Überblick

Replikation
- Grundlagen der Replikation
- JGroups
- Übungsaufgabe 4

Replikation

- Varianten
  - Aktive Replikation
    - Alle Replikate bearbeiten alle Anfragen
    - Vorteil: Schnelles Tolerieren von Ausfällen möglich
    - Nachteil: Vergleichsweise hoher Ressourcenverbrauch
  - Passive Replikation
    - Ein Replikat bearbeitet alle Anfragen
    - Aktualisierung der anderen Replikate erfolgt über Sicherungspunkte
    - Unterscheidung: „Warm passive replication“ vs. „Cold passive replication“
    - Vorteil: Minimierung des Aufwands im fehlerfreien Fall
    - Nachteil: Im Fehlerfall schlechtere Reaktionszeit als bei aktiver Replikation
- Replikationstransparenz
  - Nutzer auf Client-Seite merkt nicht, dass der Dienst repliziert ist
  - Replikatausfälle werden vor dem Nutzer verborgen

Aktive Replikation von Diensten

- Zustandslose Dienste
  - Keine Koordination zwischen Replikaten notwendig
  - Auswahl des ausführenden Replikats z. B. nach Last- oder Ortskriterien
- Zustandsbehaftete Dienste
  - Replikatzustände müssen konsistent gehalten werden
  - Beispiel für inkonsistente Zustände zweier Replikate R_0 und R_1
    - `put()`-Anfragen A_1 („MyKey“, „42“) und A_2 („MyKey“, „0“) von verschiedenen Nutzern
    - Annahme: A_1 erreicht R_0 früher als A_2, bei R_1 ist es umgekehrt

R_0	Key-Value-Speicher
$< init >$	[ ]
A_1	[(„MyKey“, „42“)]
A_2	[(„MyKey“, „0“)]

R_1	Key-Value-Speicher
$< init >$	[ ]
A_2	[(„MyKey“, „0“)]
A_1	[(„MyKey“, „42“)]

  - Sicherstellung der Replikatkonsistenz
    - Alle Replikate müssen Anfragen in derselben Reihenfolge bearbeiten
    - Protokoll/Dienst zur Erstellung einer Anfragenreihenfolge nötig

Aktive Replikation von Diensten

- Weg der Anfrage
  - Senden der Anfrage an ein Replikat
  - Verteilen der Anfrage (z. B. durch ein Gruppenkommunikationssystem)
  - Bearbeitung der Anfrage auf allen Replikaten

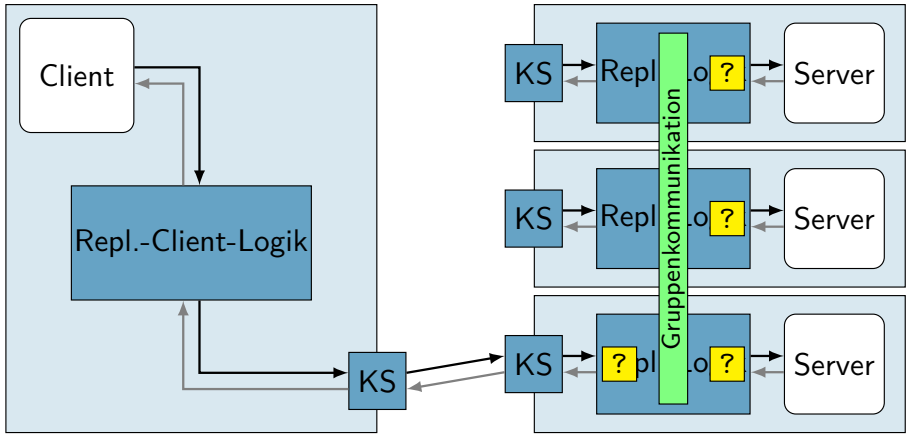

Aktive Replikation von Diensten

- Weg der Antwort
  - Alle Replikate senden ihre Antwort zum Client
  - Im einfachsten Fall: Client akzeptiert schnellste zurückgelieferte Antwort

