# Beachte:

- Threads, die auf Beendigung eines anderen Threads warten, gehen in einen Zustand joining über.
- Threads, die auf Beendigung einer IO-Operation warten, gehen in einen Zustand joiningIO über.
- Diese Zustände ähneln dem Zustand blocked für wechselseitigen Ausschluss von kritischen Abschnitten. Insbesondere gibt es
- ... für jeden Thread t eine Schlange `ThreadQueue joiningThreads;`
- ... analoge Warteschlangen für verschiedene IO-Operationen.

# Beachte:

- Threads, die auf Beendigung eines anderen Threads warten, gehen in einen Zustand joining über.
- Threads, die auf Beendigung einer IO-Operation warten, gehen in einen Zustand joiningIO über.
- Diese Zustände ähneln dem Zustand blocked für wechselseitigen Ausschluss von kritischen Abschnitten. Insbesondere gibt es
- ... für jeden Thread t eine Schlange `ThreadQueue joiningThreads;`
- ... analoge Warteschlangen für verschiedene IO-Operationen.

Spaßeshalber betrachten wir noch eine kleine Variation des letzten Programms:

```
public class CW implements Runnable {
   private static int count = 0;
   private int n = count++;
   private static Thread[] task = new Thread[3];
   public void run() {
      try { task[(n+1)%3].join(); }
      catch (InterruptedException e) {
         System.err.println(e.toString());
      }
   }
   public static void main(String[] args) {
      for(int i=0; i<3; i++)
         task[i] = new Thread(new CW());
      for(int i=0; i<3; i++) task[i].start();
   }
}  // end of class CW
```

- Jeder Thread geht in einen Wartezustand (hier: joining) über und wartet auf einen anderen Thread.
- Dieses Phänomen heißt auch Circular Wait oder Deadlock – eine unangenehme Situation, die man in seinen Programmen tunlichst vermeiden sollte :-)

## 19.2 Semaphore und das Producer-Consumer-Problem

# Aufgabe:

- Zwei Threads möchten mehrere/viele Daten-Objekte austauschen.
- Der eine Thread erzeugt die Objekte einer Klasse `Data` (Producer).
- Der andere konsumiert sie (Consumer).
- Zur Übergabe dient ein Puffer, der eine feste Zahl `N` von `Data`-Objekten aufnehmen kann.

