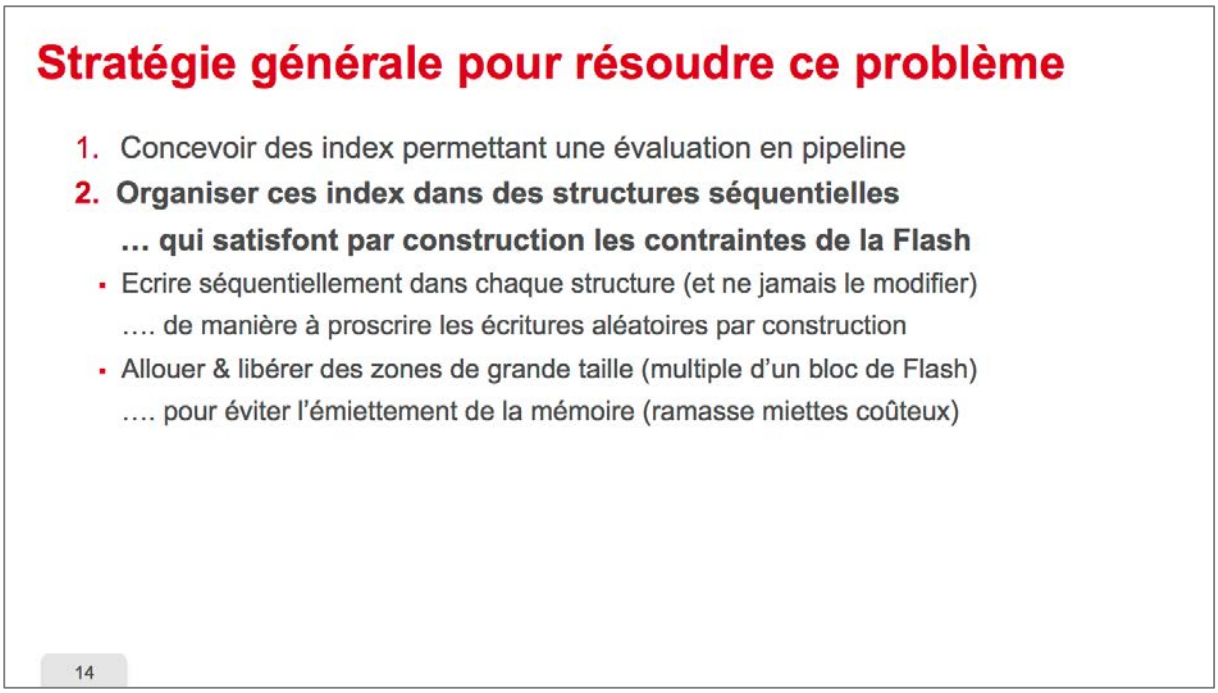

Ensuite, il faut être capable d'organiser ces index dans des structures purement séquentielles en flash dans le but d'éviter les écritures aléatoires par construction lorsqu'on va ajouter de nouvelles données. Les index construits de manière purement séquentielle, par nature, ne passent pas à l'échelle. Donc l'accès à ces index est en général linéaire, avec le volume de données indexées.