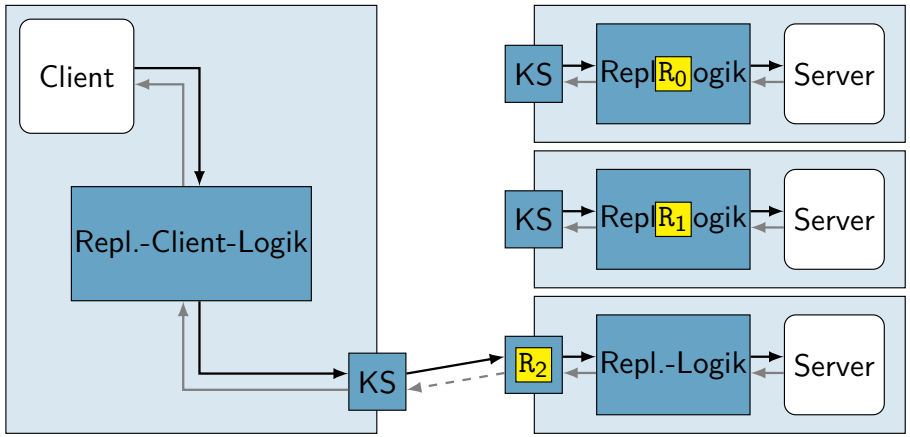

Konsistenz von Replikaten

- Voraussetzung für aktive Replikation: Anwendungsreplikate müssen dieselbe *deterministische Zustandsmaschine* realisieren
  - Identische Ausgangszustände
  - Identische Eingaben [→ Anfragen in derselben Reihenfolge.]
  - ⇒ Identische Zustandsänderungen
  - ⇒ Identische Ausgaben
- Herausforderungen
  - Mehrfädige Programme
    - Zutrittsreihenfolge von kritischen Abschnitten kann unterschiedlich sein
    - Ansatz: Zusätzliche Koordinierung zwischen Replikaten notwendig
  - Nichtdeterministische Systemaufrufe
    - Beispiele: `System.currentTimeMillis()`, `Math.random()`
    - Ansatz: Einigung auf gemeinsamen Wert
  - Seiteneffekte bzw. externalisierte Ereignisse
    - Beispiel: Anwendung greift auf externe Dienste zu [z. B. Rückruf am `VSAuctionEventHandler`]
    - Ansatz: Ein Replikat macht Aufruf, Ergebnisweitergabe an die anderen
  - ...

Überblick

Gruppenkommunikation — Übersicht

- Gruppenkommunikation
  - Zusammenschluss von Knoten zu Gruppen
  - Senden von Nachrichten an die Gruppe (anstatt an jeden Knoten einzeln)
  - Alle Knoten erhalten jede
    - an die Gruppe versendete Nachricht
    - gruppeninterne Statusmeldung

    in derselben Reihenfolge
- Grundlegende Dienste
  - Membership-Service
  - Total-Ordering-Multicast
  - Zustandstransfer-Mechanismus
- Beispiele
  - **JGroups** [`http://www.jgroups.org/index.html`]
  - Spread
  - ...

Membership-Service

- Problemstellungen
  - Zusammensetzung einer Gruppe kann dynamisch variieren
    - Knoten kommen neu hinzu
    - Knoten verlassen die Gruppe
  - Fehlersituationen
    - Verbindungsabbruch zu einzelnen Knoten
    - Gruppenpartitionierung
- Aufgabe des Membership-Service

  Benachrichtigung aller Gruppenmitglieder über die gegenwärtige Zusammensetzung der Gruppe
- JGroups: Schnittstelle `org.jgroups.MembershipListener`
  - Benachrichtigung über Gruppenänderungen

```
void viewAccepted(View new_view);
```

  - Mitteilung eines Ausfallverdachts

```
void suspect(Address suspected_mbr);
```

View

- Aktuelle Sicht auf die Gruppe

  Liste aller aktiven Gruppenmitglieder
- Problem
  - Keine gemeinsame Zeitbasis
  - Was bedeutet also „aktuell“?
- Lösung
  - Änderung der Gruppenzusammensetzung: Erzeugung einer neuen View
  - Aktuelle Teilnehmer einigen sich auf die neue View

  ⇒ Abfolge von Views fungiert als gemeinsame Zeitbasis
- JGroups: Klasse `org.jgroups.View`
  - Ausgabe der Gruppenmitglieder

```
List<Address> getMembers();
```

  - Ausgabe der Gruppengröße

```
int size();
```

Total-Ordering-Multicast

- Problemstellung
  - Clients sollen ihre Anfragen an einen beliebigen Server senden können
  - Alle Server müssen alle Anfragen in derselben Reihenfolge bearbeiten
    - Bewahrung konsistenter Server-Zustände
    - Bereitstellung konsistenter Antworten (z. B. für Fehlertoleranz)
- Total-Ordering-Multicast: Alle aktiven Knoten einer Gruppe bekommen alle Nachrichten in derselben Reihenfolge zugestellt
  - Interne Algorithmen, die
    - jeder Nachricht eine eindeutige Sequenznummer zuweisen → totale Ordnung
    - sicherstellen, dass jeder aktive erreichbare Knoten jede Nachricht erhält
    - dafür sorgen, dass jeder Knoten die Nachrichten in der richtigen Reihenfolge an die Anwendung weiter gibt
  - Hinweis