Producer
Consumer

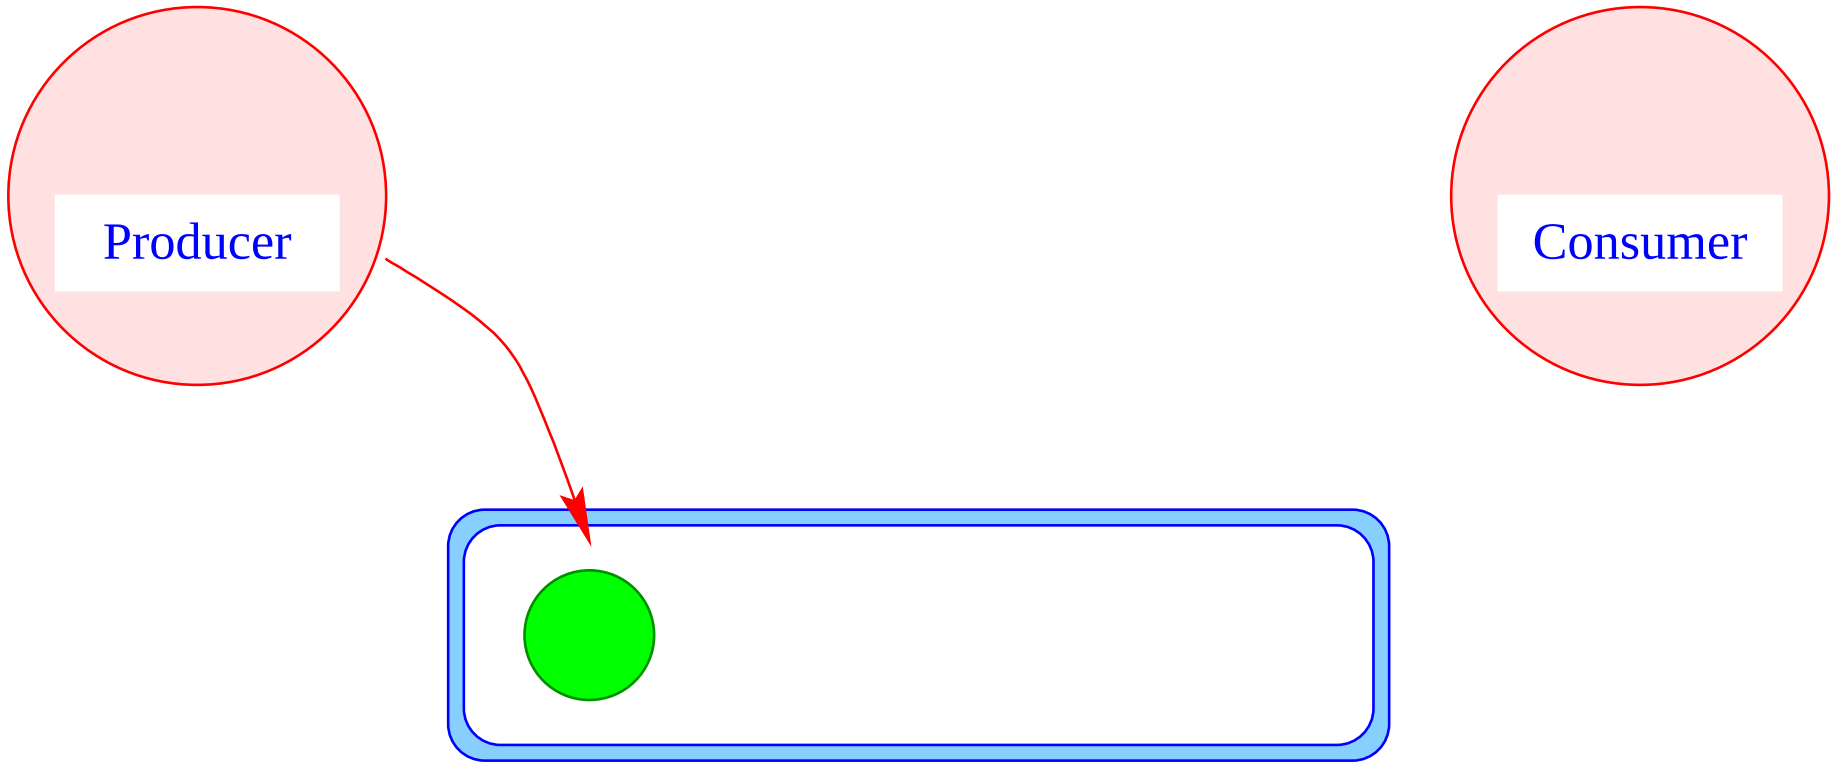
Producer
Consumer

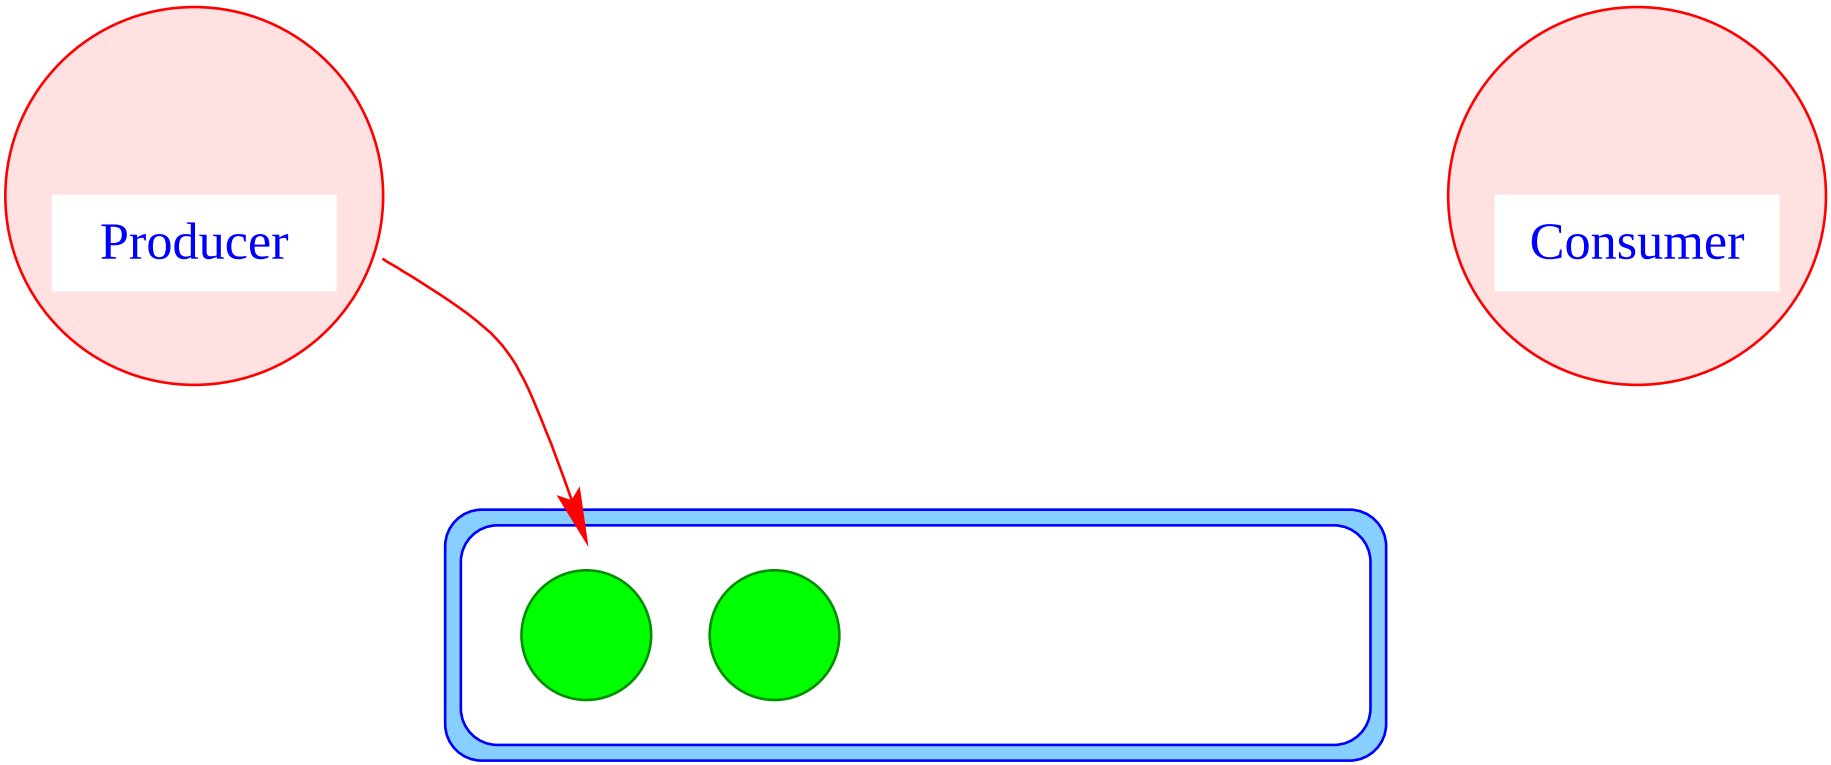
Producer
Consumer

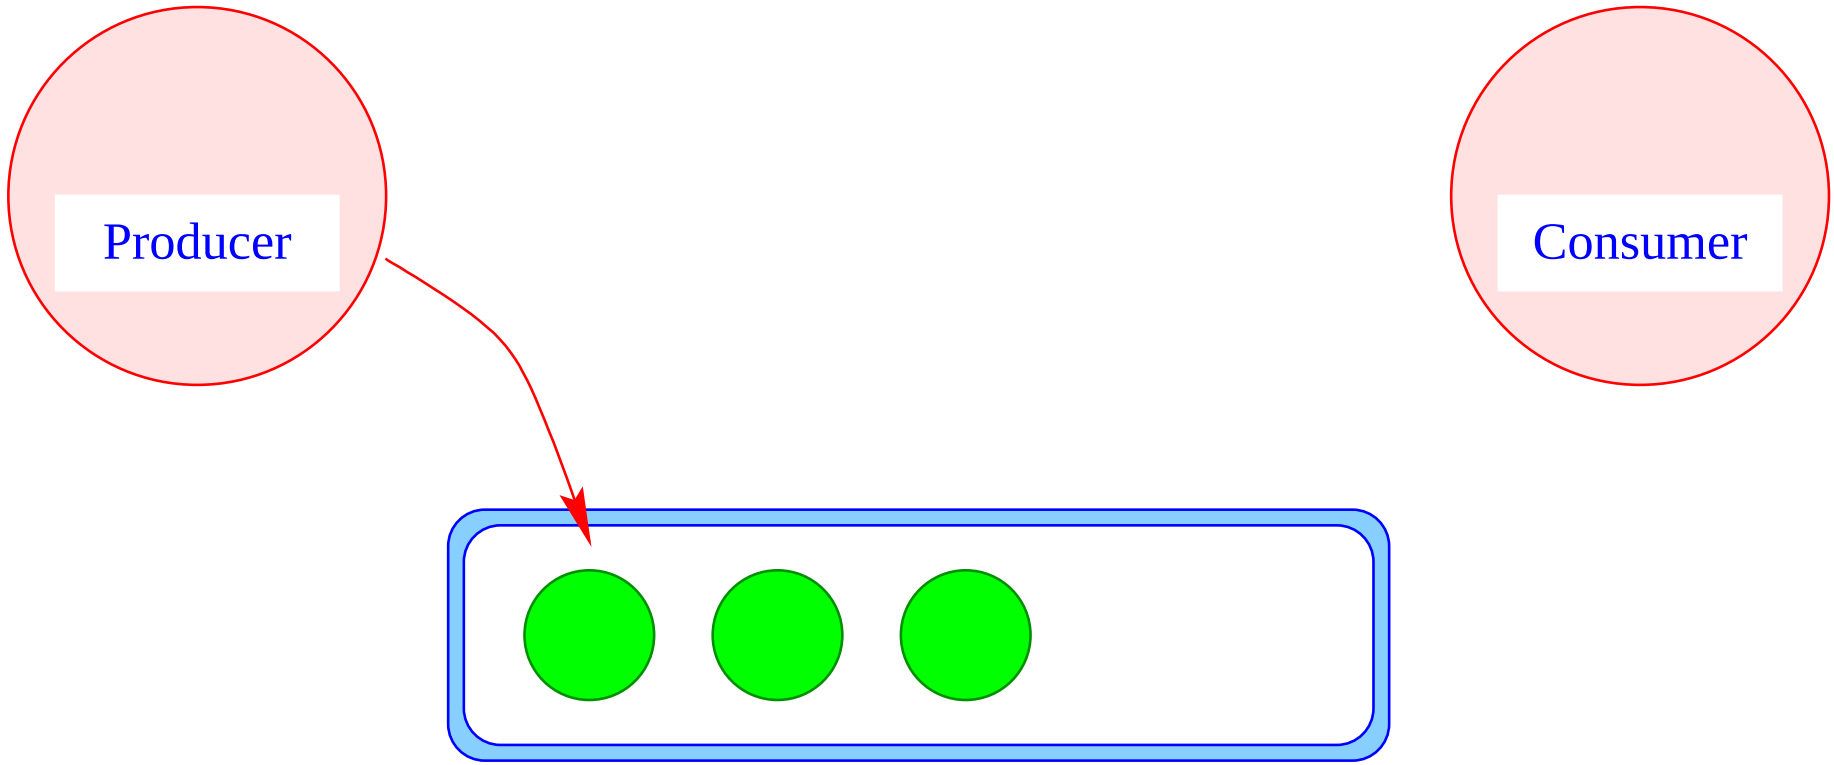
Producer
Consumer

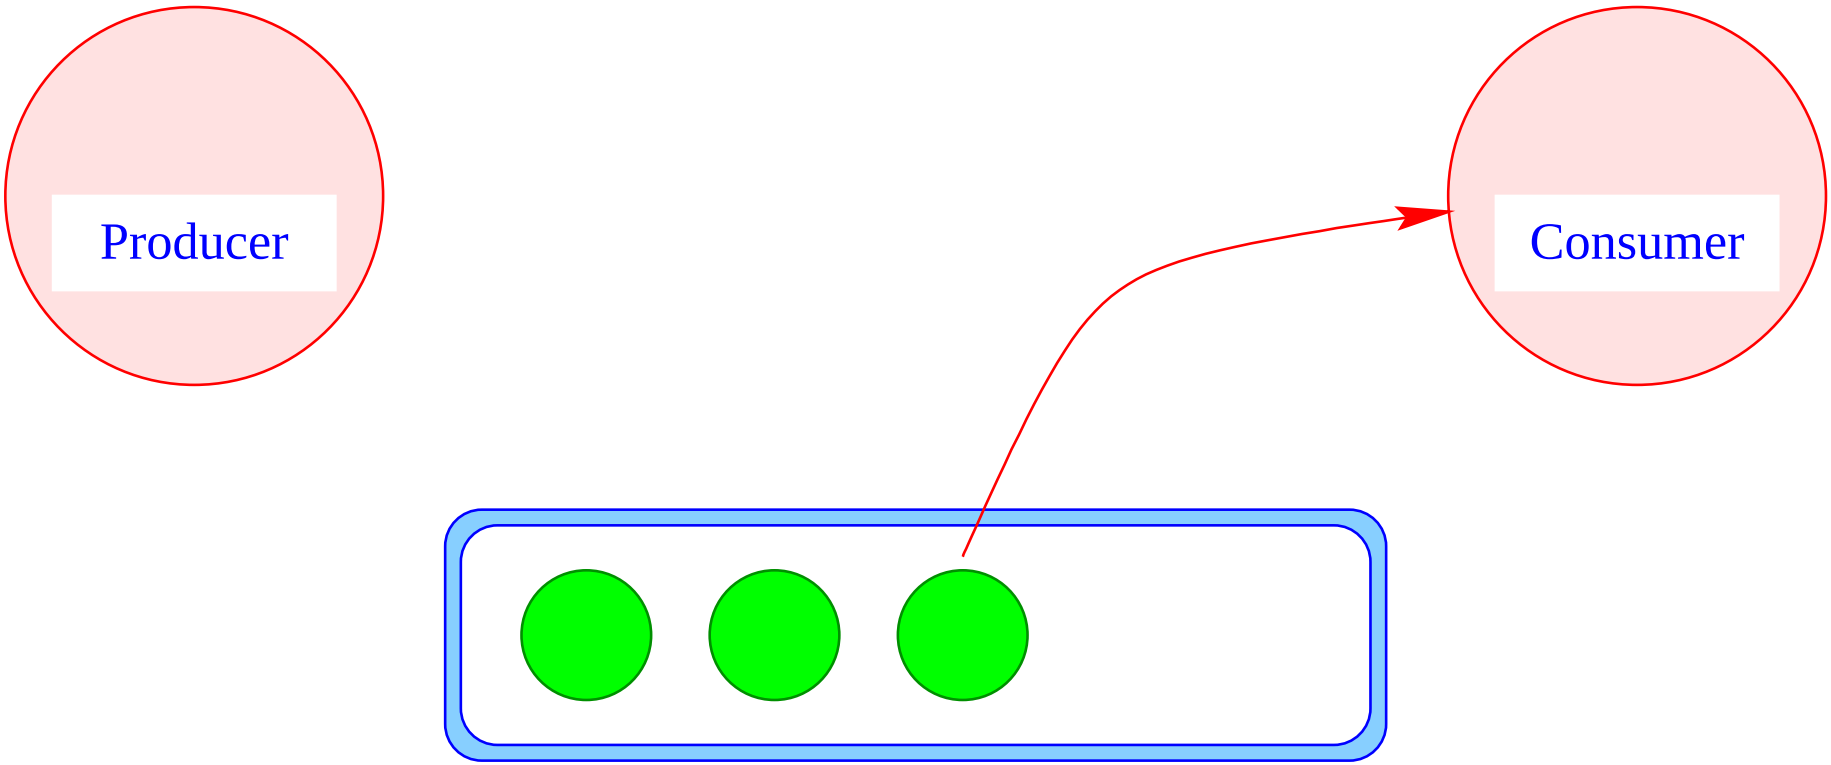
Producer
Consumer

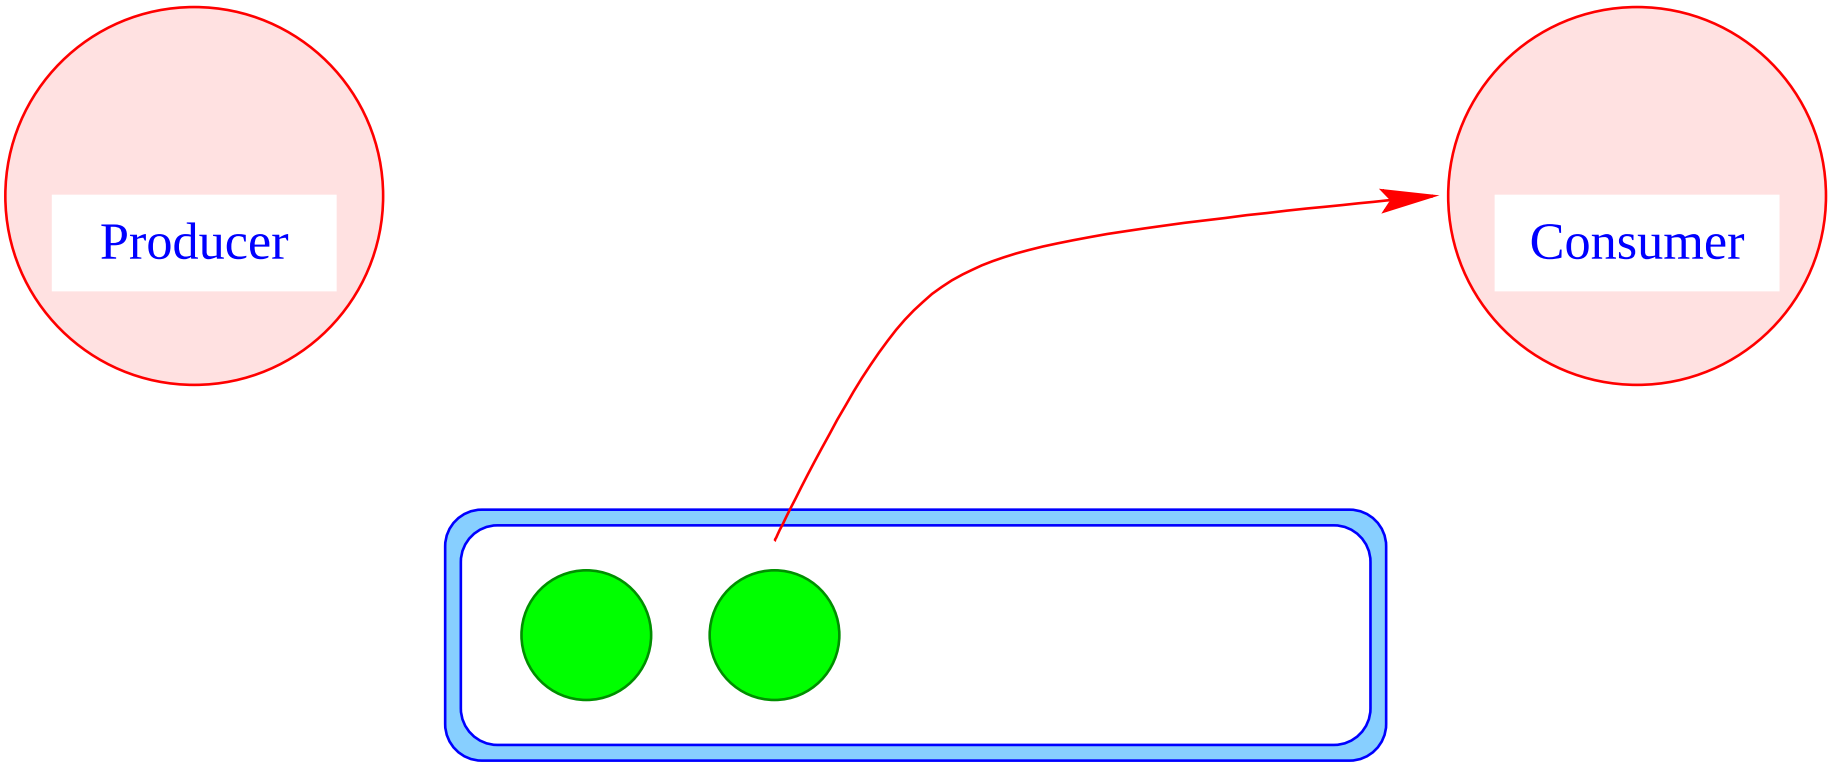
Producer
Consumer

# 1. Idee:

- Wir definieren eine Klasse `Buffer2`, die (im wesentlichen) aus einem Feld der richtigen Größe, sowie zwei Verweisen `int first, last` zum Einfügen und Entfernen verfügt:

```
public class Buffer2 {
   private int cap, free, first, last;
   private Data[] a;
   public Buffer2(int n) {
      free = cap = n; first = last = 0;
      a = new Data[n];
   }
   ...
```

- Einfügen und Entnehmen sollen synchrone Operationen sein ...

# Probleme:

- Was macht der Consumer, wenn der Producer mit der Produktion nicht nachkommt, d.h. der Puffer leer ist?
- Was macht der Producer, wenn der Consumer mit der Weiterverarbeitung nicht nach kommt, d.h. der Puffer voll ist?

## Probleme:

- Was macht der Consumer, wenn der Producer mit der Produktion nicht nachkommt, d.h. der Puffer leer ist?
- Was macht der Producer, wenn der Consumer mit der Weiterverarbeitung nicht nach kommt, d.h. der Puffer voll ist?