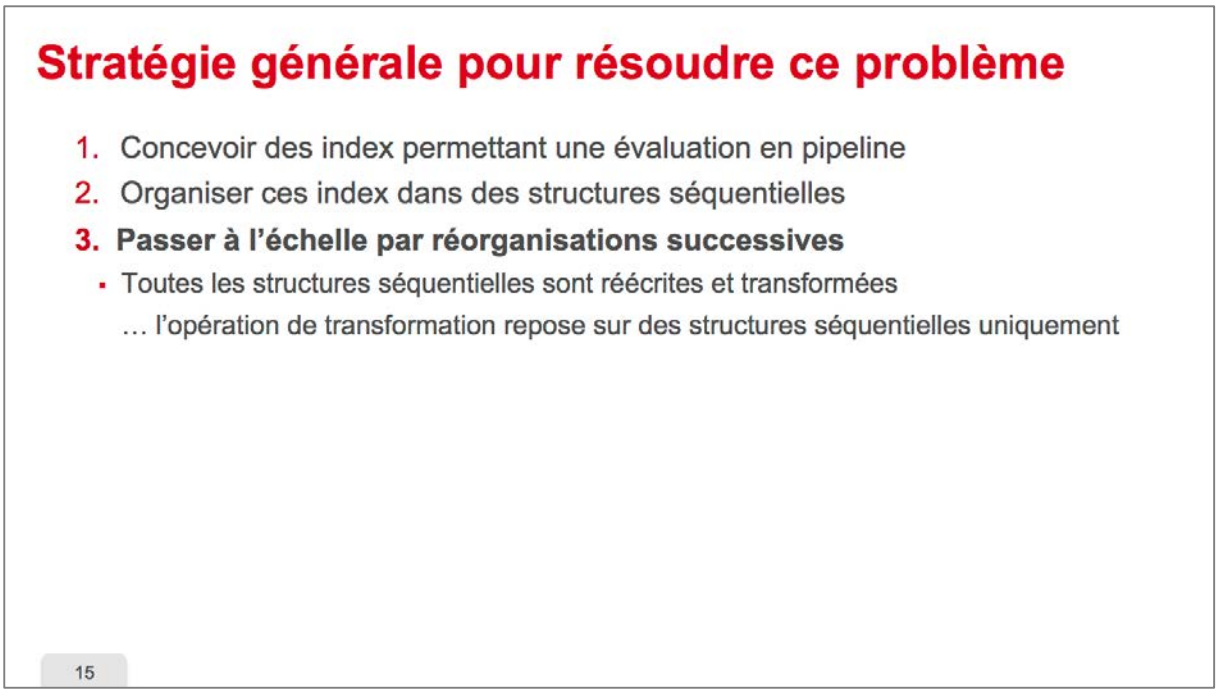

Pour passer à l'échelle, il va falloir réorganiser en tâche de fonds, ces index dans de nouvelles structures séquentielles bien plus performantes. Cette réorganisation ne devra pas non plus générer d'écriture aléatoire.

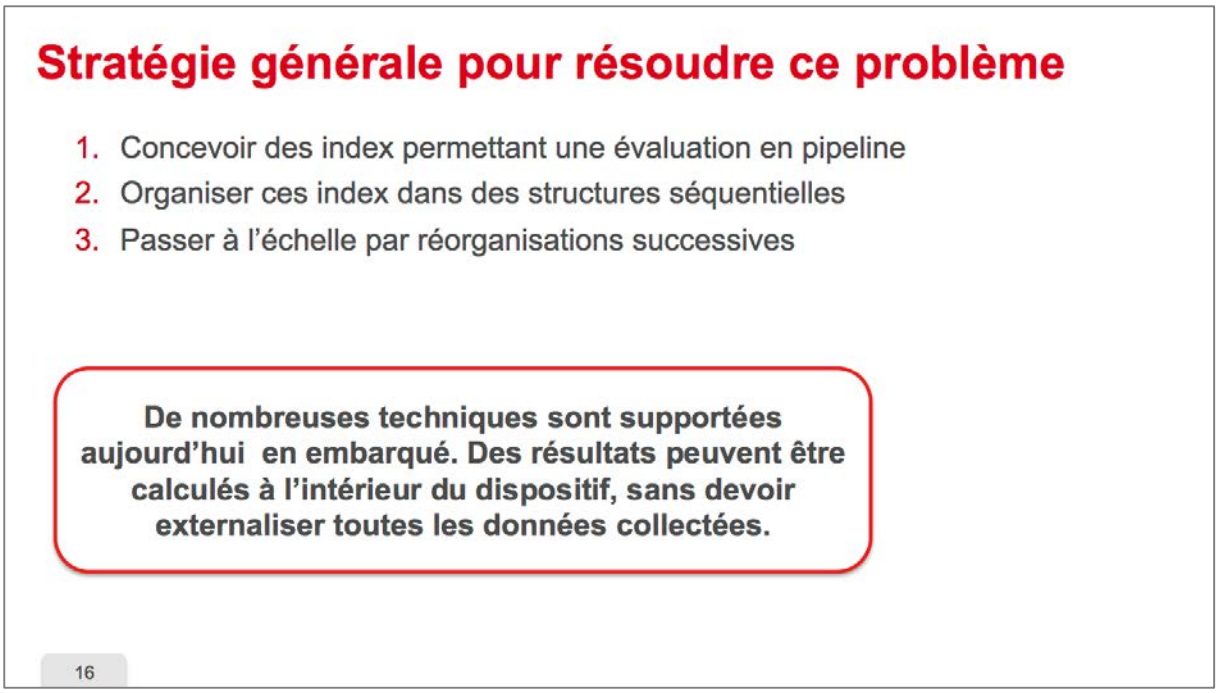

En suivant ces principes, de **nombreuses techniques de gestion de données peuvent être embarquées dans des dispositifs même extrêmement contraints**. Il est ainsi **possible de disséminer des résultats de requêtes sans devoir externaliser toutes les données de base**.