    Jede Nachricht wird an **alle** Gruppenmitglieder zugestellt; also auch an den Knoten, der die Nachricht ursprünglich gesendet hat

Nachricht

- Klasse `org.jgroups.Message`
  - Kapselung der eigentlichen Nutzdaten
  - Container für Protokoll-Header
  - Konstruktoren

```
Message(Address dst);
Message(Address dst, Address src, Object obj);
[...]
```

    - `dst` Zieladresse; falls `null` → alle
    - `src` Ursprungsadresse; falls `null` → durch JGroups ausgefüllt
    - `obj` Nutzdaten als Payload
  - Wichtigste Methoden

```
Object getObject();
Message copy();
```

    - `getObject()` Getter-Methode für Payload
    - `copy()` Erzeugung einer Kopie der Nachricht

Kommunikationskanal

- Klasse `org.jgroups.JChannel`
  - Konstruktoren

```
JChannel()                      // Standardkonfiguration
JChannel(File properties)       // XML-Datei
JChannel(String properties)     // Konfig. als Zeichenkette
```

  - Wichtigste Methoden
    - Verbindungsaufbau zur Gruppe `cluster_name`

```
void connect(String cluster_name);
```

    - Diverse Getter-Methoden

```
Address getAddress()            // Eigene Adresse
String getClusterName()         // Gruppenname
View getView()                  // Aktuelle View
```

    - Nachrichtenversand

```
void send(Message msg)
void send(Address dst, Object obj)
```

      Hinweis: Senden einer Nachricht an alle → `dst = null` setzen

Nachrichtenempfang: Kombinierte Listener & Adapter

- Kombinierte Schnittstelle: `org.jgroups.Receiver`

```
public interface Receiver extends MembershipListener,
                                  MessageListener {}
```

- Erweiterte Adapterklasse: `org.jgroups.ReceiverAdapter`
  - Implementiert (unter anderem) `Receiver`
  - Eigene Receiver-Klasse als Unterklasse von `ReceiverAdapter`
- Beispiel

```
public class VSReceiver extends ReceiverAdapter {
    public void receive(Message msg) {       // <- MessageListener
        System.out.println("received message " + msg);
    }

    public void viewAccepted(View newView) { // <- MembershipListener
        System.out.println("received view " + newView);
    }
}
```

- Registrierung am `JChannel`

```
void setReceiver(Receiver r);
```

Zustandstransfer (im Allgemeinen)

- Problem
  - Knoten bearbeiten alle Anfragen, um ihre Zustände konsistent zu halten
  - Was ist mit Knoten, die
    - später hinzu kommen, also nicht alle Anfragen kennen
    - mit der Bearbeitung der Anfragen nicht hinterher kommen oder
    - aufgrund eines Fehlers über kaputte Zustandsteile verfügen?
- Lösung: Unterstützung von Zustandstransfers
  - Mit Hilfe der Gruppenkommunikation wird dafür gesorgt, dass ein Knoten (z. B. beim Gruppenbeitritt) eine Kopie des aktuellen Zustands erhält
  - Der aktuelle Zustand stammt von einem Knoten aus der Gruppe

Zustandstransfer (mit Hilfe von JGroups)

- Zusätzliche Methoden des `MessageListener`
  - Bereitstellung des eigenen Zustands

```
void getState(java.io.OutputStream output) throws Exception;
```

  - Setzen des lokalen Zustands

```
void setState(java.io.InputStream input) throws Exception;
```

- Replikatszustand beim Verbindungsaufbau holen (`JChannel`)

```
void connect(String cluster_name, Address target, long timeout)
        throws Exception;
```

- Generelle Schritte
1. Konsistentes Holen des Zustands von existierendem Replikat (`getState()`)
   ↪ Holen des Zustands am besten vom Koordinator mittels

```
channel.connect("gruppe-0", null, 0L);
```

   - Blockiert so lange, bis `setState()` den Zustand eingespielt hat
   - Achtung: `setReceiver()`-Aufruf sollte vorher geschehen sein, da `connect()`-Aufruf sonst unendlich lange blockiert
2. Übertragen des Zustands (→ JGroups)
3. Konsistentes Einspielen des Zustands beim Zielreplikat (`setState()`)