## Java's Lösungsvorschlag: Warten ...

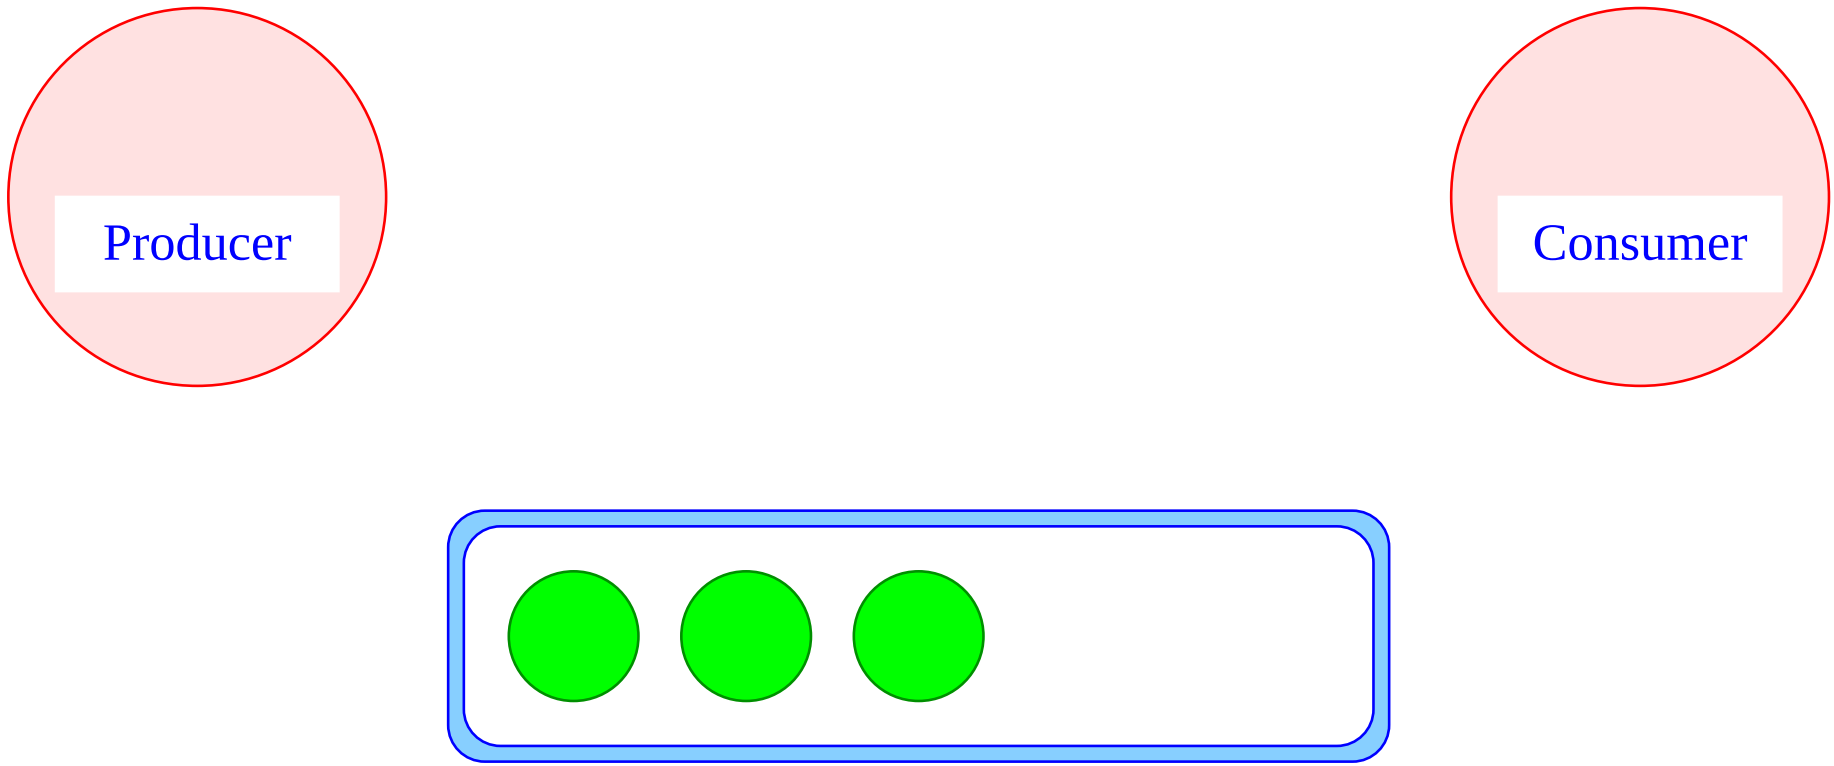
Producer
Consumer

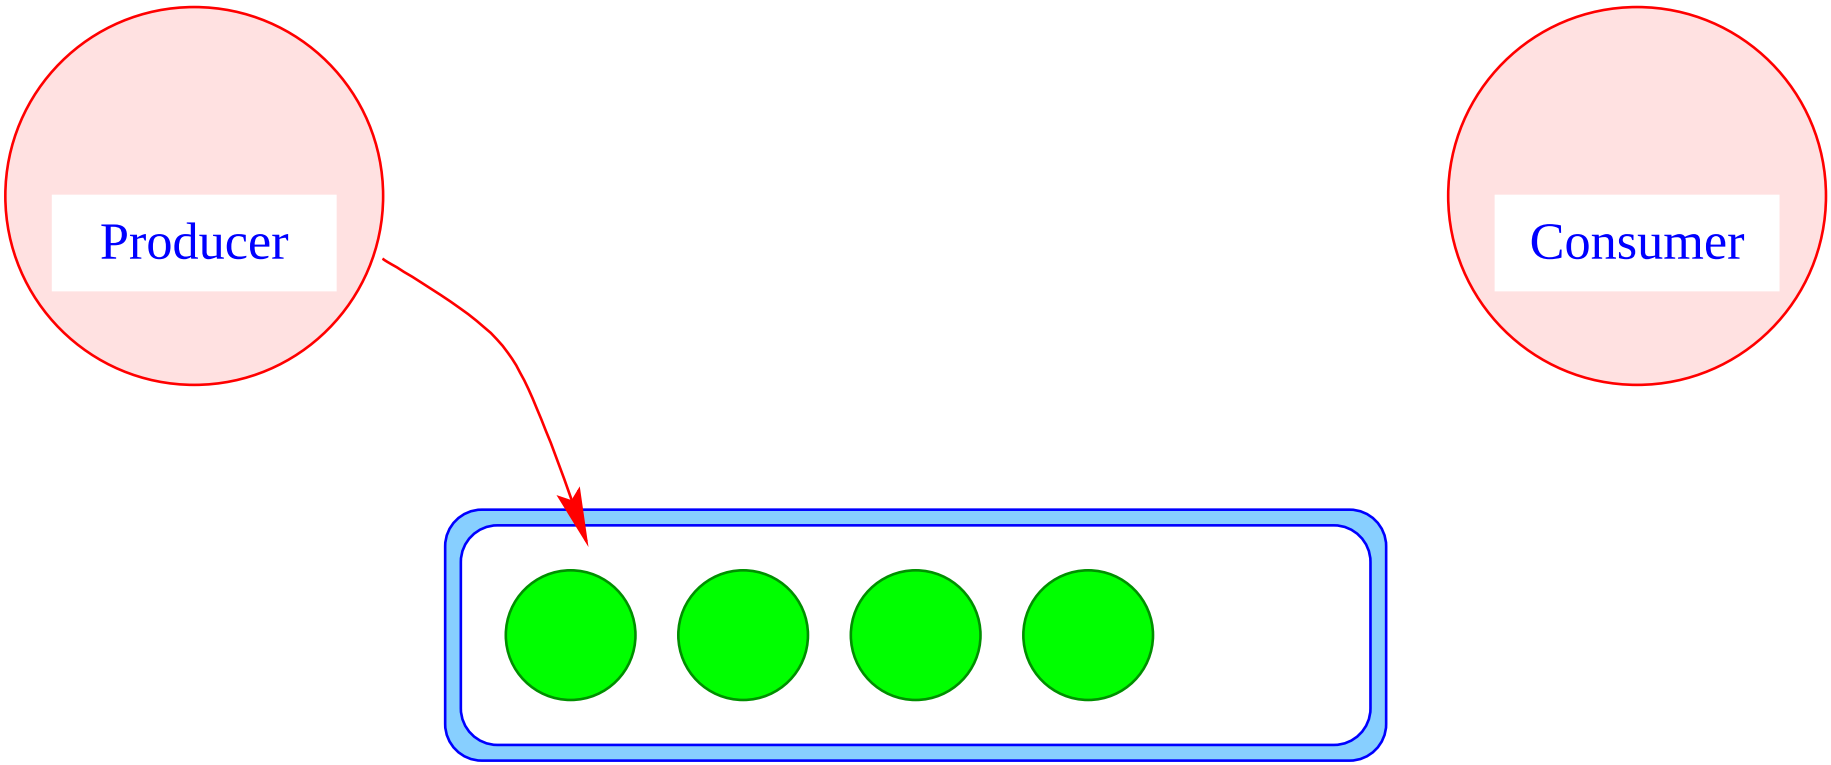
Producer
Consumer

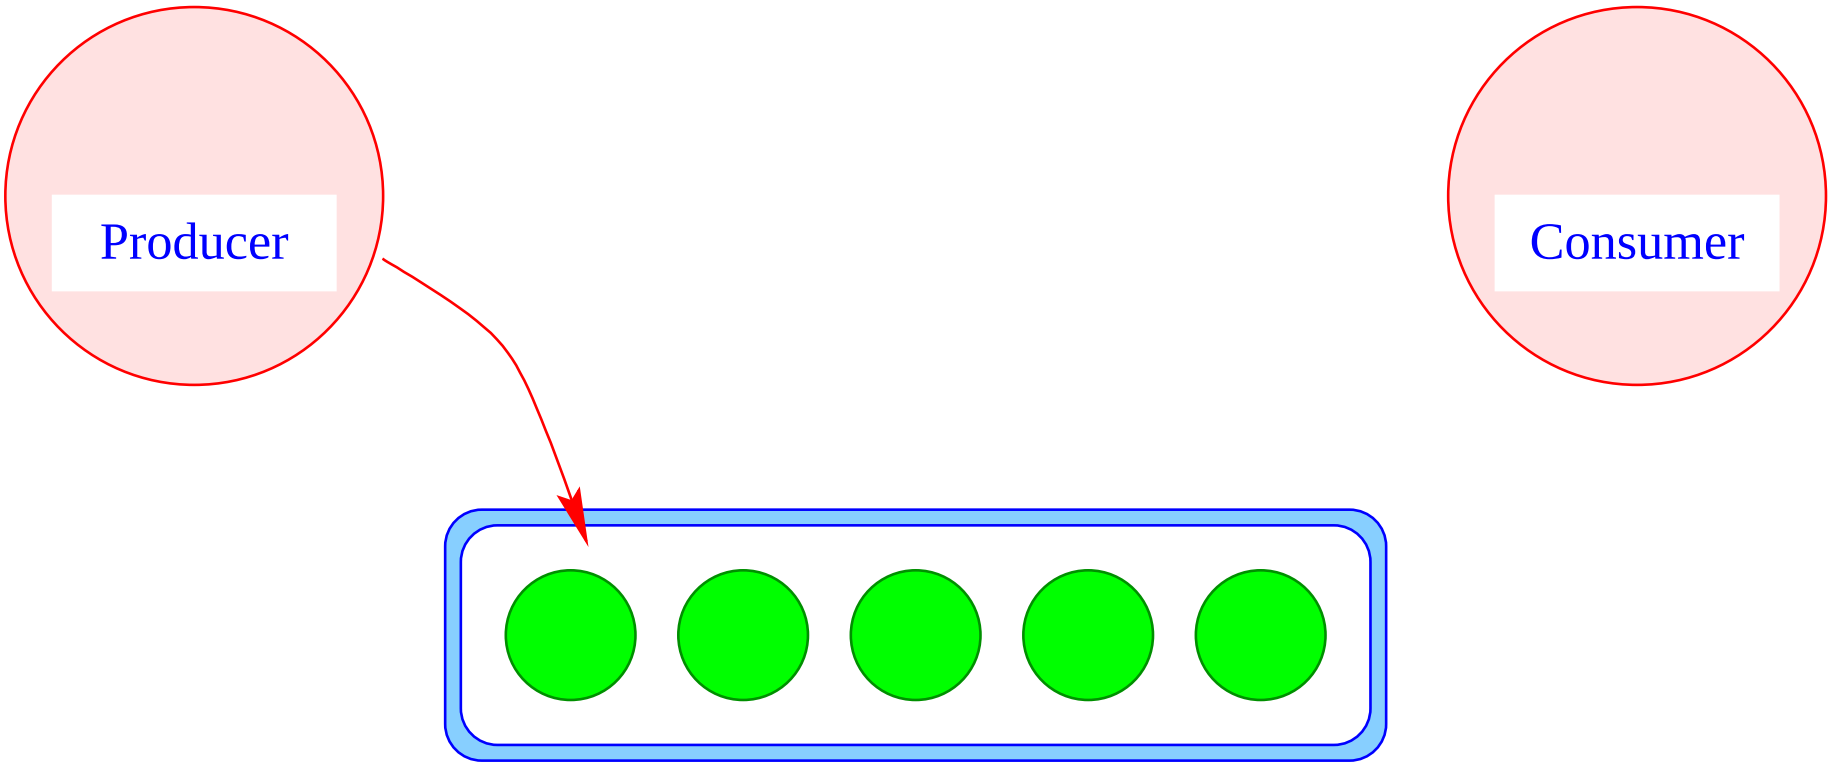
Producer
Consumer

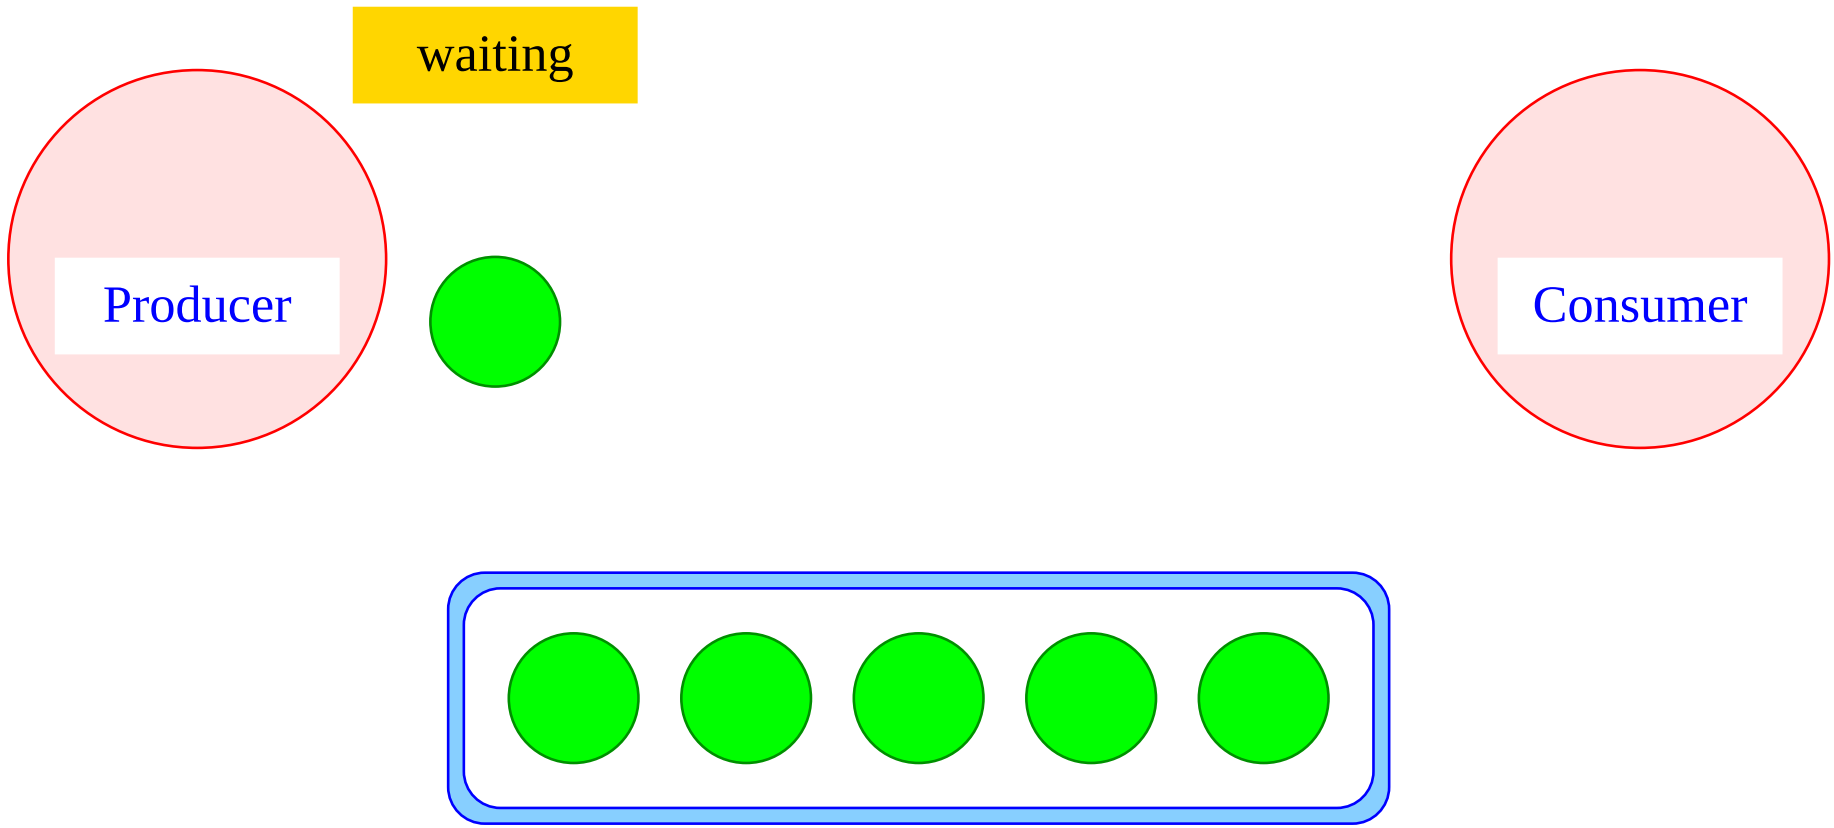
waiting
Producer
Consumer

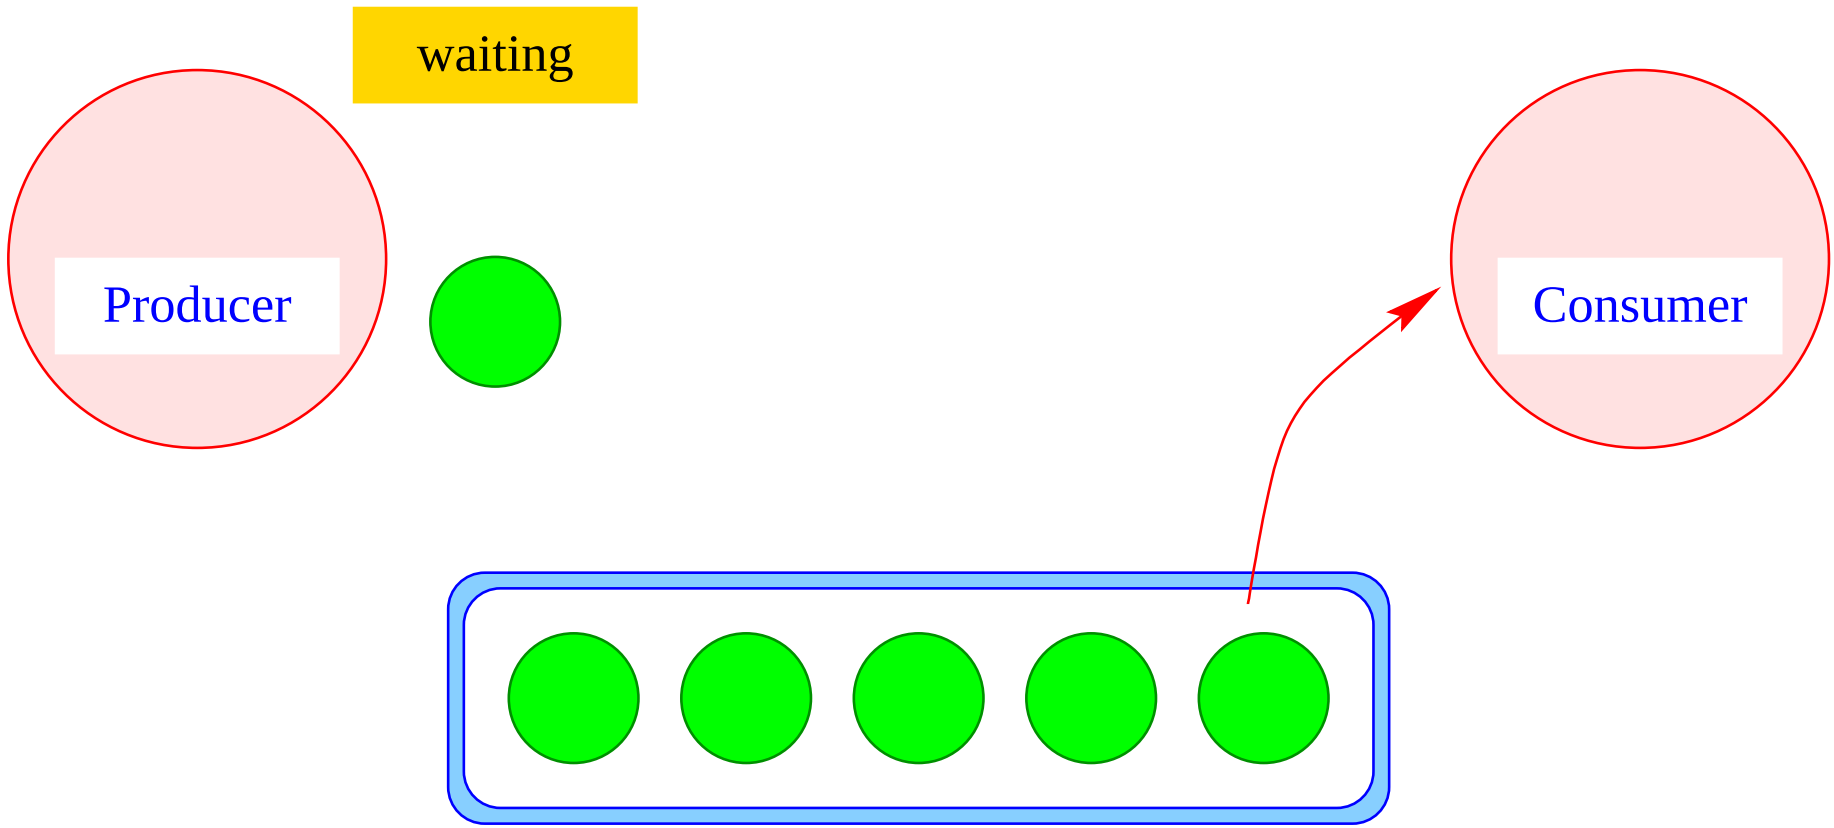
waiting
Producer
Consumer

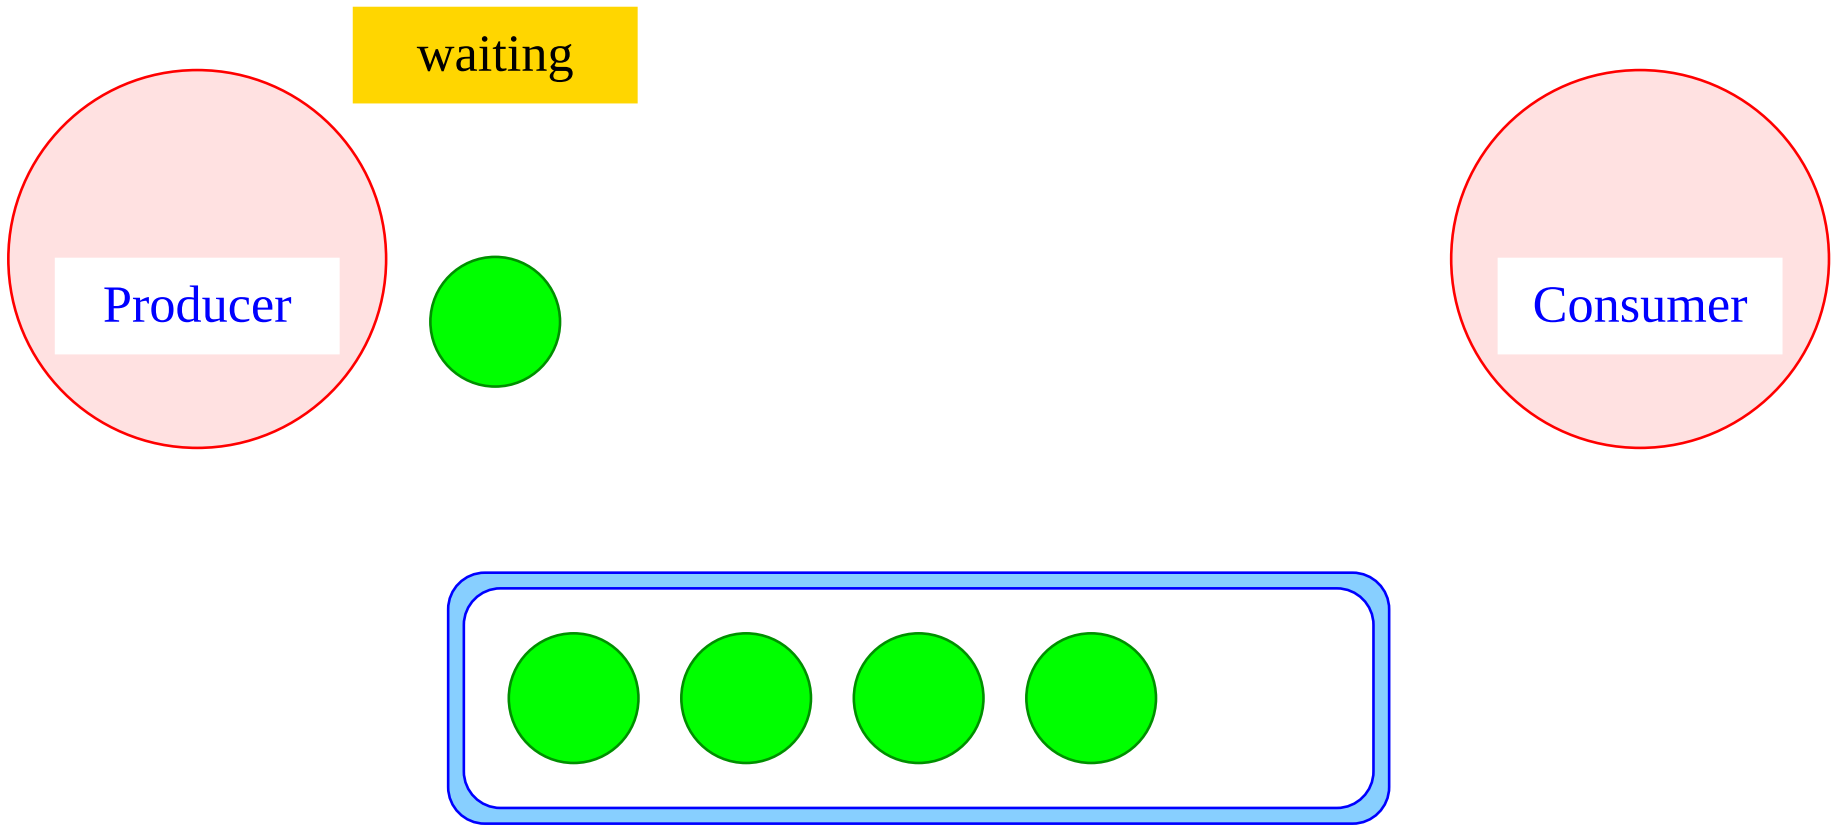
waiting
Producer
Consumer

