Literatur

Object Management Group
CORBA/IIOP Specification (Chapter 23, Fault Tolerant CORBA)
OMG Technical Committee Document formal/04-03-21, 2004.

Pascal Felber, Priya Narasimhan
Experiences, Strategies, and Challenges in Building
Fault-Tolerant CORBA Systems
IEEE Transactions on Computers, vol. 53, no. 5, pp. 497-511, 2004

R. Baldoni, C. Marchetti, R. Panella, L. Verde
Handling FT-CORBA Compliant Interoperable Object Group References
WORDS '02: Proceedings of the The Seventh IEEE International Workshop on Object-Oriented Real-Time Dependable Systems, 2002

Priya Narasimhan
Fault-Tolerant CORBA: From Specification to Reality
Computer , vol. 40, no. 1, pp.110-112, Jan. 2007

Wozu überhaupt Fehlertoleranz?

- Hardwarefehler
- Softwarefehler
- ständige Verfügbarkeit
  - Luftfahrt, Medizin, Anlagensteuerung, etc.
- Kosten bei Ausfall

Ziel

No single point of failure

Was ist ein Fehler?

Fault (Fehlerusache)

- unerwünschter Zustand, der zu einem Fehler führen kann

Error (Fehler)

- Systemzustand, der nicht den Spezifikationen entspricht

Failure (Funktionsausfall)

- Diensterbrinung ist nicht mehr möglich

Singal/Shivaratri

An error is a manifestation of a fault in a system,
which could lead to system failure.

Klassifikation von Fehlern

Gutmütige Fehler (benign faults)

- **Crash Stop:** Ein Knoten fällt komplett aus
  - **Fail Stop**: Jeder korrekte Knoten erfährt innerhalb endlicher Zeit vom Ausfall eines Knoten
  - **Fail Silent**: Keine perfekte Ausfallerkennung möglich (asynchrones oder partiell synchrones Modell)
- **Crash Recovery**: Ein korrekter Knoten kann endlich oft ausfallen und wiederanlaufen

Bösartige Fehler (malicious faults)

- Häufig als **byzantinische** Fehler bezeichnet
- Fehlerhafte Prozesse können beliebige Aktionen ausführen, und dabei auch untereinander kooperieren

FT-CORBA betrachtet **fail stop** Fehler

- Viele realen Systeme gehen von ausschließlich gutmütigen Fehlern aus. Dies ist aber nicht immer realistisch!

Fehlertoleranz durch Replikation

Redundanz

- erzeugen und verwalten von Kopien/Replikaten eines Objektes

Erkennen von Fehlern

- erkennen das ein Prozeß oder Objekt ausgefallen ist

Recovery

- ausgefallene Instanz ersetzen

CORBA und FT-CORBA

CORBA

- CORBA spezifiziert keine Mechanismen für Redundanz
- Zuverlässige Verbindungen basierend auf TCP/IP ermöglichen beschränkte Erkennung von Ausfällen

Ziele von FT-CORBA

- Minimale Modifikation von Applikationen (sowohl auf Client- wie auch auf Serverseite)
- Unterstützung für Fehlertoleranz
  - verschiedene Fehlertoleranzanforderungen
  - verschiedene Applikationen
  - verschiedene Mechanismen zur Fehlererkennung und -behandlung

Was muss eine Fehlertoleranzinfrastruktur leisten?

- Replikation von Objekten
- Erkennung von Ausfällen
- Logging von Anfragen und Zustandssicherung von Objektzuständen
- Zustandstransfer zur Initialisierung und Reinitialisierung von Objekten
- Transparente Verschattung von Ausfällen

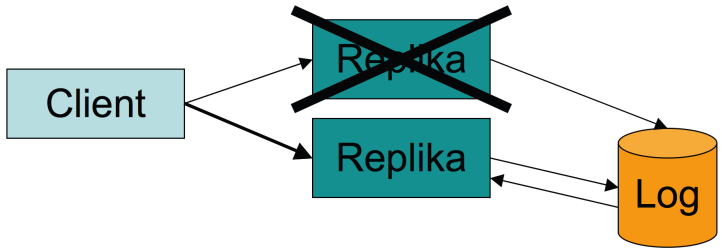

Grundlagen

Redundanz

- Objekte bilden die Einheit der Replikation
- Starke Konsistenz
  - Alle Replikate haben den gleichen Zustand
  - Ermöglicht einfache Anwendungsentwicklung
    - Client interagiert mit Objekten
  - Stellt hohe Anforderungen an die Mechanismen der Infrastruktur
    - Alle Mechanismen zur Fehlertoleranz werden durch die Middleware bereitgestellt

Grundlagen

Objektgruppe

- Menge aller Replikate eines Objektes bilden eine Objektgruppe
- Jede Gruppe verfügt über eine **Object Group Reference (IOR)**
- Zielsetzung
  - Replikationstransparenz
  - Fehlertransparenz

Identität

- CORBA-Objekte werden durch ihren Ausführungsort identifiziert
  - schwache Form von Identität
- FT-CORBA benötigt eindeutige und ortsunabhängige Identifikation
  - Objektgruppen werden durch `FTDomainId` und `ObjectGroupId` identifiziert
  - einzelne Replikate durch `FTDomainId`, `ObjectGroupId` und Ort

Grundlagen

Zustand

- Zustand bildet die Menge an Informationen die zur Erhaltung von konsistenten Replikaten nötig ist
- Zustand ergibt sich durch das replizierte Objekt und die Infrastruktur (POA und ORB)

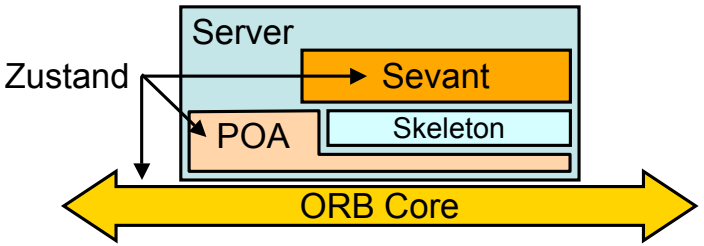

Grundlagen

Determinismus

- Replikation von Objekten erfordert deterministisches Verhalten
  - Aufrufe werden an alle Replikate in gleicher Reihenfolge zugestellt
  - Ausgehend von identischen Ausgangszuständen werden identische Endzustände erreicht
  - Objekt entspricht somit einem Zustandsautomat
- Problemfälle
  - objektexterne Informationen
    - z.B. Zeit, Zufallszahlen oder Aufruf an externen Informationsquellen
  - Koordinierung wenn parallel mehrere Threads ein Objekt verändern
    - z.B. Anforderung von Locks

Grundlagen

Replikationsart

- **Active** Replication
  - Replikate bearbeiten alle Anforderungen
- **Passive** Replication
  - Es gibt ein aktives Replikat (*master*) welches Aufrufe bearbeitet
  - Alle anderen Replikate sind in Wartestellung