Überblick

Übungsaufgabe 4: Überblick

- Basisfunktionalität (für alle)
  - Implementierung eines Schlüssel-Wert-Speichers (engl. key–value store)
  - Replikation des Speicherdiensts
  - Implementierung der Ausfallsicherung auf Client-Seite
- Erweiterte Variante (optional für 5,0 ECTS)
  - Verifizierung von Ergebnissen
  - Neustarten eines Replikats nach dessen Ausfall

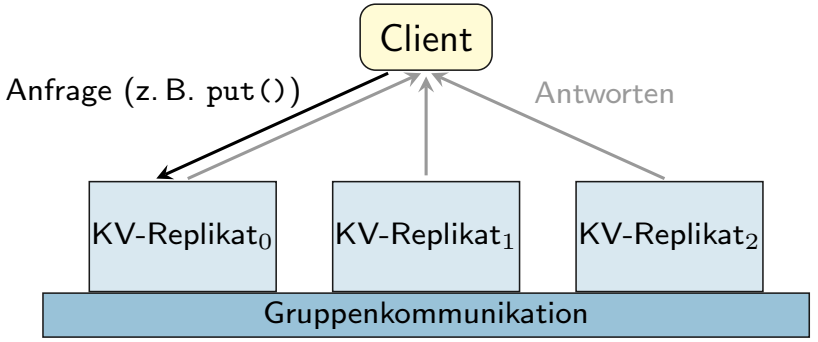

Speicherdienst für Schlüssel-Wert-Paare

```
public class VSKeyValueClient {
  // Basisfunktionalitaet
  public void put(String key, String value) throws RemoteException;
  public String get(String key) throws VSKeyValueException,
                                       RemoteException;
  public void delete(String key) throws RemoteException;
  public long exists(String key) throws RemoteException;

  // Erweiterte Variante (optional fuer 5,0 ECTS)
  public long reliableExists(String key, int threshold)
      throws RemoteException;
}
```

- `put()` (Über-)Schreiben eines Werts `value` unter Schlüssel `key`
- `get()` Abfragen des Datensatzes mit dem Schlüssel `key`
- `delete()` Löschen des Datensatzes mit dem Schlüssel `key`
- `exists()` Prüfen der Existenz eines Schlüssels und ggf. Rückgabe des Zeitstempels der Erstellung oder letzten Aktualisierung
- `reliableExists()` Wie `exists()`, Rückgabe des Ergebnisses aber nur, wenn `#threshold` Replikate dasselbe Ergebnis liefern

Replikation des Speicherdiensts

- Client sendet Anfrage an ein beliebiges Replikat
- Empfang von bis zu #Replikate Antworten