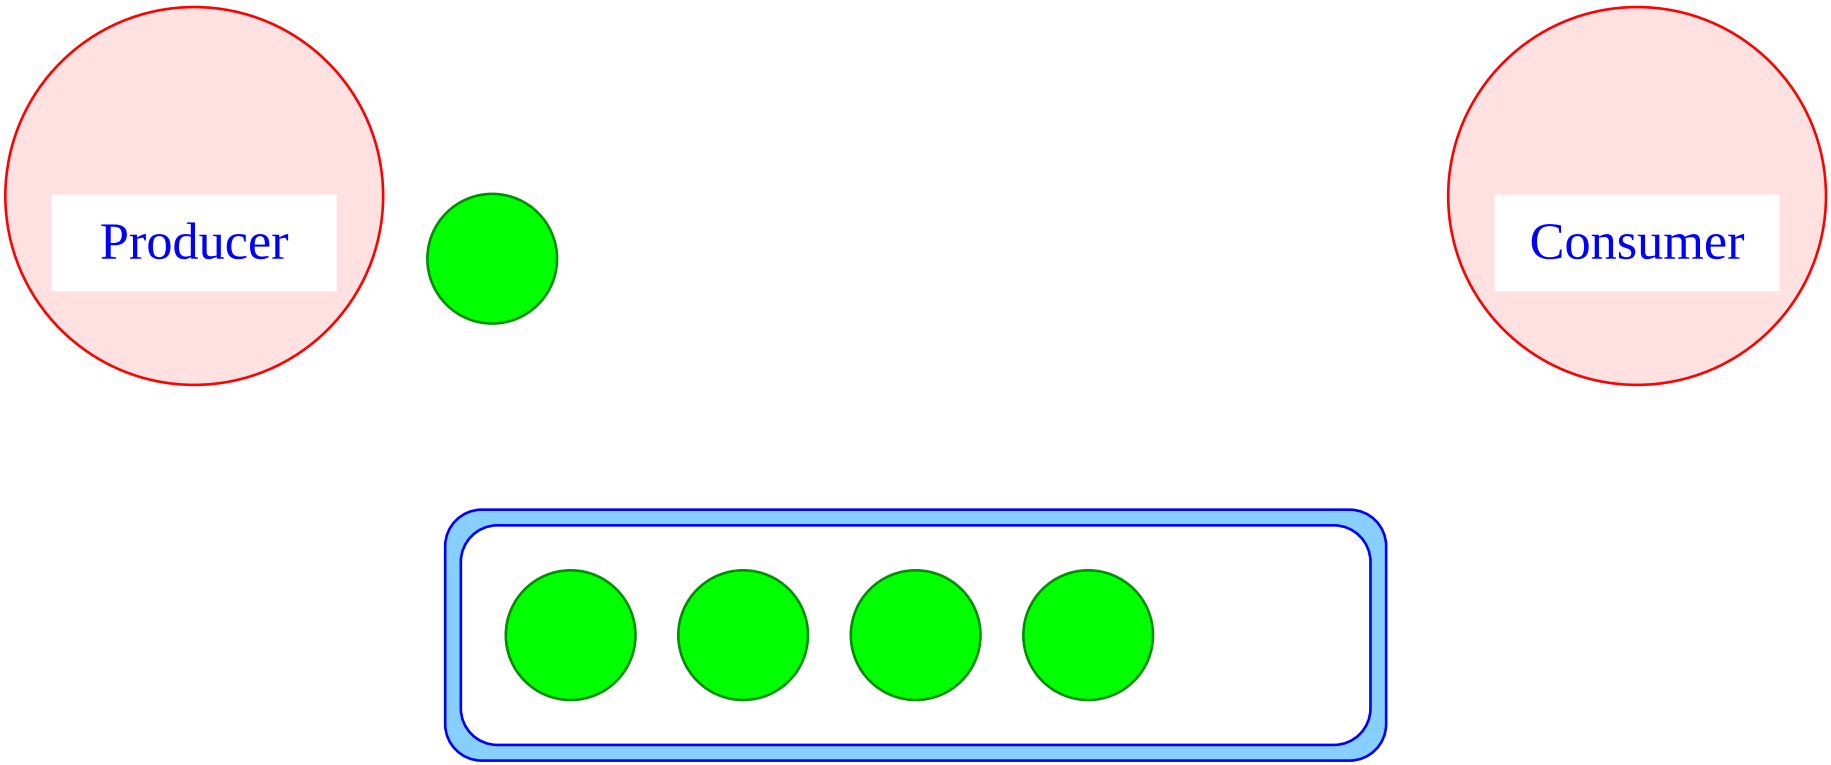
Producer
Consumer

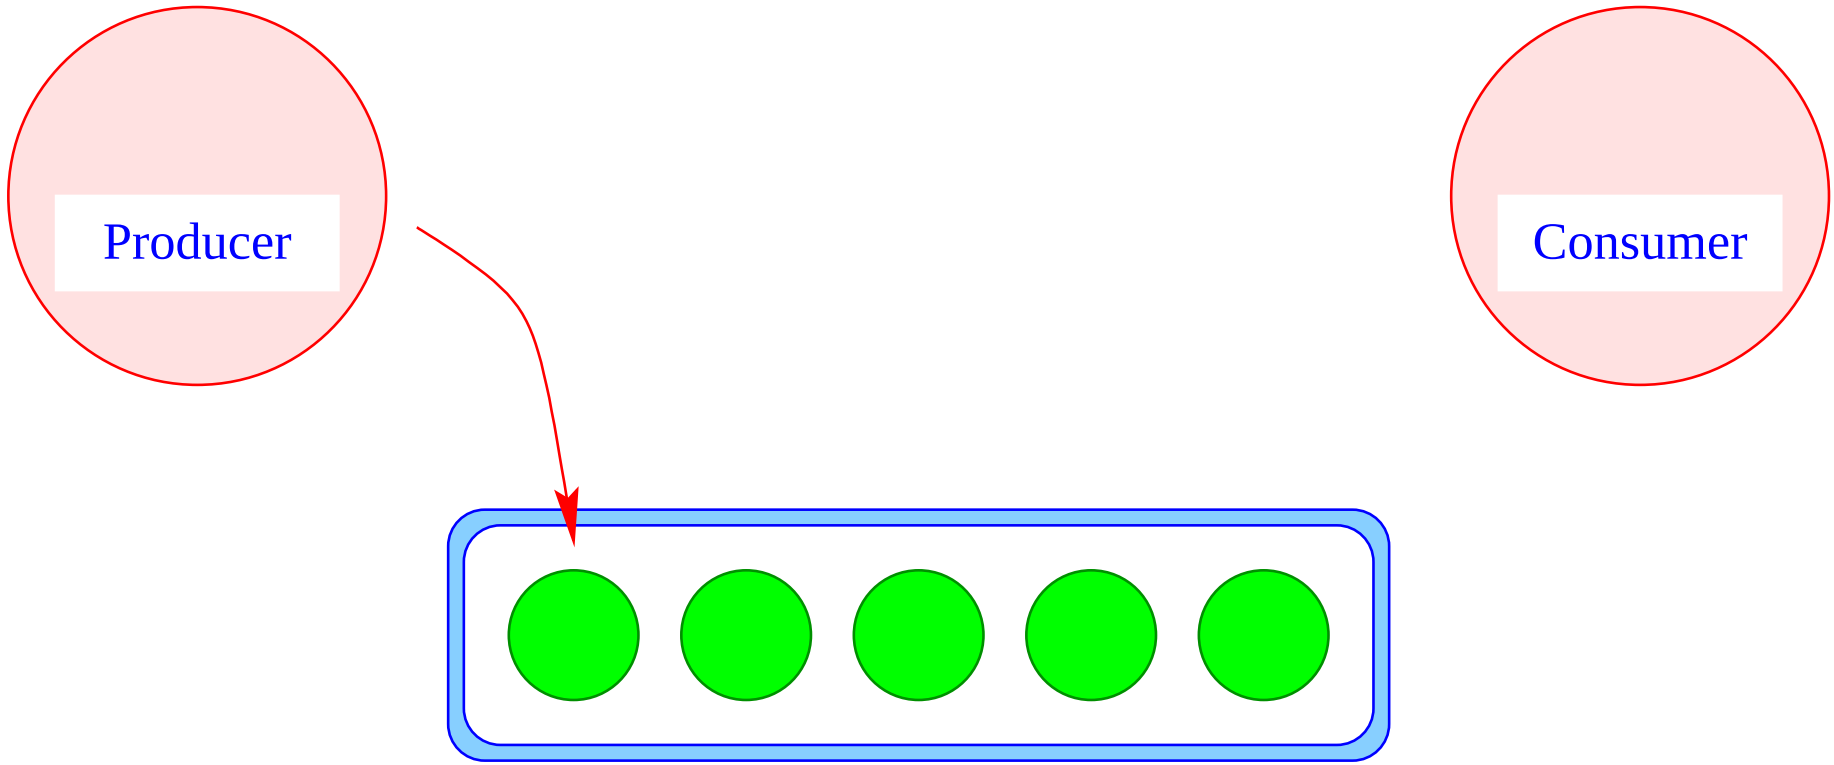
Producer
Consumer

- Jedes Objekt (mit `synchronized`-Methoden) verfügt über eine weitere Schlange `ThreadQueue waitingThreads` am Objekt wartender Threads sowie die Objekt-Methoden:

  ```
  public final void wait() throws InterruptedException;
  ```

  ```
  public final void notify();
  ```

  ```
  public final void notifyAll();
  ```

- Diese Methoden dürfen nur für Objekte aufgerufen werden, über deren Lock der Thread verfügt !!!
- Ausführen von `wait();` setzt den Zustand des Threads auf waiting, reiht ihn in eine geeignete Warteschlange ein, und gibt das aktuelle Lock frei:

```
public void wait() throws InterruptedException {
   Thread t = Thread.currentThread();
   t.state = waiting;
   waitingThreads.enqueue(t);
   unlock();
}
```