Anwendungen besitzen unterschiedliche Fehlertoleranzanforderungen

- Active Replication
  - Sehr kurze Verzögerungen im Fehlerfall
  - Hoher Aufwand unter anderem durch die erforderliche Gruppenkommunikation
- Passive Replication
  - Längere Verzögerung bei Ausfällen
  - Geringer Aufwand zur Laufzeit
  - Schnellere Antwortzeit im Normalbetrieb

Grundlagen

Zuständigkeiten Serverseite

- Objektreplikation
- Verwaltung der System- und Fehlertoleranzanforderungen pro Objektgruppe
  - `Property Manager`-Schnittstelle
- Erzeugen von replizierten Objekten
  - `Generic Factory`-Schnittstelle
  - `Replication Manager`-Schnittstelle
  - Zustandstransfer
- Erkennung von Ausfällen

Grundlagen

Zuständigkeiten Clientseite

- Failover
  - Falls ein Server nicht antwortet wird es entweder erneut versucht oder ein anderer Server wird kontaktiert
  - Aufrufe werden nur einmal durch das replizierte Objekt ausgeführt (muss durch die Serverseite unterstützt werden)
- Adressierung
  - Veraltete Referenzen werden in Kooperation mit dem Server ersetzt
    - Server liefert aktuelle Version
- Ausfall der Verbindung
  - z. B. kein Replikat ist erreichbar
  - Anwendung wird benachrichtig

Grundlagen

Kontrolle und Verwaltung

- Infrastruktur kontrolliert Fehlertoleranz
  - Automatische Erzeugung von Replikaten
  - Automatische Erhaltung der Konsistenz
- Applikation kontrolliert Fehlertoleranz
  - Applikation lenkt die Erzeugung und Platzierung von Replikaten
  - Applikation gewährleistet die Konsistenz
  - Achtung: Nur in Spezialfällen nötig!

Grundlagen

Fault Tolerance Domain

- Menge von Rechnern zur Bereitstellung von fehlertoleranten Applikationen
- Zentrale Komponente bildet der Replication Manager
  - steuert Erzeugung und Platzierung von Replikaten

Limitationen des FT-CORBA Standards

- Determinismus bleibt Aufgabe des Anwendungsentwicklers
- Keine explizite Unterstützung für
  - Behandlung von Netzwerkpartitionierungen
  - bösartige Fehler
  - Softwarefehler und Designfehler
- Interoperabilität
  - Alle Replikate eines replizierten Objektes müssen die gleiche Infrastruktur nützen

Es ist Aufgabe der Hersteller hier individuelle Lösungen anzubieten!

Architekturübersicht

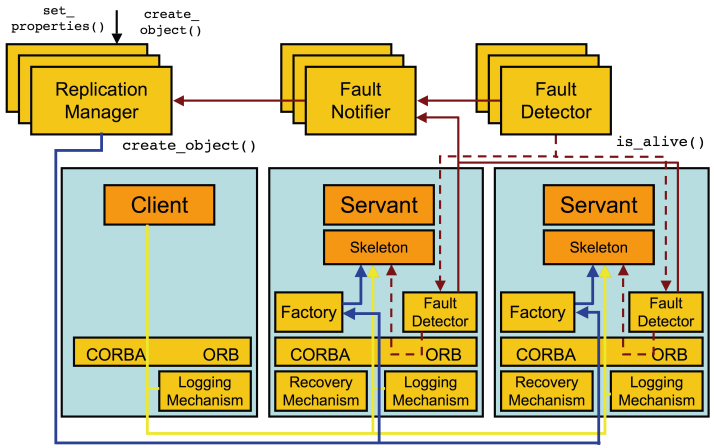

Adressierung

Interoperable Object Group Reference (IOGR)

- Eine IGOR besitzt mehrere IOR Profile
- Jedes Profil enthält Informationen zur Identität des Objektes
  - `FTDomainId` identifiziert die Domäne
  - `ObjectGroupId` identifiziert das replizierte Objekt (innerhalb der Domäne)
  - `ObjectGroupRefVersion` legt die Version der Referenz fest
- Maximal ein Profil enthält die Komponente `TAG_PRIMARY` zur Identifikation des primären Replikats.
  - Achtung, muss nicht aktuell sein!

Was wird adressiert?

- direkte Addresssieung der Replikate
- Addessierung von Gateways

Adressierung

Interoperable Object Group Reference (IOGR)

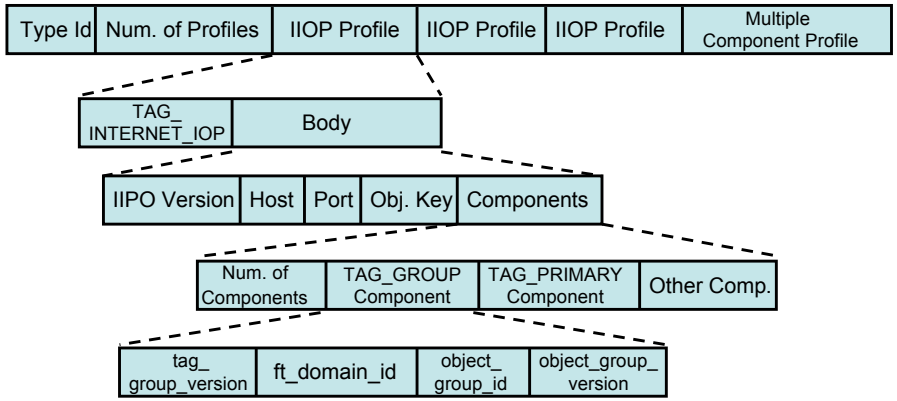

Adressierung

Aktualität von IOGRs

- Problem
  - Objektreferenzen können veralten, da sich die referenzierte Objektgruppe verändert
    - einzelne Replikate fallen aus, es kommen neue Replikate hinzu
- Lösung
  - Version der Client-Referenz wird bei Anfragen an den Server übertragen
    - Versionsinformation aus der Referenz wird als `GROUP_VERSION Service Context` der Anfrage beigefügt

Adressierung

Aktualität von IOGRs

- Lösung (Fortsetzung)
  - Server entnimmt Anfragen die Versionsinformation
  - Ist die Version des Clients aktuell wird die Anfrage verarbeitet
  - Ist die Version des Clients veraltet wird eine `LOCATE_FORWARD_PERM` Exception erzeugt
  - Ist die Version des Servers (anscheinend) veraltet wird der Replication Manager nach der aktuellen Referenz gefragt

