

Virtualisierungsbasierte Fehlertoleranz

Motivation

Remus



- Widersprüchliche Entwicklung
 - (Geschäfts-)Kritische Dienste werden zunehmend in die Cloud verlagert
 - Hard- und Software-Ausfälle sind nicht die Ausnahme, sondern die Regel
 - Abstürze einzelner Prozesse
 - Ausfälle ganzer Rechner und sogar Datenzentren

→ Generische Fehlertoleranzmechanismen für Anwendungen erforderlich
- Vorteile einer virtuellen Maschine (VM) gegenüber einer physischen
 - Kurze Startzeit
 - Einfache Migrierbarkeit (auch während der Ausführung)
 - Paralleler Betrieb mehrerer Maschinen auf einem Rechner möglich
- Herausforderungen
 - Wie lassen sich die speziellen Eigenschaften von virtuellen Maschinen für die Bereitstellung von Fehlertoleranzmechanismen ausnutzen?
 - Wie kann Fehlertoleranz als Dienst des Cloud-Anbieters realisiert werden?



Remus

- Anforderungen
 - Anwendungs- und Hardware-unabhängiger Ansatz
 - Keine Modifikationen im Anwendungs- bzw. Betriebssystem Quellcode
 - Kein externalisierter Zustand darf verloren gehen
- Remus
 - Behandlung einer virtuellen Maschine als Black-Box
 - Passiv replizierter Ansatz basierend auf häufigen Sicherungspunkten
 - Ausnutzung bereits existierender VM-Migrationsmechanismen
 - Steigerung der Effizienz durch spekulative Ausführung
 - Aufrechterhaltung von Netzwerkverbindungen im Fehlerfall

Literatur




Brendan Cully, Geoffrey Lefebvre, Dutch Meyer, Mike Feeley et al.
Remus: High availability via asynchronous virtual machine replication
Proceedings of the 5th Symposium on Networked Systems Design and Implementation (NSDI '08), S. 161–174, 2008.



Architektur

- Primary
 - Ausführung der zu sichernden aktiven virtuellen Maschine
 - Periodisches Erzeugen von Sicherungspunkten der aktiven VM [z. B. alle 25 ms]
 - Puffern des ausgehenden Netzwerkverkehrs bis der Backup den Erhalt des korrespondierenden Sicherungspunkts bestätigt hat
- Backup
 - Auf letztem Sicherungspunkt basierendes VM-Image im Hauptspeicher
 - Senden von Bestätigungen für Sicherungspunkte
 - Ein Backup für mehrere Primaries denkbar



- Anforderungen
 - Möglichst keine bzw. kurze Dienstunterbrechung während der Migration
 - Möglichst geringe Dauer des Migrationsvorgangs
- Naiver Ansatz: „*Stop the World*“
 - Unterbrechung der laufenden VM auf dem Ausgangsrechner
 - Kopieren sämtlicher für die VM relevanter Daten auf den Zielrechner
 - Fortsetzung der VM auf dem Zielrechner
- Zu migrierende Ressourcen
 - Daten im Arbeitsspeicher
 - Daten auf der Festplatte
 - Netzwerkverbindungen
- Literatur
 -  Christopher Clark, Keir Fraser, Steven Hand, Jacob Gorm Hansen et al.
Live migration of virtual machines
Proceedings of the 2nd Symposium on Networked Systems Design and Implementation (NSDI '05), S. 273–286, 2005.



- Mechanismus zur Erkennung veränderter Seiten
 - Markierung aller Speicherseiten der Schattenseitentabelle als *rein-lesend*
 - Schreibzugriff auf Speicherseite löst einen Trap aus
 - VMM markiert entsprechende Speicherseite als „dirty“
- Pre-Copy-Ansatz
 - Push-Phase
 - Rundenbasiertes Kopieren von Speicherseiten auf den Zielrechner
 - Erste Runde: Duplizieren aller Speicherseiten
 - Runde n : Kopieren aller in Runde $n - 1$ veränderten Speicherseiten
 - Mögliche Kriterien für das Ende der Phase (Beispiele)
 - * Keine veränderten Speicherseiten seit der letzten Runde
 - * Über mehrere Runden konstante Anzahl an veränderten Speicherseiten
 - * Vordefinierte maximale Anzahl n_{max} an Runden
 - Stop-and-Copy-Phase
 - Stoppen der VM auf dem Ausgangsrechner
 - Kopieren der in der letzten Runde der Push-Phase veränderten Speicherseiten
 - Fortsetzen der VM auf dem Zielrechner



Hochfrequente Sicherungspunkte

- Arbeitsspeicher
 - Implementierung auf Basis des Stop-and-Copy-Mechanismus
 - Periodisches Suspendieren der aktiven VM
 - Kopieren modifizierter Speicherseiten in einen lokalen Puffer
 - Fortsetzen der zu sichernden aktiven VM auf demselben Rechner
 - Zur Ausführung asynchrone Übertragung des Pufferinhalts zum Backup
- Festplatte
 - Primary
 - Aufzeichnen aller Schreiboperationen auf dem Primary
 - Asynchrones Weiterleiten der Schreiboperationen an den Backup
 - Backup
 - Zwischenspeichern der Schreiboperationen im Arbeitsspeicher
 - Ausführen der Schreiboperationen, sobald Sicherungspunkt bestätigt wurde
- Backup: Bestätigung des Sicherungspunkts erst, wenn sowohl die Arbeitsspeicher- als auch die Festplattenaktualisierungen vorliegen



Konsistenz und Transparenz bei Fehlersituationen

- Netzwerkkonfiguration auf dem Primary
 - Eingehender Netzwerkverkehr wird direkt an die aktive VM weitergeleitet
 - Ausgehender Netzwerkverkehr wird gepuffert
 - Solange der korrespondierende Sicherungspunkt vom Backup nicht bestätigt wurde, reflektieren die gepufferten Nachrichten *spekulativen* Zustand
 - Bei Eintreffen einer Bestätigung: Versenden des gesicherten Teils des Puffers
- Umschalten auf den Backup im Fehlerfall
 - Fehlererkennung: Timeout nach Ausbleiben neuer Sicherungspunkte
 - Laden des letzten vollständigen Sicherungspunkts
 - Fortsetzen der virtuellen Maschine
 - Verlust eventuell auf dem Primary vorhandenen spekulativen Zustands
- Aufrechterhaltung von Netzwerkverbindungen
 - Ausnutzung zuverlässiger Übertragungsprotokolle (z. B. TCP)
 - Umschalten erscheint als temporärer Fehler, der toleriert werden kann
 - Erneutes Senden von Nachrichten erforderlich [Für die Anwendung transparent.]