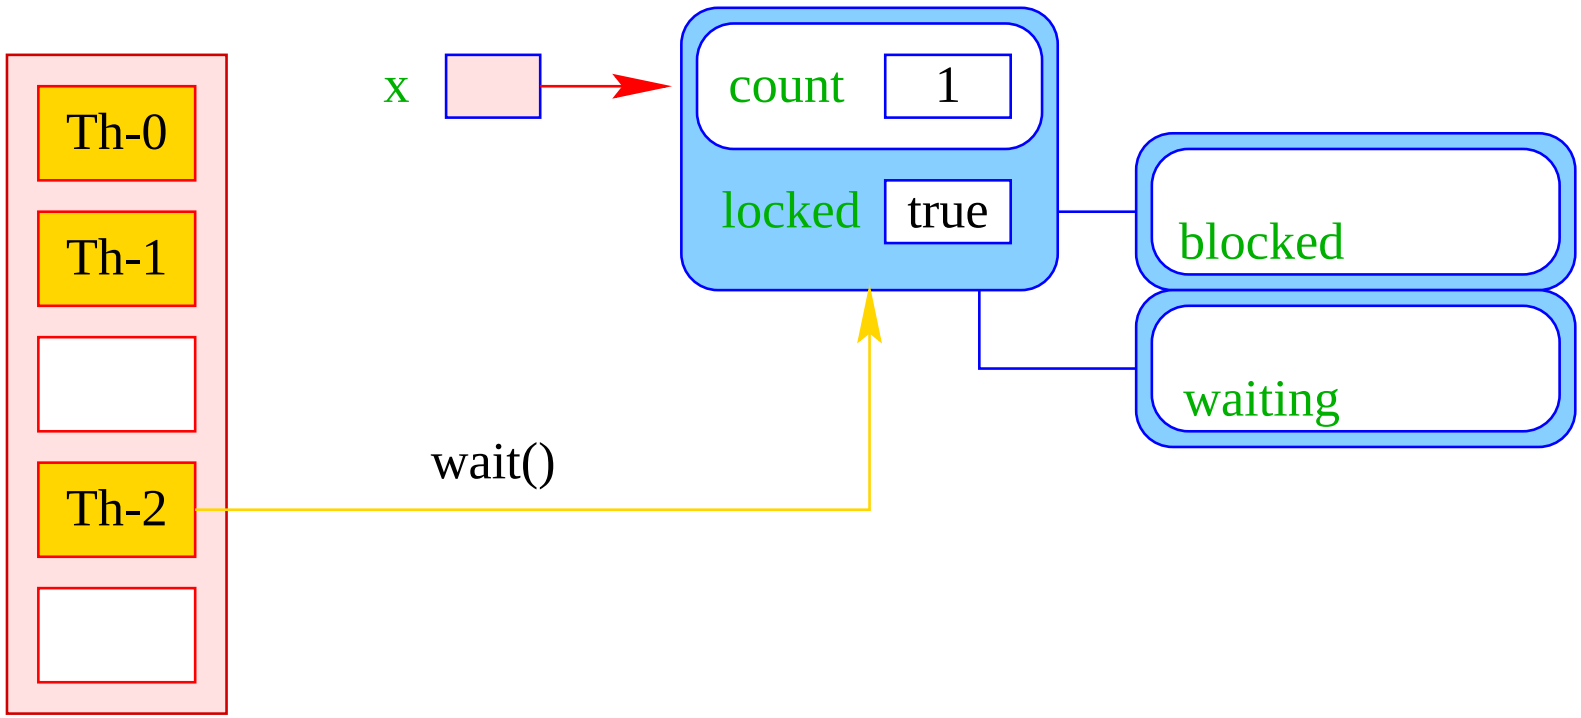
Th-0
Th-1
Th-2
x
count
1
locked
true
blocked
waiting
wait()

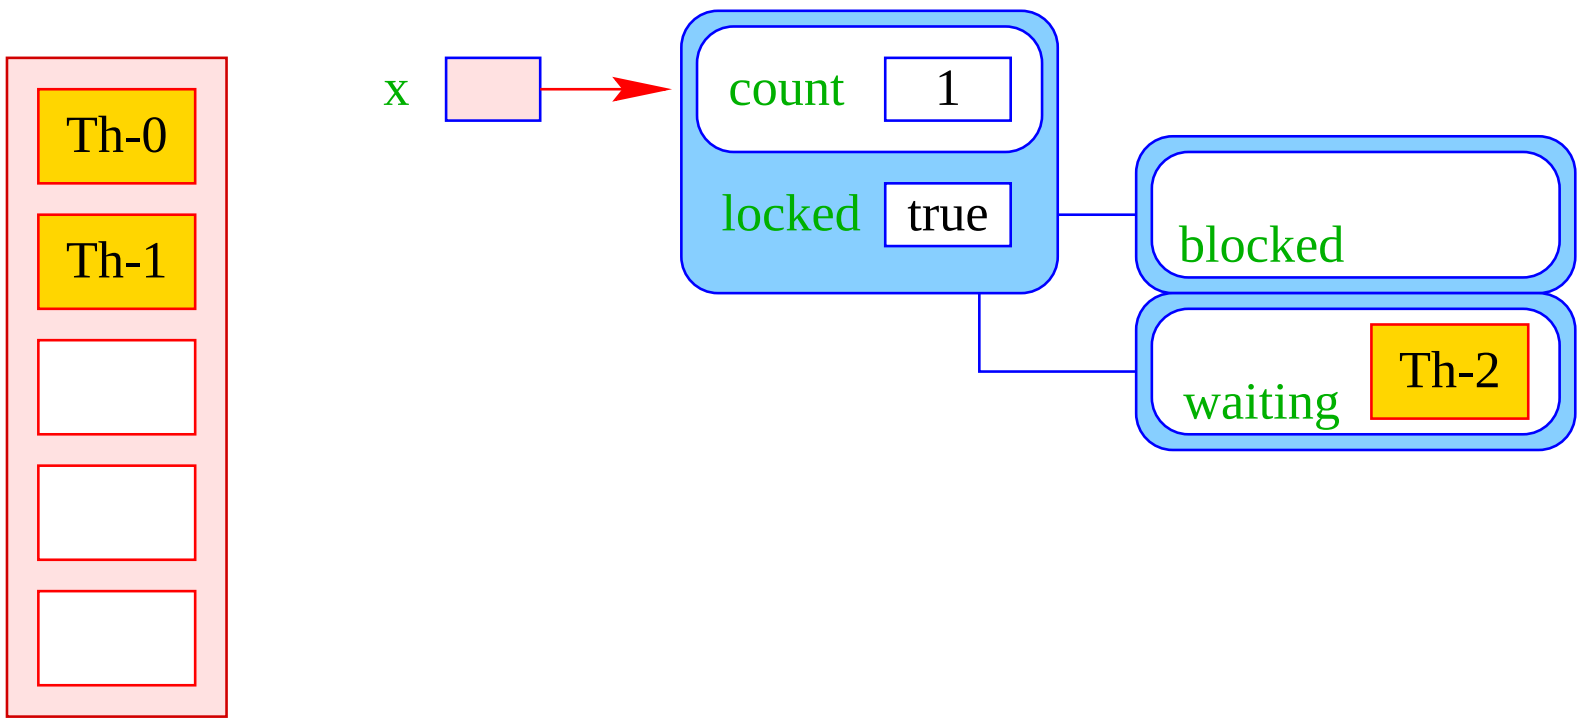
Th-0
Th-1
x
count
1
locked
true
blocked
waiting
Th-2

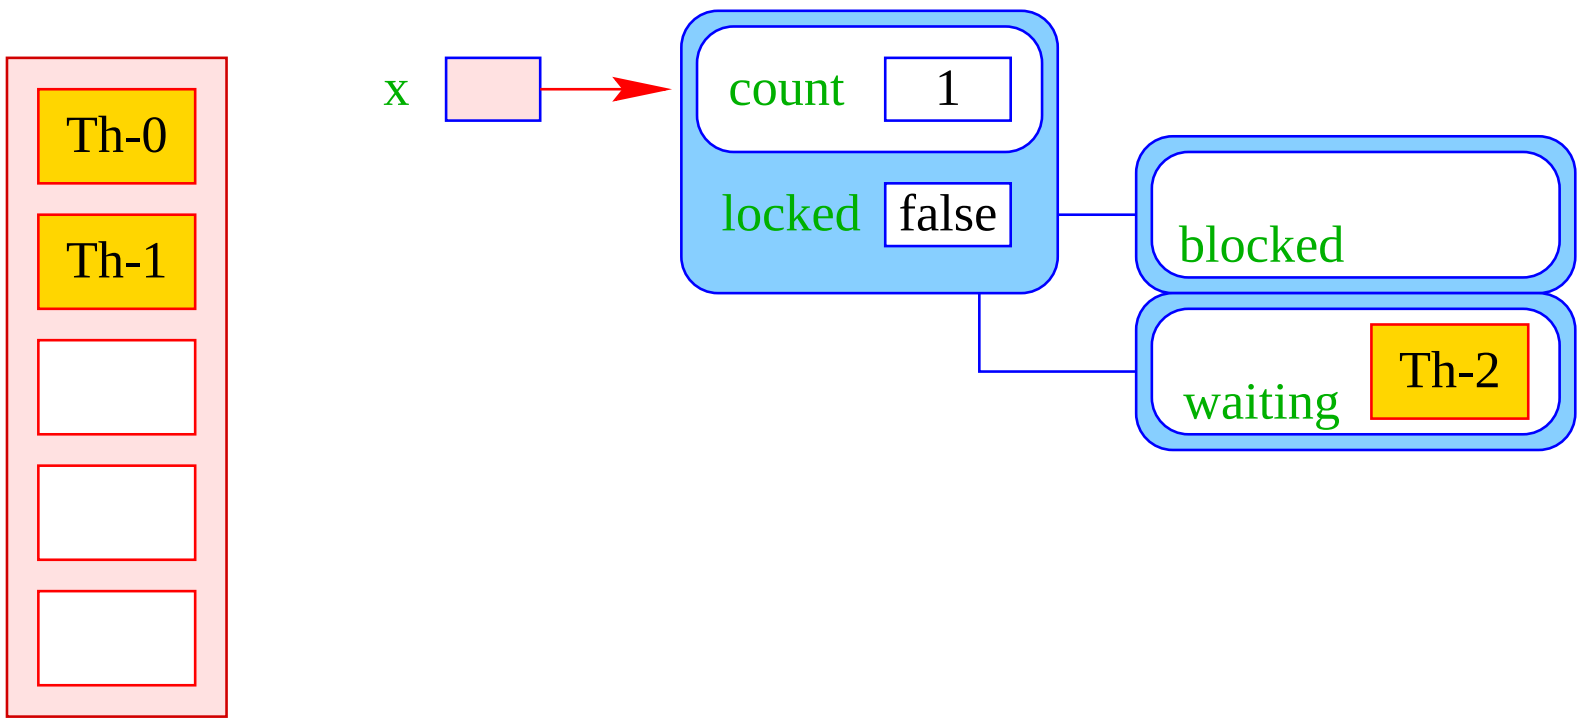
Th-0
Th-1
x
count
1
locked
false
blocked
waiting
Th-2

- Ausführen von `notify();` weckt den ersten Thread in der Warteschlange auf, d.h. versetzt ihn in den Zustand ready ...

```
public void notify() {
   if (!waitingThreads.isEmpty()) {
      Thread t = waitingThreads.dequeue();
      t.state = ready;
   }
}
```

- ... mit der Auflage, erneut das Lock zu erwerben, d.h. als erste Operation hinter dem `wait();` ein `lock()` auszuführen.