Verhalten bei Ausfällen

Wiederholung von Aufrufen bei Ausfällen von Replikaten

- Auf ORB-Transportebene gibt es eine der folgenden Exceptions
  - `COMM_FAILURE, TRANSIENT, NO_RESPONSE, OBJ_ADAPTER`
  - Status ist `COMPLETED_MAYBE`
- Problem
  - Ohne weitere Maßnahmen kann eine Verletzung der at-most-once Semantik vorliegen
- Lösung
  - Eindeutige Identifizierung von Anfragen durch `REQUEST Service Context`
    - `Client Id`, identifiziert den Client
    - `Retention Id`, identifiziert den Aufruf
    - `Expiration Time`, legt fest wie lange Aufrufergebnisse aufbewahrt werden
  - Server ORB erkennt so die Wiederholungen von Anfragen und sendet das bereits ermittelte Ergebnis

Verhalten bei Ausfällen

- Problem
  - Es kommt zu einem Serverausfall oder Verbindungsproblem während eines Aufrufs
  - Die TCP/IP Verbindung wird nicht ordnungsgemäß beendet und der Client bekommt den Abbruch deshalb nicht mit
- Lösung
  - Periodische Testaufrufe (heartbeat messages)
  - Client fragt diese via Policy pro Verbindung an und spezifiziert
    - Aufruffrequenz
    - Timeout
  - Client-ORB ruft `_FT_HB()` beim Server-ORB auf
  - Operation wird vom Skeleton bereitgestellt
  - Server-ORB muss dies explizit erlauben
    - Kontrolle von erzeugtem Netzwerkverkehr

Einstellung von Fehlertoleranzeigenschaften

Konfigurierbare Eigenschaften

- Replikation
- Mitgliedschaft
- Konsistenz
- Monitoring
  - Intervall und Timeout
- Konfiguration von Factories
- Replikatanzahl
  - initiale Anzahl beim Start eines Dienstes
  - minimale Anzahl
- Sicherungspunktintervall

Replikation

Stateless

- statische Daten und nur lesender Zugriff

Cold Passive Replication

- Recovery wird durch Sicherungspunkt und Protokollierung von Aufrufen erreicht

⇒ langsame Kompensation von Ausfällen

Warm Passive Replication

- Aktueller Zustand des primären Replikats wird periodisch an alle anderen Replikate übertragen
- Protokollierung von Aufrufen

⇒ schnelleres Recovery im Vergleich zu cold passive

Active Replication

- alle Replikate bearbeiten Aufrufe

⇒ sehr geringe Verzögerung bei Ausfällen

Active Replication

Normalbetrieb

- Wenn replizierte Objekte von anderen replizierten Objekten aufgerufen werden müssen duplizierte Aufrufe und Antworten unterdrückt werden

Behandlung von Ausfällen

- Infrastruktur verschattet Ausfälle transparent da mindestens ein Replikat auf Anfragen antwortet

Behandlung von Beitritten

- Zustandstransfer zur Integration eines neuen oder temporär ausgefallenen Replikats nötig

Active Replication

Unterdrückung von duplizierten Ergebnissen

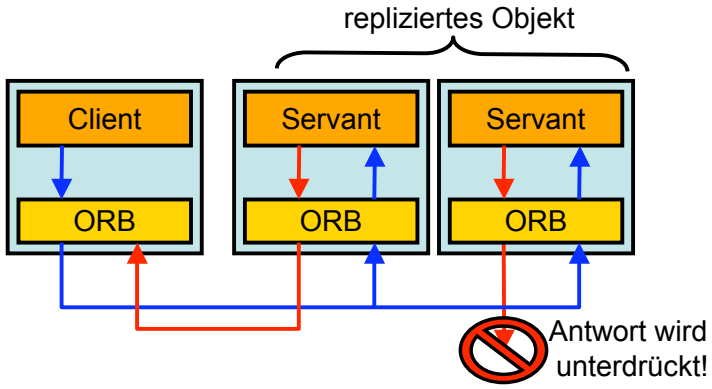

Active Replication

Unterdrückung von duplizierten Aufrufen

- Nötig wenn ein repliziertes Objekt andere Objekte aufruft

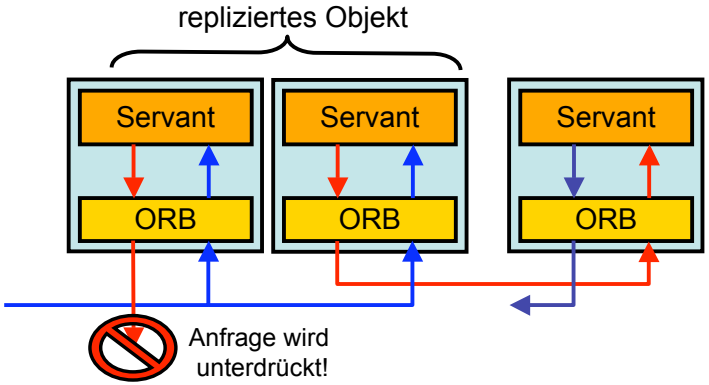

Passive Replication

Normalbetrieb

- periodischer Zustandstransfer zu allen Replikaten (nur bei warm passive nötig)
- Logging von Aufrufen und Sicherungspunkten

Behandlung von Ausfällen

- Ausfall des primären Replikats erfordern die Wahl eines neuen Replikats
- Initialisierung des neuen primären Replikats (Zustandstransfer bei cold passive Replication)
- Erkennung von dublizieren Anfragen

Behandlung von Beitritten

- Zustandstransfer zu neuem oder wiederhergestelltem Replikat bei warm passive Replication

Passive Replication

Unterdrückung von Anfragen und Zustandstransfer

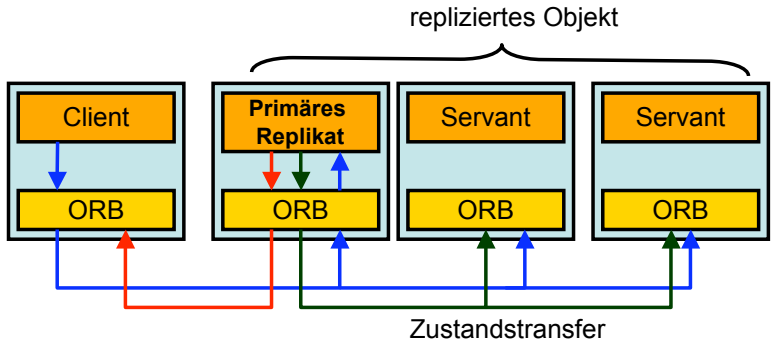

Vergleich der Replikationsformen

Passive Replication

- Geringerer Ressourcenbedarf (z.B. Speicher und CPU)
- Langsame Erholung von Ausfällen

Active Replication

- Hoher Ressourcenbedarf
  - Ausführung von Anfragen durch alle Replikaten
- Schnelle Kompensation von Ausfällen

Beide Ansätze erfordern die gleichen Mechanismen!

