EMMANUEL COQUERY

TECHNOLOGIES DE CACHE WEB / APPLICATIF

CACHES

- Objectif: améliorer les performances
- Principe: sauvegarder le résultat d'un traitement de façon à ne pas refaire ce traitement lors de futures accès
- Utilisables à de nombreux niveaux: du cache CPU L1 au CDNs

CONCEPTS GÉNÉRAUX

- Granularité:
  - Unité d'information transmise entre le client et le cache (e.g. CPU-L1: mot)
  - Unité d'information transmise entre le cache et la mémoire de niveau supérieur (e.g. L1-L2: ligne)
- Localité:
  - Spatiale: données « proches » accédées ensemble
  - Temporelle: traitement sur une même donnée proches dans le temps
- Clé identifiant les données (e.g. adresse mémoire pour un cache physique, numéro de compte client pour un cache applicatif)

LES CACHES SONT PARTOUT

- Caches matériels: CPU, disques durs
- Caches système: fichiers
- Caches internes aux applications:
  - caches de tables/requêtes dans les SGBD
  - caches d’objets dans les ORMs
    (e.g. EntityManager en Java)
- Caches Web: (reverse)-proxys, cache navigateur, CDNs

CACHES « APPLICATIFS »

- Données résultant d'une combinaison d'accès aux données et de calculs
  - Résultats de rendu de page
    - architectures type CGI ou PHP
    - pages lourdes (gros volume, génération de HTML complexe)
  - Extraction de données complexes (e.g. profil utilisateur)
    - Requêtes multiples
    - Plusieurs sources de données à interroger

PERTINENCE DES DONNÉES EN CACHE

- Surcoûts potentiels liés au cache
  - Temps de calcul en cas défaut de cache
    - Normalement peu élevé
  - Occupation mémoire/disque
    - En général pas toutes les données en cache
    - 80/20:
      - 80% des demandes correspondent à
      - 20% des données

COHÉRENCES DES DONNÉES EN CACHE

- Modification des données de niveau supérieur
  - Invisible depuis le cache (cache statique)
  - Invalide le cache
    - e.g. supprime la donnée modifiée du cache
  - Met à jour le cache (cache dynamique)
    - write-through: en simultané avec les données de niveau supérieur
    - write-back: lors de la suppression de la donnée depuis le cache

GESTION DES MODIFICATIONS INVISIBLES DEPUIS LE CACHE

- Durée de vie associée à la donnée
  - dépend du métier
  - globale vs par type d'objet
- TTL (Time To Live) vs TTI (Time To Idle)

INVALIDATION DES DONNÉES EN CACHE

- Simple dans le cas de données atomiques / identifiées par la clé
- Complexe en cas de modification de données indirectement référencées
  - e.g. cache d'une page listant les produits correspondant à un mot clé (clé = mot) à invalider en cas de modification d'un mot clé
  - surcoût potentiel de recherche des conséquences de la modification

MISE À JOUR DU CACHE EN WRITE-THROUGH

- Même problèmes que pour l'invalidation de cache
- Rechargement des données
  - Les données seront-elles utilisées dans un temps cours (avant d'être supprimées) ?
  - Peut être moins coûteux qu'une suppression puis une réinsertion à la demande
    - si valeur modifiée disponible
    - ou si on veut éviter une latence à la prochaine lecture

POLITIQUE D'ÉVICTION

- Si pas assez de place pour ajouter une donnée dans le cache, quelle donnée supprimer ?
- Mesures classiques:
    - Most/Least Recently Used (MRU)
    - Most/Least Frequently Used (MFU)
    - Liées au TTL / TTI

INITIALISATION

- Augmentation du temps de latence si une donnée n’est pas en cache
- Sollicitation élevée de la mémoire de niveau supérieur (e.g. SGBD/serveur Web)
- Potentiellement problématique:
  - Lors de la mise en place de l’application
  - Lors d’un redémarrage
- Pré-remplissage du cache
  - En particulier en cache de redémarrage
    - Nécessite une forme de persistance

CACHE ET HTTP

- Directives de gestion du cache
  - Fraîcheur des données:
    - Cache-Control: max-age
    - Expires
  - (In)validation:
    - Last-Modified
    - ETag (tag de version)
- Pas forcément utile si le cache est dynamique
  (rmq: le cache client est en général statique)

CACHE PAR FRAGMENT

- Cache de parties de page Web
- Utile lors de la réutilisation de nombreux éléments aux sein d'une grande variété de pages
  - Personnalisations utilisateur:
    mélanges parties communes et parties personnalisées au sin d'une même page
  - Portails Web
- Assemblage possible côté serveur ou côté client

CDN: CONTENT DELIVERY NETWORKS

- Réseau de cache distribués géographiquement
- Réduction du temps de latence et augmentation du débit
- Plutôt du contenu statique (images, scripts js, fichiers lourds, etc)

