


Mémoire Reconfigurable pour l'Indexation de Masses de Données

Plate-forme matérielle




L'ACI ReMIX propose l'élaboration d'une mémoire spécialisée de très grande taille, dans le but d'accélérer la recherche d'informations dans des bases de données indexées. Une architecture matérielle dédiée a été développée. Trois champs disciplinaires représentatifs serviront de support pour valider cette proposition : la génomique, la recherche d'images par le contenu et la recherche documentaire basée sur les textes et leurs structures.

Caractéristiques :

- ✓ L'architecture ReMIX est un cluster de 4 PCs. Chaque nœud est doté de 2 cartes mémoires reconfigurables (RMem) de 64Go, portant la mémoire d'index globale à 512Go.
- ✓ Les index sont distribués sur 8 supports physique indépendants.
- ✓ La technologie mémoire « Flash Nand » utilisée offre une latence d'accès en lecture 200 à 500 fois inférieure à un disque dur.
- ✓ La bande passante agrégée en sortie de mémoire est d'environ 5Go/s.
- ✓ Des opérateurs matériels reconfigurables, implantés dans un FPGA, permettent un filtrage efficace des données en sortie de la mémoire.
- ✓ Un système de fichiers dédié permet la gestion des bancs mémoires Flash.
- ✓ Un environnement de programmation générique de haut niveau parallélise les traitements au niveau du cluster.

Architecture de la RMem :



Recherche par le contenu dans les bases de séquences génomiques

✓ Objectif : Indexation du programme BLAST sur ReMIX.

✓ BLAST (Basic Local Alignment Search Tool) : Programme le plus utilisé en biologie moléculaire pour la recherche d'alignement entre des séquences génomiques.

✓ Temps de calcul proportionnel à la taille des bases de données qui double tous les 14 mois.


✓ Heuristique : Dans un alignement les 2 séquences partagent au moins W caractères.



✓ Principe de BLAST : Indexation de la séquence requête, et parcourt de toute la banque génomique.

=> Temps de calcul limité par le débit des données.

✓ Indexation sur ReMIX (IBLAST) : Indexation de la banque et parcourt de la requête.



✓ Opération à implémenter sur FPGA : Calcul d'alignement sur le voisinage de la clé d'index.

Recherche par le contenu dans des banques d'images

✓ Objectif : Retrouver une image éventuellement modifiée dans une banque d'images protégées par le copyright.

✓ 94% du chiffre d'affaire généré par le marché de la distribution de photos à usage professionnel (plus de 1600M Euros) est lié au copyright. => Importance de la vérification du respect du copyright.

✓ Recherche par le contenu : basée sur la présence de similitudes visuelles entre l'image piratée et l'image originale.


✓ Nécessité d'être robuste aux altérations éventuellement sévères.

✓ Une image est définie par des descripteurs locaux de 24 dimensions : 50 à 1000 descripteurs par image.

✓ Description d'une image (base ou requête) par détection automatique des points d'intérêts (Harris), puis traitement du signal autour de chaque point (convolution, dérivation, mélange spécifique).

✓ Processus de recherche :

- => Description de l'image requête,
- => Interrogation de la base pour chaque descripteur,
- => Comptage du taux d'apparition de chaque image de la base,
- => Sélection des meilleures images.




✓ Opération à implémenter sur FPGA : Calcul de distance euclidienne entre descripteurs multidimensionnels.

Recherche approchée d'information dans des bases de documents semi-structurés

✓ Objectif : Indexation et interrogation de bases de documents semi-structurés de tailles de l'ordre de 50 à 100 Go.

✓ Documents représentés sous la forme d'un arbre DOM, assimilable à un ensemble de chemins ($\{P_i\}$).


Arbre DOM
(Document Object Model)



✓ Type de recherche : Hors contexte, en contexte ou sur la structure des documents.

✓ Requêtes complexes fragmentées en requêtes élémentaires relatives sur les nœuds ReMIX.

✓ Opérations assemblées et création du résultat réalisés sur l'hôte.



✓ Opération à implémenter sur FPGA : Calcul de distance entre deux chemins (Distance d'édition de Levenshtein).

Contacts :

Dominique LAVENIER
IRISA
Campus de Beaulieu
35042 Rennes Cedex
Tel : (33) 2 99 84 72 17
Email : lavenier@irisa.fr

Gilles GEORGES
IRISA
Campus de Beaulieu
35042 Rennes Cedex
Tel : (33) 2 99 84 74 54
Email : georges@irisa.fr



CENTRE NATIONAL
DE LA RECHERCHE
SCIENTIFIQUE



ministère
Jeunesse
Éducation
recherche
E
ministère délégué
recherche et nouvelles
technologies



INRIA