Mitgliedschaft

Infrastruktur kontrolliert Replikaterzeugung

- Infrastruktur erzeugt Replikate und platziert diese im Kontext der Domäne

Anwendung kontrolliert Replikaterzeugung

- Anwendung erzeugt und platziert Replikate entsprechend ihrer Erfordernisse

Mitgliedschaft

Infrastruktur kontrolliert Replikaterzeugung

- Anwendung ruft `create_object()`-Methode des Replication Managers auf

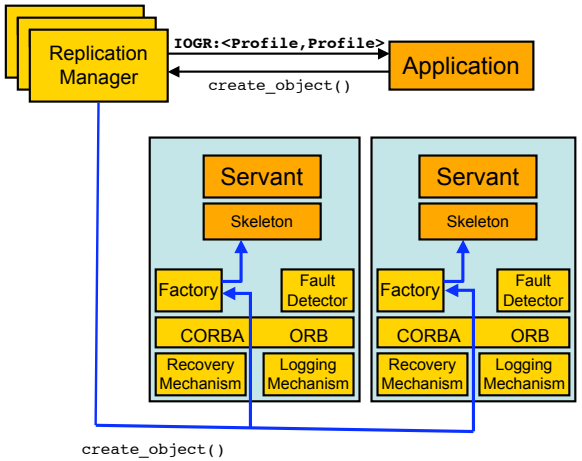

Mitgliedschaft

Anwendung kontrolliert Replikaterzeugung

- Anwendung beauftragt den Replication Manager zur Erzeugung einzelner Replikate

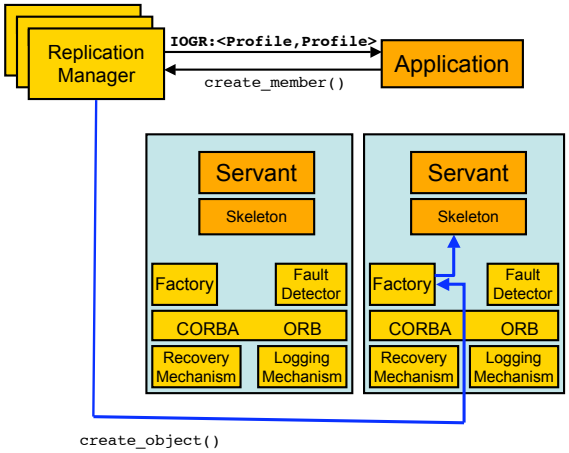

Mitgliedschaft

Anwendung kontrolliert Replikaterzeugung

- Anwendung erzeugt Replikate eigenständig und nutzt den Replication Manager zur Verwaltung

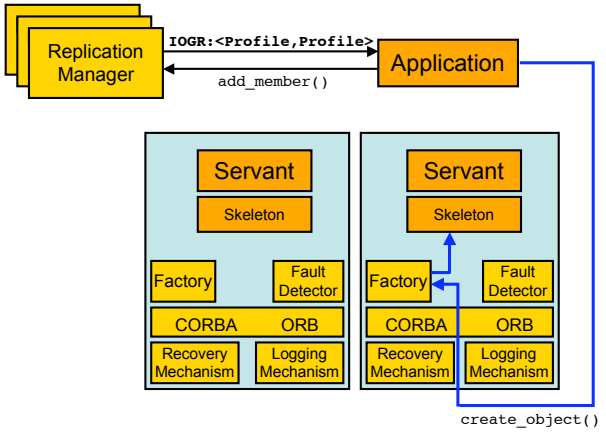

Konsistenz

Infrastruktur kontrolliert Konsistenz

- Infrastruktur erhält die Konsistenz durch Mechanismen wie Logging, Zustandssicherung und Recovery
  - Aktive Replication
    - Nach jedem Aufruf haben alle Replikate den gleichen Zustand
    - Erfordert eine Gruppenkommunikation und total geordnete Zustellung von Nachrichten
  - Passive Replication
    - Nach jedem Zustandstransfer haben alle Replikate den gleichen Zustand

Anwendung kontrolliert Konsistenz

- Anwendung stellte alle Mechanismen zur Konsistenzerhaltung bereit

Monitoring

Granularität der Beobachtung

- **Mitglieder**
  - Es wird jedes Mitglied einer Objektgruppe beobachtet
- **Ort**
  - Es wird ein Objekt als Repräsentant für den Ort beobachtet
  - Wird das beobachtete Replikat beendet wird ein anderes Objekt ausgewählt
  - Fällt das Objekt aus wird der Rechner als ausgefallen betrachtet
- **Ort und Typ**
  - Es wird ein Objekt pro Ort und Typ kontrolliert.
  - Wird das beobachtete Replikat beendet wird ein anderes Objekt vom gleichen Typ ausgewählt
  - Fällt das Objekt aus werden alle Objekte des Typs an diesem Ort als ausgefallen betrachtet

Factories

Sequenz von `FactoryInfo` Strukturen

- Erzeugung von replizierten Objekten wird durch eine Sequenz von `FactoryInfo` Strukturen konfiguriert
- Aufbau der `FactoryInfo` Struktur
  - Referenz auf Fabrik
  - Ort der Fabrik
  - Information zur Konfiguration der Fabrik (`Criteria`)

Verwaltung von Replikaten

Aufgaben des Replication Manager

- Verwaltung von Objektgruppen und ihren Eigenschaften
  - Replikationsart
  - Mitgliedschaft
  - Konsistenz
  - usw.

Schnittstelle des Replication Manager

- Methoden zur Benachrichtigung von Ausfällen
  - `register_fault_notifier()`
  - `get_fault_notifier()`
- Erbt von
  - `Property Manager` – Management von Fehlertoleranzeigenschaften
  - `Object Group Manager` – Verwaltung von Objektgruppen
  - `Generic Factory` – Erzeugung von replizierten Objekten

Property Manager Schnittstelle

Ermöglicht konfigurieren von Eigenschaften

- für alle Objektgruppen
- für alle replizierten Objekte eines bestimmten Typs
- für ein bestimmtes repliziertes Objekt zum Zeitpunkt der Erzeugung
- für ein bestimmtes repliziertes Objekt zu Lauftzeit

Spezifischere Definitionen haben höhere Priorität

Property Manager Schnittstelle

- Setzen/Ermitteln der Standardwerte für alle replizierten Objekte
  - `set_default_properties()`
  - `get_default_properties()`
  - `remove_default_properties()`
- Setzen/Ermitteln der Werte für alle replizierten Objekte eines Typs
  - `set_type_properties()`
  - `get_type_properties()`
  - `remove_type_properties()`
- Setzen/Ermitteln der Werte für ein bestimmtes repliziertes Objekt
  - `set_properties_dynamically()`
  - `get_properties()`