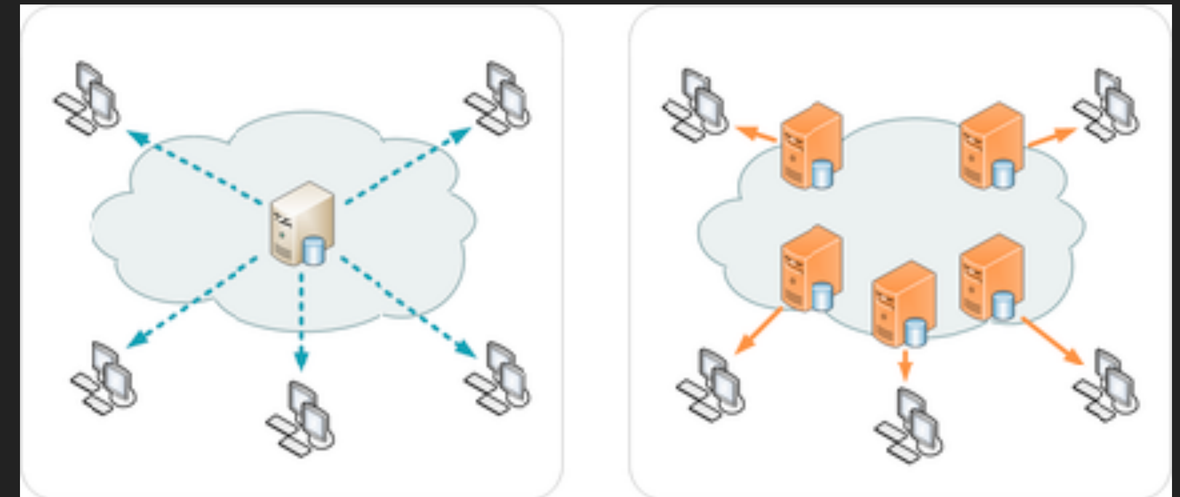

[https://en.wikipedia.org/wiki/Content_delivery_network]

CACHES ET ORM

- Cache mémoire intégré au framework
  - EntityManager en Java
- Cache de 2e niveau:
  - Au sein d'un même serveur: partagé entre les instances d'EntityManager
  - En Java: `@Cacheable` pour indiquer les entités pouvant être mises en cache
- Peut être utilisé dans des clusters, mais attention à la cohérence des caches entre machines

KV-STORES POUR LE CACHE

- Systèmes clé-valeur très utilisés pour le cache applicatif
  - Pas besoin de requêter la valeur pour du cache
- Permet de partager un cache entre des instances de serveur hébergeant le code métier
- 2 gros acteurs: Memcached et Redis

MEMCACHED

- clés et valeurs textuelles
- rapide
- distribué

REDIS

- Clés pouvant être grosses (512 Mo, même si déconseillé)
- Valeurs complexes possibles: « It supports data structures such as strings, hashes, lists, sets, sorted sets with range queries, bitmaps, hyperloglogs and geospatial indexes with radius queries. »
- Persistance des données:
  - Utilisation possible comme cache d'écriture type write-back
  - Stockage de données de calcul intermédiaire:
    Permet d'éviter de relancer complètement un calcul en cas de perte d'un noeud
- Distribué
- En général conseillé pour les nouveau projets

CACHES DISTRIBUÉS

- Deux vecteur de passage à l'échelle:
  - Réplication
    - Permet de répondre à une montée en charge sur une même ressource
    - Gestion de cohérence plus complexe/coûteuse
  - Distribution des données (sharding)
    - Basée sur la valeur de la clé (en général via hashage)
    - Problématique de partitionnement pour étaler correctement la charge

CACHES DISTRIBUÉS:
MISE EN PLACE DU PARTITIONNEMENT

- Frontend qui distribue les requêtes sur les réplicats / partitions (*shards*)
  - Exemple: Twemproxy (memcached et Redis)
  - Possibilité de le faire fonctionner en cluster
    (évite de devenir un *single point of failure*)
- Interrogation d’un élément du cluster avec redirection vers le bon *shard* (Redis)
- Gestion des shards par le client:
  les membres du cluster ne se connaissent pas entre eux

IMPORTANCE DES EXPÉRIMENTATIONS

- Difficile de prévoir l'impact réel du cache
- Nécessité d'instrumenter les serveurs pour
  - vérifier les apports du cache
  - régler les paramètres de cache
- Mesure standard de l'utilité du cache:
  hit ratio = #données trouvées / #demandes

QUELQUES RÉFÉRENCES

- http://infrastructure.smile.eu/Tout-savoir-sur/Principes-d-architecture-et-outils-open-source/Le-cache/Principes-du-cache
- https://www.nginx.com/blog/nginx-caching-guide/
- http://deptinfo.cnam.fr/new/spip.php?pdoc4647
- https://redis.io/documentation
- https://fr.wikipedia.org/wiki/M%C3%A9moire_cache
- https://fr.wikipedia.org/wiki/Cache_web
- https://en.wikibooks.org/wiki/Java_Persistence/Caching