

**ภารีเดช สุดสี** : การเพิ่มผลิตภาพของการทดสอบซอฟต์แวร์แบบกระจายโดยใช้จุด  
ตรวจสอบ (A PRODUCTIVITY IMPROVEMENT OF DISTRIBUTED SOFTWARE  
TESTING USING CHECKPOINTS) อาจารย์ที่ปรึกษา : ผู้ช่วยศาสตราจารย์ ดร.ชาญวิทย์  
แก้วกสิ, 116 หน้า.

จากความก้าวหน้าของเทคโนโลยีการเก็บข้อมูลและอัตราการสร้างข้อมูลที่เกิดขึ้นได้อย่างรวดเร็วในปัจจุบันทำให้เกิดข้อบกพร่องของข้อมูลขนาดใหญ่ แต่เครื่องมือที่ออกแบบมาค่อนหน้านั้นพบว่าไม่เหมาะสมสำหรับการประมวลผลข้อมูลขนาดใหญ่ที่เก็บอยู่ในปัจจุบัน ดังนั้นเพื่อที่จะประมวลผลข้อมูลเหล่านั้นจึงมีการพัฒนาเครื่องมือที่ใช้ประมวลผลงานในลักษณะงานที่ต้องการประมวลผลข้อมูลที่สามารถขยายได้ เครื่องมือหนึ่งที่เป็นที่นิยมในการใช้งานคือ Apache Spark ซึ่งเน้นการประมวลผลบนหน่วยความจำ ทำให้ทำงานได้อย่างรวดเร็ว แต่อย่างไรก็ตามพบว่าซึ่งไม่มีกลไกในการควบคุมคุณภาพซอฟต์แวร์ที่สามารถทดสอบกับกรณีทดสอบบนข้อมูลจริงที่มีขนาดใหญ่ได้ นักพัฒนาจึงเลือกที่จะใช้ข้อมูลตัวแทนชุดข้อมูลมาเพื่อทดสอบ ทำให้นักพัฒนาบางรายเลือกที่จะไม่ทดสอบซอฟต์แวร์เลยเพื่อลดความยุ่งยากและต้องใช้เวลาทดสอบนาน หรือกระทำการที่ไม่สามารถทดสอบได้บนเครื่องคอมพิวเตอร์เครื่องเดียว

งานวิจัยในเอกสารนี้จึงได้นำเสนอ Distributed Test Checkpointing (DTC) สำหรับกรอบงาน Apache Spark ซึ่งจะทำให้สามารถทดสอบซอฟต์แวร์เป็นกรณีทดสอบแบบเชิงหน่วยบนข้อมูลขนาดใหญ่ที่ยังคงความถูกต้อง และใช้เวลาทดสอบที่ผู้ใช้สามารถยอมรับได้จากการทดลองพบว่ากรอบงาน DTC จะใช้เวลาทำงานใกล้เคียงหรือสูงกว่าเมื่อเทียบกับกลไกสร้างจุดตรวจสอบด้วยเดิมของ Spark ในกรณีทดสอบแรก และในกรณีทดสอบด้วยมากลับสามารถลดระยะเวลาได้อย่างมาก กรณีการตั้งค่ากรอบงาน DTC ที่ดีที่สุดพบว่าสามารถลดเวลาการประมวลผลได้ถึงร้อยละ 450 ถึงร้อยละ 500 และยังพบอีกว่าสามารถลดการใช้พื้นที่เก็บจุดตรวจสอบได้มากกว่า 19.7 เท่า

BHURIDECH SUDSEE : A PRODUCTIVITY IMPROVEMENT OF DISTRIBUTED SOFTWARE TESTING USING CHECKPOINTS. THESIS  
ADVISOR : ASST. PROF. CHANWIT KAEWKASI, Ph.D., 116 PP.

DISTRIBUTED CHECKPOINTING/APACHE SPARK/BIG DATA TESTING/  
SOFTWARE TESTING;

The advancement of storage technologies and the fast-growing number of generated data have made the world moved into the Big Data era. In this past, we had many data mining tools but they are inadequate to process Data-Intensive Scalable Computing workloads. The Apache Spark framework is a popular tool designed for Big Data processing. It leverages in-memory processing techniques that make Spark up to 100 times faster than Hadoop. Testing this kind of Big Data program is time consuming. Unfortunately, developers lack a proper testing framework, which could help assure quality of their data-intensive processing programs, while saving development time.

We propose Distributed Test Checkpointing (DTC) for Apache Spark. DTC applies unit testing to the Big Data software development life cycle and reduce time spent for each testing loop with checkpoint. From the experimental results, we found that in the subsequence rounds of unit testing, DTC dramatically speed the testing time up to 450 – 500% . In case of storage, DTC can cut unnecessary data off and make the storage 19.7 times saver than the original checkpoint of Spark.

School of Computer Engineering  
Academic Year 2017

Student's Signature \_\_\_\_\_  
Advisor's Signature \_\_\_\_\_