Zeitpunkt der Konfiguration

Eigenschaften	Standard	Typ	Erzeugung	Dynamisch
Replikation	X	X	X	
Mitgliedschaft	X	X	X	
Konsistenz	X	X		
Monitoring	X	X		
Granularität	X	X	X	X
Fabriken		X	X	X
Initiale Replikatanzahl	X	X	X	
Minimale Replikatanzahl	X	X	X	X

Generic Factory Schnittstelle

- Wird vom Replication Manager und von Fabriken implementiert zum Erzeugen von replizierten Objekten

```
typedef Object ObjectGroup;
typedef any FactoryCreationId;

Object create_object(
   in TypeIdtype_id,
   in Criteria the_criteria,
   out FactoryCreationIdfactory_creation_id)
raises(NoFactory, ObjectNotCreated, InvalidCriteria,
          InvalidProperty, CannotMeetCriteria);

void delete_object(
   in FactoryCreationIdfactory_creation_id)
raises(ObjectNotFound);
```


Object Group Manager

- Operationen der `Object Group Manager` Schnittstelle:
  - `create_member()`
  - `add_member()`
  - `set_primary_member()`
  - `remove_member()`
  - `locations_of_members()`
  - `get_object_group_ref()`
  - `get_object_group_id()`
  - `get_member_ref()`

Object Group Manager

- Wichtige Operation `create_member` und `add_member`

```
ObjectGroup create_member(
   in ObjectGroup object_group,
   in Location the_location, in TypeId type_id,
   in Criteria the_criteria)
raises(ObjectGroupNotFound, MemberAlreadyPresent,
          NoFactory, ObjectNotCreated, InvalidCriteria
            ,...);

ObjectGroup add_member(
   in ObjectGroup object_group,
   in Location the_location, in Object member)
raises(ObjectGroupNotFound, MemberAlreadyPresent,
  ObjectNotAdded);
```


Fehlermanagement

Fault Detector

- Erkennt Fehler und erzeugt Fehlerberichte

Fault Notifier

- Sammelt und verarbeitet Fehlerberichte von Fault Detectors und Fault Analyzers
- Bildet eine Art Datenbank für alle Fehlerberichte

Fault Analyzer

- Spezifisch für jede Anwendung
- Verarbeitet Fehlerberichte und fasst abhängige Fehler zusammen

Fehlermanagement

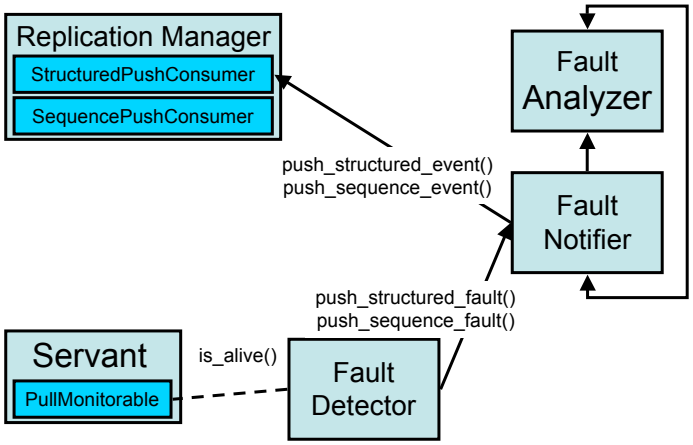

Fehlermanagement

Fehlerweitergabe durch Fault Detectors

- einzelne Fehlerreporte (`CosNotification::StructuredEvent`)
- Sammelreport (`CosNotification::EventBatch`)
- Fehlertyp: (`ObjectCrashFault`)
  - `Domain_name - FT_CORBA`
  - `Type_name - ObjectCrashFault`
  - `Location - host/process`
  - `TypeId - IDL:Library:1.0`
  - `ObjectGroupId - 4711`
- Sind alle Objekte eines Ortes ausgefallen wird `TypeId` und `ObjektGroupId` nicht im Fehlerreport vermerkt
- Sind alle Objekte eines Types ausgefallen wird die `ObjektGroupId` weggelassen

Fehlermanagement

Fehlerverarbeitung

- Fehlerberichte werden durch Fault Detectors erzeugt und via *push* an den Fault Notifier weitergeleitet
- Beliebige Konsumenten registrieren sich beim Fault Notifier und werden über Fehler benachrichtigt
  - Filter reduzieren das Nachrichtenaufkommen

Fehlermanagement

Schnittstelle des Fault Notifier

```
void push_structured_fault(
   in CosNotification::StructuredEvent event);

CosNotifyFilter::Filter create_subscription_filter(
   in string constraint_grammer)
 raises(CosNotifyFilter::InvalidGrammer);

ConsumerId connect_structured_fault_consumer(
   in CosNotifyComm::StructuredPushConsumerconsumer,
   in CosNotifyFilter::Filter filter);
```

Logging und Recovery

Beispiel: Active Replication

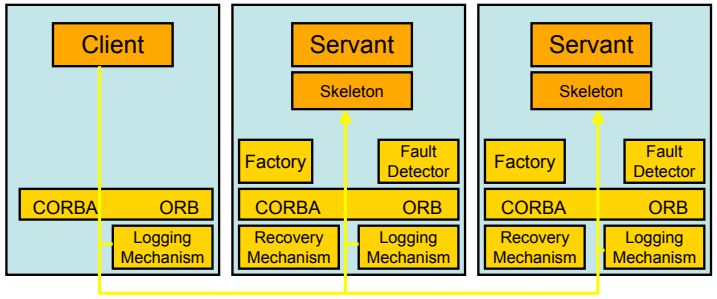

Logging und Recovery

Schnittstelle zum Erzeugen Sicherungspunkten

```
interface Checkpointable {
   State get_state()
      raises(NoStateAvailable);
   void set_state(in State s)
      raises(InvalidState);
};
```

Schnittstelle zum Erzeugen von partiellen Sicherungspunkten

```
interface Updateable : Checkpointable {
   State get_update()
      raises(NoUpdateAvailable);
   void set_update(in State s)
      raises(InvalidUpdate);
};
```