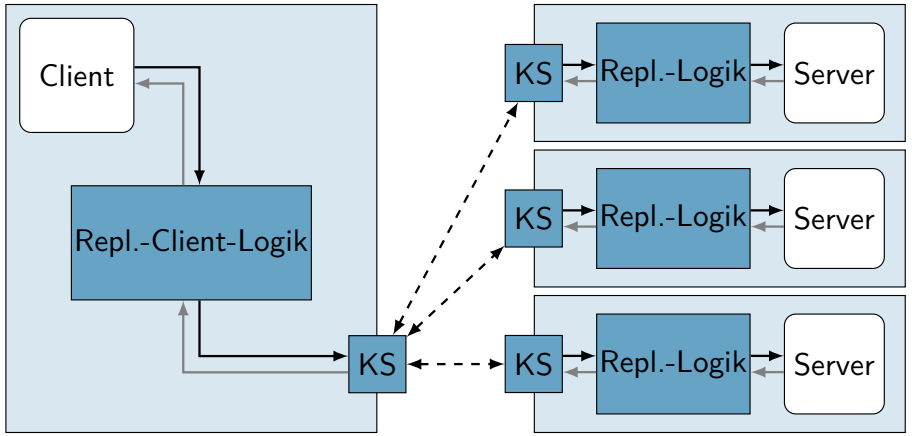

Replikation des Speicherdiensts

- Aktive Replikation des eigenen Fernaufrufsystems
  - Drei Replikate auf verschiedenen Rechnern
  - Alle Replikate bearbeiten alle Anfragen in derselben Reihenfolge
  - Alle Replikate senden ihre Antwort zum Client
- Replikation mittels JGroups
  - JGroups-Bibliothek im Pub-Verzeichnis (`/proj/i4vs/pub/aufgabe4`)
  - Konfiguration für Total-Ordering-Multicast: Einsatz eines *Sequencer*
    - Legt Reihenfolge der Nachrichten fest und verteilt diese an alle Replikate
    - Zu verteilende Nachrichten werden (intern) an den Sequencer geschickt
    - (Interne Sequenznummer ist *nicht* total geordnet)

```
JChannel channel = new JChannel(); // Kanal erstellen

// Erweiterung des Standard-Protokoll-Stacks um Sequencer
ProtocolStack protocolStack = channel.getProtocolStack();
protocolStack.addProtocol(new SEQUENCER());

[...] // Receiver registrieren und Verbindung oeffnen
```

Client-Server-Kommunikation

- Alle Replikate müssen in der Lage sein, den Client zu erreichen
- Antwortübermittlung von Replikaten zu Clients mittels Rückrufen
  - Replikat implementiert `handleRequest()`-Methode, die vom Client (fern-)aufgerufen werden kann

```
public interface VSKeyValueRequestHandler extends Remote {
  public void handleRequest(VSKeyValueRequest request)
      throws RemoteException;
}
```

  ↪ Mögliche Implementierung:
  Remote-Referenz des Client ist Bestandteil der Anfragenachricht

  - Client implementiert `handleReply()`-Methode, die von den Replikaten (fern-)aufgerufen werden kann

```
public interface VSKeyValueReplyHandler extends Remote {
  public void handleReply(VSKeyValueReply reply)
      throws RemoteException;
}
```

Client-Server-Kommunikation: Gesamtüberblick

- Methodenfernaufrufe erfolgen über Java RMI
- Jedes Replikat verfügt über eigene (RMI-)Registry

→ Clients erhalten Replikat-Stubs (S_{R_0}, S_{R_1}, S_{R_2}) über jeweilige Registry

- Replikate nutzen jeweiligen Client-Stub (S_C) zur Antwortrückgabe

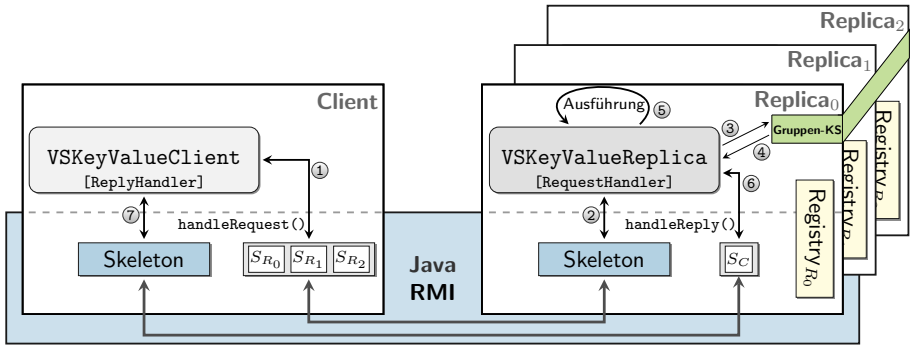

Referenzierung von Diensten/Replikaten

- Problem: Clients müssen Replikatreferenzen bekanntgemacht werden

→ Bekanntmachen und Festlegen der Adressen (`Hostname:Port`) der einzelnen Replikat-Registrys über dieselbe Datei

- Beispieldatei (Dateiname: `replica.addresses`)

```
faui00a:12345
faui00b:12346
faui00c:12347
```

→ 1. Zeile korrespondiert zu Replikat 0, 2. Zeile zu Replikat 1 usw.

- Beispielkommandozeilenaufruf
  - Client

```
java -cp <classpath> vsue.replica.VSKeyValueClient replica.addresses
```

  - Server (Starten von Replikat 0 ⇔ 1. Zeile)

```
java -cp <classpath> vsue.replica.VSKeyValueReplica 0 replica.addresses
```

Logging in JGroups

- Konfiguration
  - Granularitätsstufen: `OFF`, `SEVERE`, `WARNING`, `INFO`, `FINE`, `FINER`, `ALL`,...
  - Konfiguration in Datei
  - Programmstart

```
java -Djava.util.logging.config.file=<Datei> <Programm>
```

- Beispiele für Konfigurationsdateien
  - Ausgabe der Log-Meldungen auf der Konsole (Stufe: `FINE`)

```
handlers=java.util.logging.ConsoleHandler
.level=FINE
```

