

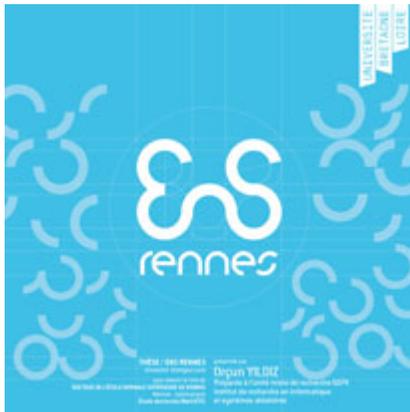


EFFICIENT BIG DATA PROCESSING ON LARGE-SCALE SHARED PLATFORMS: MANAGING I/OS AND FAILURE

le 8 décembre 2017 9h30

Campus de Beaulieu Salle Metivier, Inria Rennes

**Soutenance de thèse de Orçun Yildiz (équipe KerData - IRISA / Inria Rennes)
mention informatique**



En 2017 nous vivons dans un monde régi par les données. Les applications d'analyse de données apportent des améliorations fondamentales dans de nombreux domaines tels que les sciences, la santé et la sécurité. Cela a stimulé la croissance des volumes de données (le déluge du Big Data). Pour extraire des informations utiles à partir de cette quantité énorme d'informations, différents modèles de traitement des données ont émergé tels que MapReduce, Hadoop, et Spark. Les traitements Big Data sont traditionnellement exécutés à grande échelle (les systèmes HPC et les Clouds) pour tirer parti de leur puissance de calcul et de stockage. Habituellement, ces plateformes à grande échelle sont utilisées simultanément par plusieurs utilisateurs et de multiples applications afin d'optimiser l'utilisation des ressources. Bien qu'il y ait beaucoup d'avantages à partager de ces plateformes, plusieurs problèmes sont soulevés dès lors qu'un nombre important d'utilisateurs et d'applications les utilisent en même temps, parmi lesquels la gestion des E / S et des défaillances sont les principales qui peuvent avoir un impact sur le traitement efficace des données.

Nous nous concentrons tout d'abord sur les goulots d'étranglement liés aux performances des E/S pour les applications Big Data sur les systèmes HPC. Nous commençons par caractériser les performances des applications Big Data sur ces systèmes. Nous identifions les interférences et la latence des E/S comme les principaux facteurs limitant les performances. Ensuite, nous nous intéressons de manière plus détaillée aux interférences des E/S afin de mieux comprendre les causes principales de ce phénomène. De plus, nous proposons un système de gestion des E/S pour réduire les dégradations de performance que les applications Big Data peuvent subir sur les systèmes HPC. Par ailleurs, nous introduisons des modèles d'interférence pour les applications Big Data et HPC en fonction des résultats que nous obtenons dans notre étude expérimentale concernant les causes des interférences d'E/S. Enfin, nous exploitons ces modèles afin de minimiser l'impact des interférences sur les performances des applications Big Data et HPC. Deuxièmement, nous nous concentrons sur l'impact des défaillances sur la performance des applications Big Data en étudiant la gestion des pannes dans les clusters MapReduce partagés. Nous présentons un ordonnanceur qui permet un recouvrement rapide des pannes, améliorant ainsi les performances des applications Big Data.

ABSTRACT

As of 2017, we live in a data-driven world where data-intensive applications are bringing fundamental improvements to our lives in many different areas such as business, science, health care and security. This has boosted the growth of the data volumes (i.e., deluge of Big Data). To extract useful information from this huge amount of data, different data processing frameworks have been emerging such as MapReduce, Hadoop, and Spark. Traditionally, these frameworks run on largescale platforms (i.e., HPC systems and clouds) to leverage their computation and storage power. Usually, these largescale platforms are used concurrently by multiple users and multiple applications with the goal of better utilization of resources. Though benefits of sharing these platforms exist, several challenges are raised when sharing these large-scale platforms, among which I/O and failure management are the major ones that can impact efficient data processing.

To this end, we first focus on I/O related performance bottlenecks for Big Data applications on HPC systems. We start by characterizing the performance of Big Data applications on these systems. We identify I/O interference and latency as the major performance bottlenecks. Next, we zoom in on I/O interference problem to further understand the root causes of this phenomenon. Then, we propose an I/O management scheme to mitigate the high latencies that Big Data applications may encounter on HPC systems. Moreover, we introduce interference models for Big Data and HPC applications based on the findings we obtain in our experimental study regarding the root causes of I/O interference. Finally, we leverage these models to minimize the impact of interference on the performance of Big Data and HPC applications. Second, we focus on the impact of failures on the performance of Big Data applications by studying failure handling in shared MapReduce clusters. We introduce a failure-aware scheduler which enables fast failure recovery while optimizing data locality thus improving the application performance.

THÉMATIQUE(S)

Débouchés, Recherche - Valorisation, Vie de l'École

Mise à jour le 23 janvier 2018

ARCHIVES

[Séminaires 2020-2021](#)
[Séminaires 2019-2020](#)
[Séminaires 2018-2019](#)
[Séminaires 2017-2018](#)
[Séminaires 2016-2017](#)
[Séminaires 2015-2016](#)
[Séminaires 2014-2015](#)
[Séminaires 2013-2014](#)
[Séminaires 2012-2013](#)
[Séminaires 2011-2012](#)
[Séminaires 2010-2011](#)
[Séminaires 2009-2010](#)
[Séminaires 2008-2009](#)
[Séminaires 2007-2008](#)
[Séminaires 2006-2007](#)
[Séminaires 2005-2006](#)
[Séminaires 2004-2005](#)
[Séminaires 2003-2004](#)
[Séminaires 2002-2003](#)

JURY

M. BEAUMONT Olivier / rapporteur

Directeur de Recherche, Inria Bordeaux

M. MONNET Sébastien/ rapporteur

Professeur, Polytech' Annecy-Chambéry

Mme ARANTES Luciana / examinatrice

Maître de Conférences, UPMC

M. TAIANI François / examinateur

Professeur, Université de Rennes 1

M. ANTONIU Gabriel / directeur de thèse

Directeur de Recherche, INRIA Rennes

M. IBRAHIM Shadi / co-directeur de thèse

Chargé de Recherche, INRIA Rennes