Logging und Recovery

Beispiel: Cold Passive Replication — Normalbetrieb

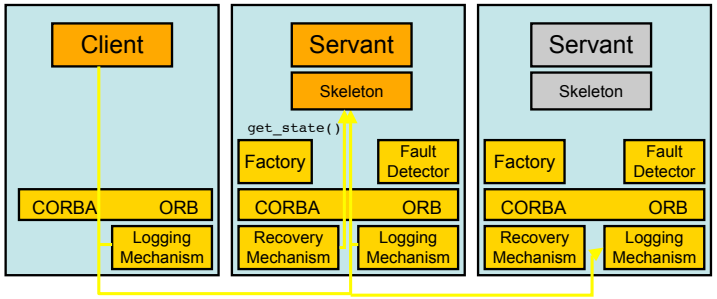

Logging und Recovery

Beispiel: Cold Passive Replication — Recovery

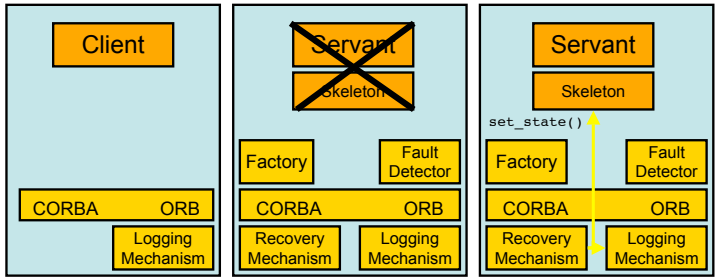

Implementierungsvarianten

- Integrativer Ansatz
  - Unterstützung für replizierte Dienste wird direkt durch den ORB realisiert
- Dienst-Ansatz
  - Unterstützung für replizierte Dienste wird als CORBA Service angeboten
- Interceptor-Ansatz
  - Aufrufe werden durch Interceptoren (unterhalb des ORBs) abgefangen

Integrativer Ansatz

- ORB wird durch eine Gruppenkommunikation ergänzt
- IIOP wird durch ein proprietäres Protokoll ausgetauscht

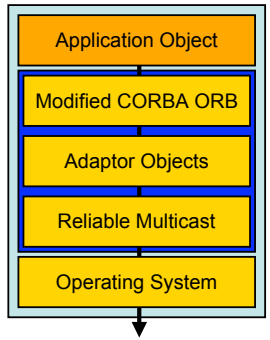

- Nachteil: Aufwendige Implementierung
- Vorteil: Effizient und transparent für die Applikation und kann FT-CORBA kompatible sein

Dienst-Ansatz

- Anwendung kommuniziert über lokale Dienste mit dem replizierten Objekt

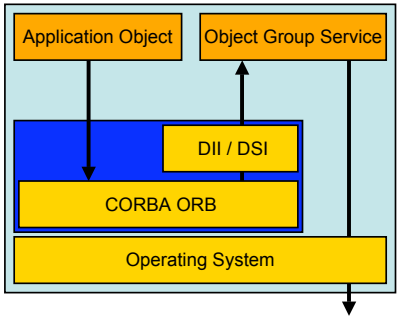

- Nachteil: Indirektion über den ORB
- Nachteil: Nicht transparent für die Anwendung und nicht kompatible
- Vorteil: Keine Veränderung des ORBs nötig und damit portable

Interceptor-Ansatz

- Interceptoren fangen Aufrufe ab und vermitteln sie weiter an das replizierte Objekt

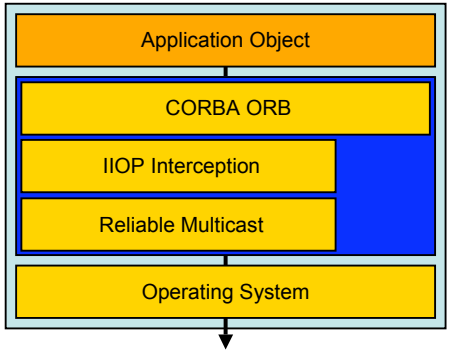

- Nachteil: Interceptoren sind oft spezifisch für ein Betriebssystem
- Vorteil: Transparent für die Anwendung

Kommunikation

- Vorraussetzung für aktive (und teilweise passive) Replikation ist in der Regel ein total geordneter Multicast (*abcast*)
  - Es gibt auf allen Nachrichten eine globale Reihenfolge
- Mögliche Realisierungen
  - Gruppenkommunikation nach dem *Virtual Synchrony Modell*
  - Einigungsalgorithmen (z.B. PAXOS von Lamport)

Kommunikation

Beispiel: JGroups (http://www.jgroups.org)

- Java basierte Gruppenkommunikation
- realisiert Virtual Synchrony Modell
- Protokolle werden pro Applikation konfiguriert
- Beispielkonfiguration für aktive Replikation
  - TCP – Nachrichten werden via TCP übertragen
  - FD – Heartbeat Nachrichten zur Detektion von Ausfällen
  - UNICAST – Nachrichten an einzelne Mitglieder
  - NAKACK – Nachrichten an alle Mitglieder
  - STATE_TRANSFER – Unterstützung für Zustandstransfer
  - GMS – Nachrichten zu Änderungen der Kommunikationsgruppe
  - STABLE – Garbage Collection von Nachrichten
  - TOTAL – Unterstützung für globale Reihenfolge von Nachrichten

Kommunikation

Beispiel: JGroups TOTAL

- Fester Knoten (Sequencer) bestimmt Nachrichtenreihenfolge
- Sequencer vergibt kontinuierliche Sequenznummer
  - UB: Sender an Sequencer, Sequencer an alle
  - BB: Sender an alle, Sequencer an alle
  - UUB: Sender an Sequencer, Sequencer an Sender, Sender an alle
- Empfänger puffert Nachrichten und liefert an Anwendung aus, falls `seqNR(erwartet)==seqNr(Nachricht)`
- Sequenzerausfall: View-Wechsel: Knoten auf gleichen Stand bzgl. alter View bringen, Neubeginn mit neuer View

Andere Beispiele: Spread, Ensemble, Rampart (byzantinisch)

Zustandstransfer

Vorraussetzungen

- Objekt muss die `Checkpointable`-Schnittstelle implementieren
- Erfordert den gesamten Objektzustand als Bytearray bereitzustellen
  - Aufgabe des Entwicklers!
- Sicherungspunkt kann erstellt werden wenn sich das Objekt in einem konsistenten Zustand befindet
  - alle laufenden Aufrufe werden beendet
  - neue Aufrufe werden blockiert

Zustandstransfer

Beispiel: Protokoll eines nicht-blockierenden Zustandstransfers

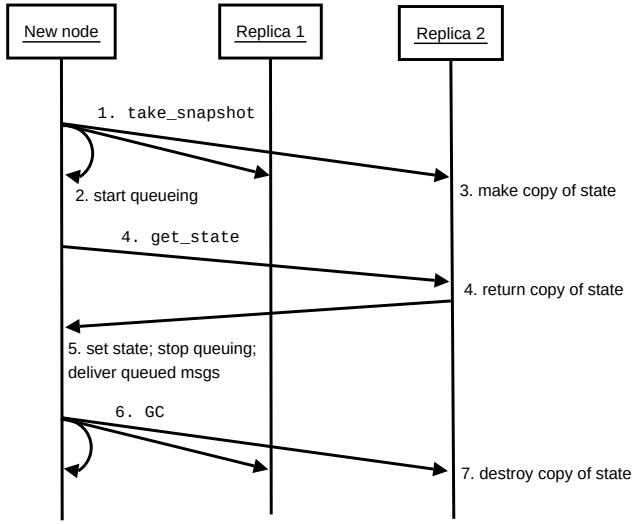

Determinismus bei mehrfädiger Ausführung

- Nicht-replizierte objektbasierte Applikationen sind in der Regel mehrfädig implementiert
- Zielsetzung: Überführung zu replizierten Diensten ohne Veränderung der Anwendung
- **Problem**: Fehlertolerante Infrastrukturen gestatten **meist** nur einfädige Ausführung um Determinismus zu garantieren