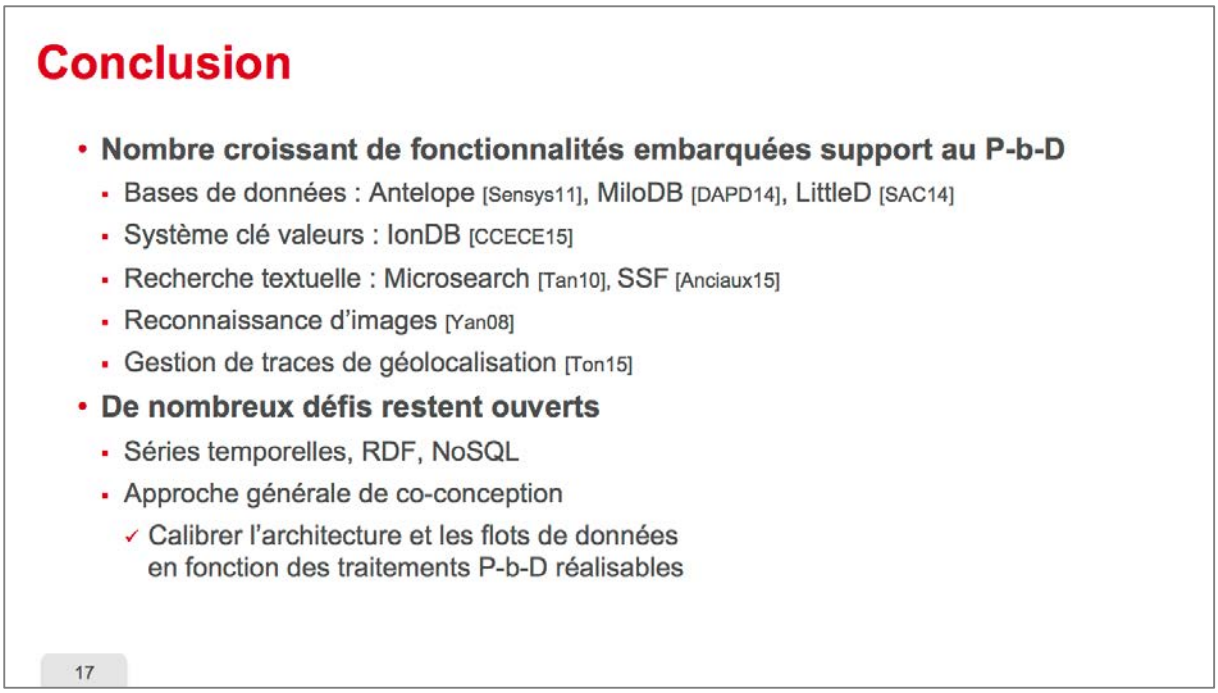

Pour conclure, il est actuellement possible d'embarquer de nombreuses techniques de gestion de données, dans des objets intelligents, même très contraints :

- Des techniques de base de données avec des prototypes comme Antelope, Milo-DB ou LittleD.
- Des systèmes de gestion de données clés valeurs, comme IonDB,
- Des moteurs de recherche textuels comme Microsearch ou SSF.
- Des processus de reconnaissance d'images,
- Gestion de traces de géolocalisation.

Bien sûr, de nombreux défis restent ouverts.
Il reste à gérer tout type de séries temporelles, des données RDF, des systèmes noSQL.
Il reste encore à concevoir une approche générale à la co-conception, c'est-à-dire qui soit capable de calibrer l'architecture, et les flots de données en fonction des traitements privacy by design qu'on va souhaiter réaliser.

Références

- [Cavoukian11] Cavoukian, A. (2011). "Privacy by Design - The 7 Foundational Principles." http://www.ipc.on.ca/images/Resources/7foundationalprinciples.pdf
- [Cavoukian12] Cavoukian, A., & Jonas, J. (2012). *Privacy by design in the age of big data*. Information and Privacy Commissioner of Ontario, Canada.
- [PlugDB] https://project.inria.fr/plugdb/
- [Tan10] Tan, C. C., Sheng, B., Wang, H., & Li, Q. (2010). Microsearch: A search engine for embedded devices used in pervasive computing. ACM Transactions on Embedded Computing Systems (TECS), 9(4).
- [Anciaux15] Anciaux, N., Lallali, S., Popa, I. S., Pucheral, P. A Scalable Search Engine for Mass Storage Smart Objects. PVLDB 8(9), 2015.
- [Anciaux14] Anciaux, N., Bouganim, L., Pucheral, P., Guo, Y., Le Folgoc, L. MiloDB: a Personal, Secure and Portable Database Machine. Distributed and Parallel Databases (DAPD), Vol. 32(1), 2014.
- [Ton15] Ton That, D. H., Popa, I. S., Zeitouni, K. TRIFL: A Generic Trajectory Index for Flash Storage. ACM Transactions on Spatial Algorithms and Systems 1(2), 2015.
- [Yan08] Yan, T., Ganesan, D., and Manmatha, R. Distributed image search in camera sensor networks. In Proc. of the 6th ACM Conference on Embedded Network Sensor Systems, SenSys'08, pp. 155–168, 2008.
- [Douglas14] Douglas, G., & Lawrence, R. (2014, March). LittleD: a SQL database for sensor nodes and embedded applications. In *Proceedings of the 29th Annual ACM Symposium on Applied Computing* (pp. 827-832). ACM.
- [CCECE15] Fazackerley, S., Huang, E., Douglas, G., Kudlac, R., & Lawrence, R. (2015, May). Key-value store implementations for Arduino microcontrollers. In *Electrical and Computer Engineering (CCECE), 2015 IEEE 28th Canadian Conference on* (pp. 158-164). IEEE. IonDB, Link: https://www.reddit.com/r/arduino/comments/34uu8r/iondb_is_a_key_value_store_for_the_arduino/