  - Ausgabe der Log-Meldungen in einer Datei `vs.log` (Stufe: `INFO`)

```
handlers=java.util.logging.FileHandler
.level=INFO
java.util.logging.FileHandler.pattern=vs.log
```

Ausfallsicherung auf Client-Seite

- Wechsel des Replikats bei Verbindungsabbrüchen
- Client implementiert selbst verschiedene Strategien zum Wechsel eines Replikats

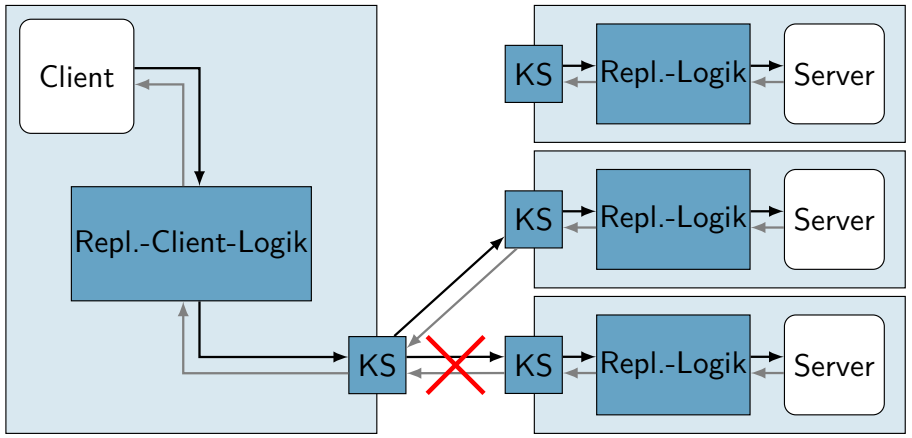

Verifizierung von Ergebnissen

- `exists()` liefert stets schnellste, aber evtl. fehlerhafte Antwort
- Bei Verwendung von `reliableExists()` erfolgt Vergleich mehrerer Antworten, um falsche Antworten zu erkennen

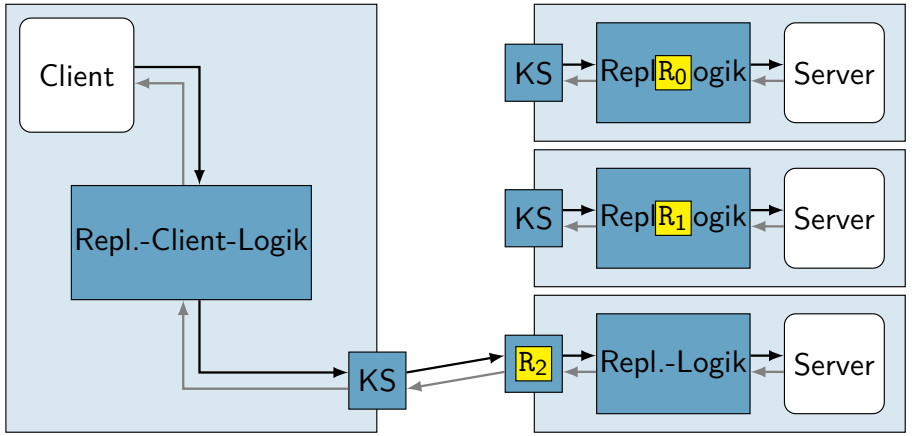

Neustart nach Replikatausfall

- Problem
  - `VSKeyValueReplica`-Implementierung verwaltet ihren Zustand im Hauptspeicher
  - Datenverlust bei Ausfall eines Replikats

  → Kein Neustart des Replikats möglich

- Lösung
  - Verwendung von JGroups für Zustandstransfer (siehe Folie 15f.)
    - Annahme: Zu jeder Zeit ist mindestens ein Replikat verfügbar
    - Neustart: Holen des Zustands von einem anderen Replikat
  - Implementieren von `getState()`/`setState()` zum Auslesen/Serialisieren und Setzen/Deserialisieren des Zustands
  - Zustandstransfer und Nachrichtenempfang sind voneinander entkoppelt, d. h. Zustellung totalgeordneter Nachrichten ist asynchron zu Zustandstransfer

    → Erweiterter `connect()`-Aufruf garantiert, dass Nachrichten erst nach Abschluss des Zustandstransfers eintreffen

    → `{get,set}State()`- und `receive()`-Aufrufe müssen synchronisiert werden

    → Konsistenzwahrung beim Zustandstransfer ist Teil der Replikatlogik