Determinismus bei mehrfädiger Ausführung

- *Determinismus* ist zwingend für aktive Replikation
- *Multithreading* ist eine Quelle für Nichtdeterminismus

```
class Simple {
   double state=0;
   void clear() {  synchronized(this) { state=0; }  }
   void inc() {    synchronized(this) { state++; }  }
}
```

- Nichtdeterminimus: C_1 ruft `clear()` auf, C_2 ruft `inc()` auf

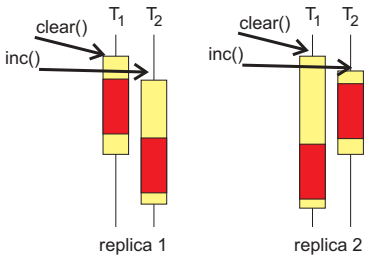

Determinismus bei mehrfädiger Ausführung

Ansatz der meisten Systeme:

abcast + **sequentielle Ausührung von Aufrufen**

Probleme:

- 1: Deadlocks

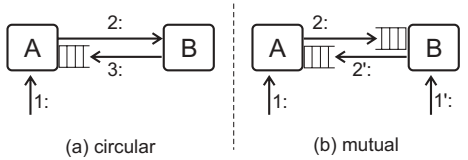

Determinismus bei mehrfädiger Ausführung

Probleme:

- 2: Keine Unterstützung für Konditionvariablen

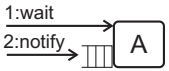

Determinismus bei mehrfädiger Ausführung

Probleme:

- 3: Leerlauf bei verschachtelten Aufrufen

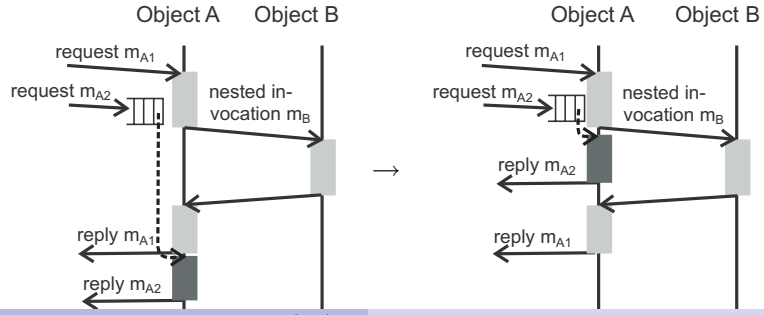

Status quo: Existierende Lösungen

Ansatz der meisten Systeme:

abcast + **sequentielle Ausührung von Aufrufen**

Existierende Lösungen

- Eternal (Narasimhan'99): einzelner logischer Thread
  (Lösung für Problem 1a: *zirkuläre Deadlocks*)
- Jimenez-Peris, Eternal (Zhao'05): ein aktiver Thread
  (Lösung für Problem 1+3: *Deadlocks* und *des Leerlaufs bei verschachtelten Aufrufen*)
- Aspectix DEterministic Thread Scheduler–Single Active Threads (ADETS-SAT), ein aktiver Thread + Unerstützung für Konditionvariablen und des nativen Java Koordinierungsmodels
  - `synchronized` statements, `wait()`, `wait(`*timeout*`)`, `notify()`, `notifyAll()`

Jörg Domaschka, Franz J. Hauck, Hans P. Reiser, Rüdiger Kapitza
Deterministic Multithreading for Java-based Replicated Objects
PDCS 2006 (Dallas, TX, USA, Nov 13-15, 2006); pp. 516-521

ADETS-SAT: Interception durch Codetransformation

Interception der Java Synchronisationsanweisungen durch einen Scheduler

```
public class Queue extends ... {
    public synchronized
            String remove()
    {
        while(data.size()==0)
            wait();
        return data.remove(0);
    }

    public synchronized
        void append(String x)
    {
        data.add(x);
        notify();
    }

}
```

⇒

```
public class Queue extends ... {
    public String remove() {
        _scheduler().lock(this);
        try {
            while(data.size()==0)
                _scheduler().mtwait(this);
            return data.remove(0);
        } finally {
            _scheduler().unlock(this);
        }
    }
    public void append(String x) {
        _scheduler().lock(this);
        try {
            data.add(x);
            _scheduler().mtnotify(this);
        } finally {
            _scheduler().unlock(this);
        }
    } }
```

ADETS-SAT: Annahmen

- Korrekte Koordinierung
  - Zustand wird nur dann verändert wenn das entsprechende Lock angefordert ist
  - Keine implizite (atomare Variablen) oder wait-free Synchronisation
- Keine anderen Quellen für Nichtdeterminismus wie Zufallszahlen etc.

ADETS-SAT: Basiskonzepte

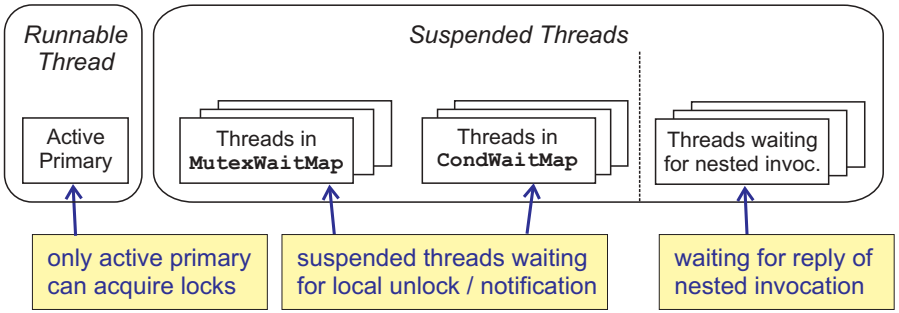

- Es gibt immer genau einen aktiven Thread
- Eine Reihe von blockierten Threads
  - blockierte Threads
  - wartende Threads
  - durch externe Aufrufe blockierte Threads

ADETS-SAT: Interne Zustände

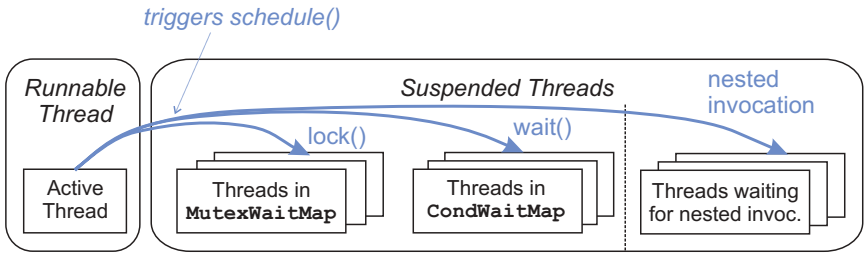

- Übergang auf den nächsten lauffähigen Thread durch den Aufruf von `lock()`, `wait()` oder einer entfernten Methode

ADETS-SAT: Interne Zustände

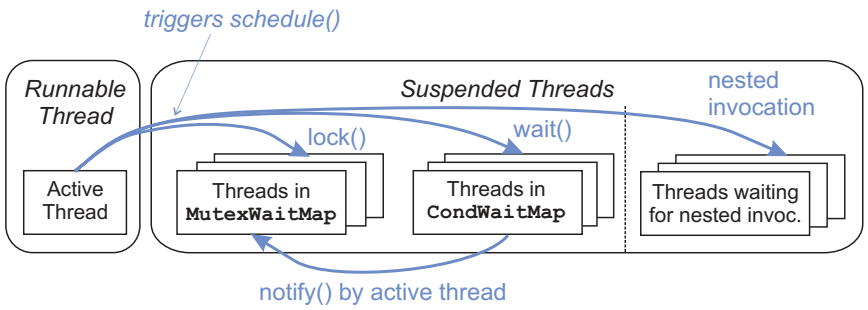

- Wartende Threads werden durch `notify()` in die `MutexWaitMap` verschoben

ADETS-SAT: Interne Zustände

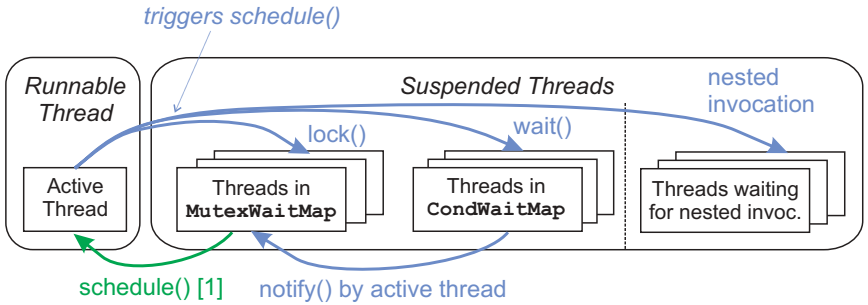

- Schedule macht den ersten Thread aus der `MutexWaitMap` zum neuen aktiven Thread

ADETS-SAT: Interne Zustände

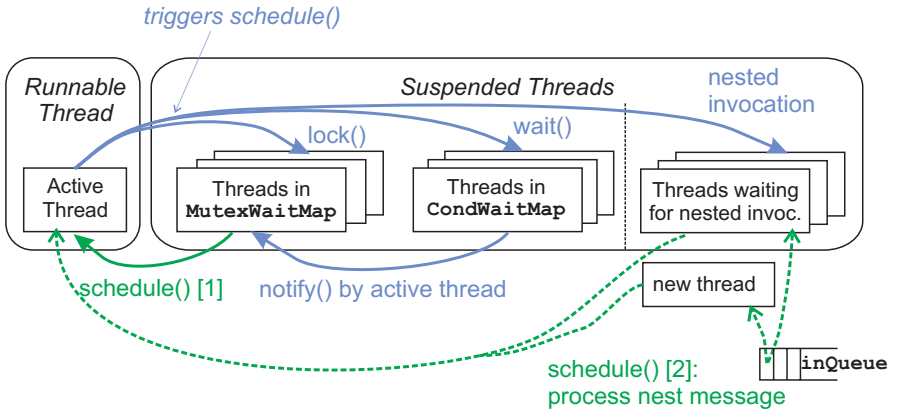

ADETS-SAT: Timeouts

- `wait()`-Zeitschranken können ablaufen

```
class Buffer {
  // [...]
  Object getItem() throws OperationTimeoutExcpetion {
     synchronized(data) {
        if (data.isEmpty())     data.wait(100);
        if (!data.isEmpty())    return data.getNext();
        throw new OperationTimeoutException();
     }
  }
  void putItem(Object obj) {
     synchronized(data) {
        data.append(obj);
        data.notify();
     }
  }
}
```


ADETS-SAT: Timeouts

- `wait(n)` Ablauf einer Zeitschranke nach `n` ms
- Problem explizite Benachrichtigung und Ablauf der Zeitschranke können konkurrieren

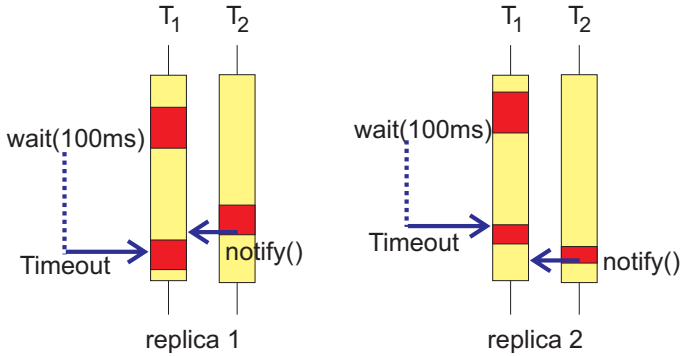

ADETS-SAT: Timeouts

Lösung

- Timeout erzeugt einen eigenen Thread
- Notify-Thread oder Timeout-Thread erhält deterministisch das entsprechende Lock

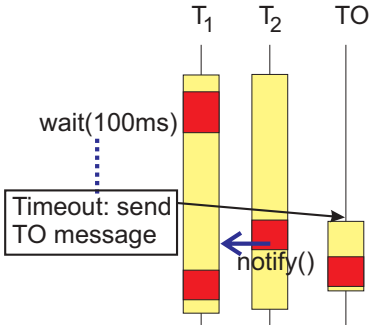

Zusammenfassung

- FT-CORBA bildet einen Standard zu Entwicklung fehlertoleranter Infrastrukturen und Anwendungen
- Durch Middlewaremechanismen und starke Konsistenz sind replizierte Objekte weitgehend transparent für Anwendungen
- Objektimplementierungen müssen angepasst werden
  - Determinismus
  - Zustandstransfer

Zusammenfassung

Kritikpunkte

- Einheit der Replikation: Objekt vs. Prozess
- Nichtdeterminismus muss durch den Anwendungsentwickler behandelt werden
- Zustand: Objekt + Infrastruktur – Zustand der Infrastruktur ist schwer zu ermitteln
- Konfiguration ist kompliziert
- Konsistente Replikation erfordert aufwendige Gruppenkommunikation