- Ausführen von `notify();` weckt den ersten Thread in der Warteschlange auf, d.h. versetzt ihn in den Zustand ready ...

```
public void notify() {
   if (!waitingThreads.isEmpty()) {
      Thread t = waitingThreads.dequeue();
      t.state = ready;
   }
}
```

- ... mit der Auflage, erneut das Lock zu erwerben, d.h. als erste Operation hinter dem `wait();` ein `lock()` auszuführen.
- `notifyAll();` weckt alle wartenden Threads auf:

```
public void notifyAll() {
   while (!waitingThreads.isEmpty()) notify();
}
```

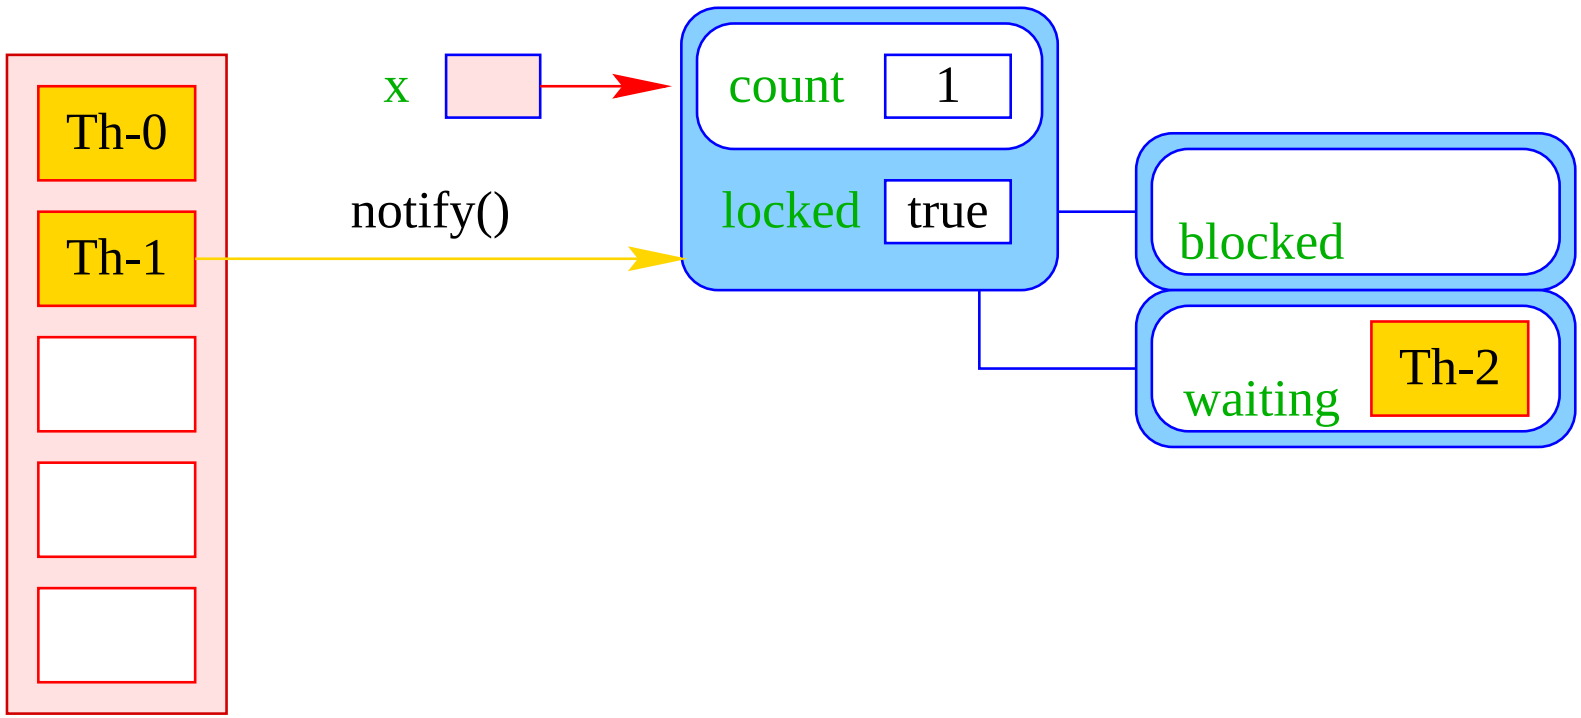
Th-0
Th-1
x
notify()
count
1
locked
true
blocked
waiting
Th-2

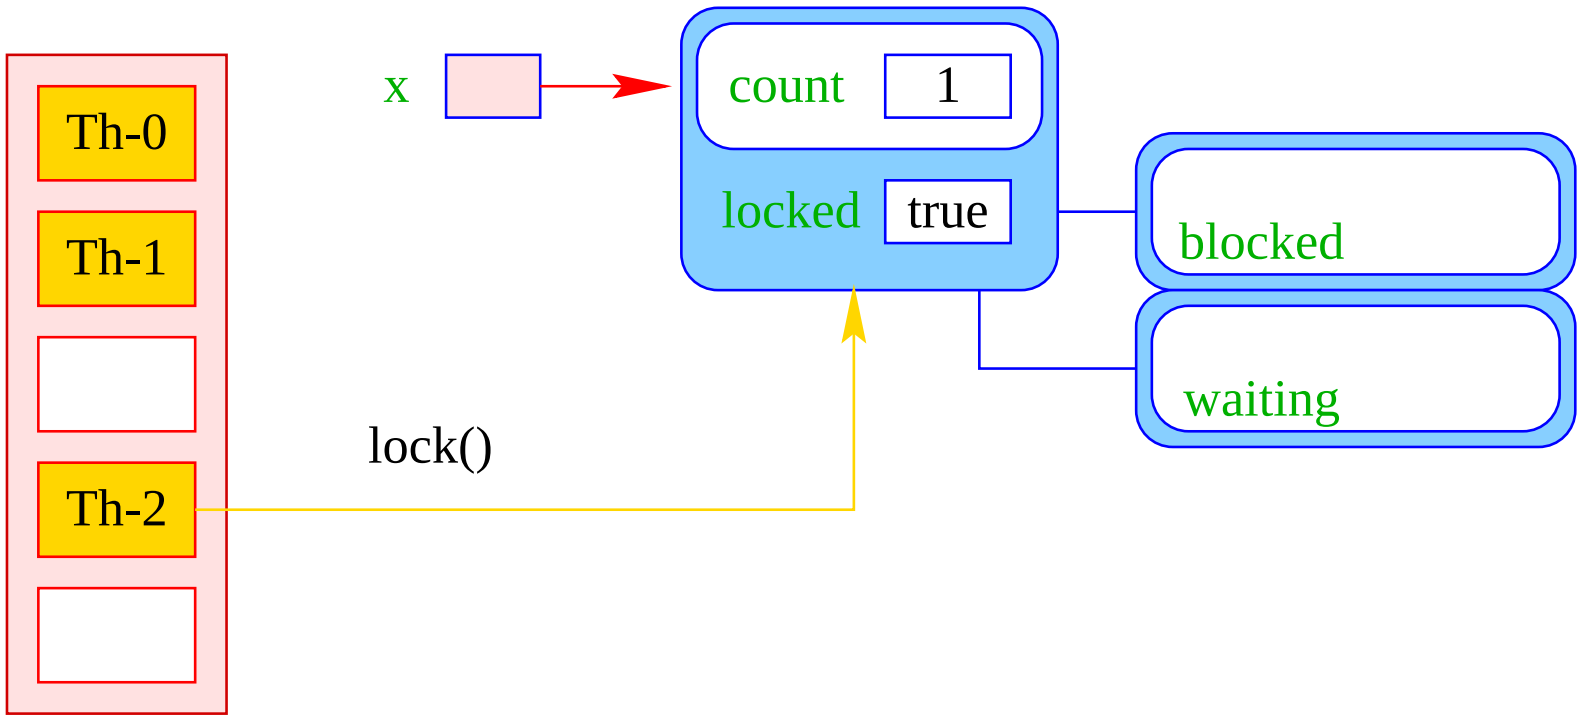
Th-0
Th-1
Th-2
x
count
1
locked
true
blocked
waiting
lock()

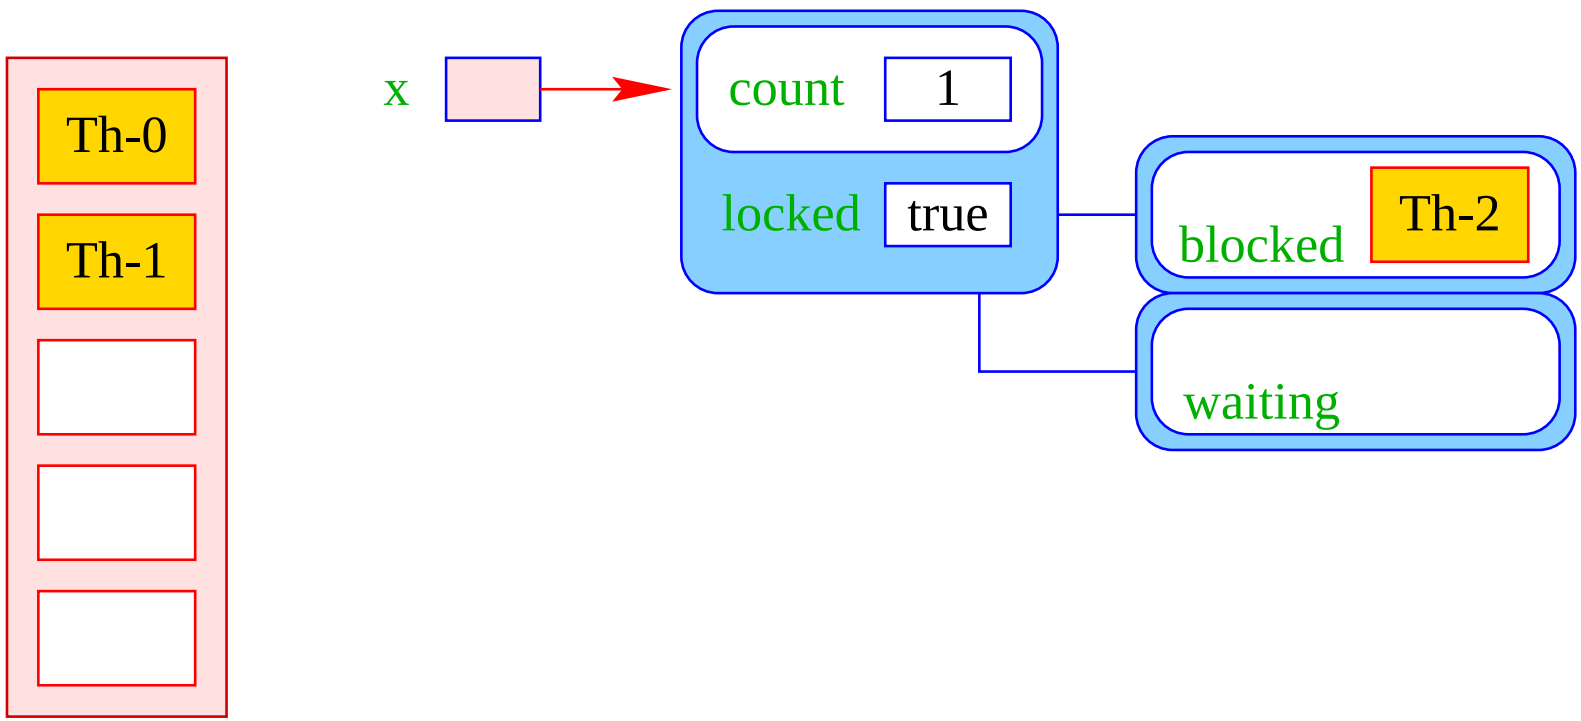
Th-0
Th-1
x
count
1
locked
true
blocked
Th-2
waiting

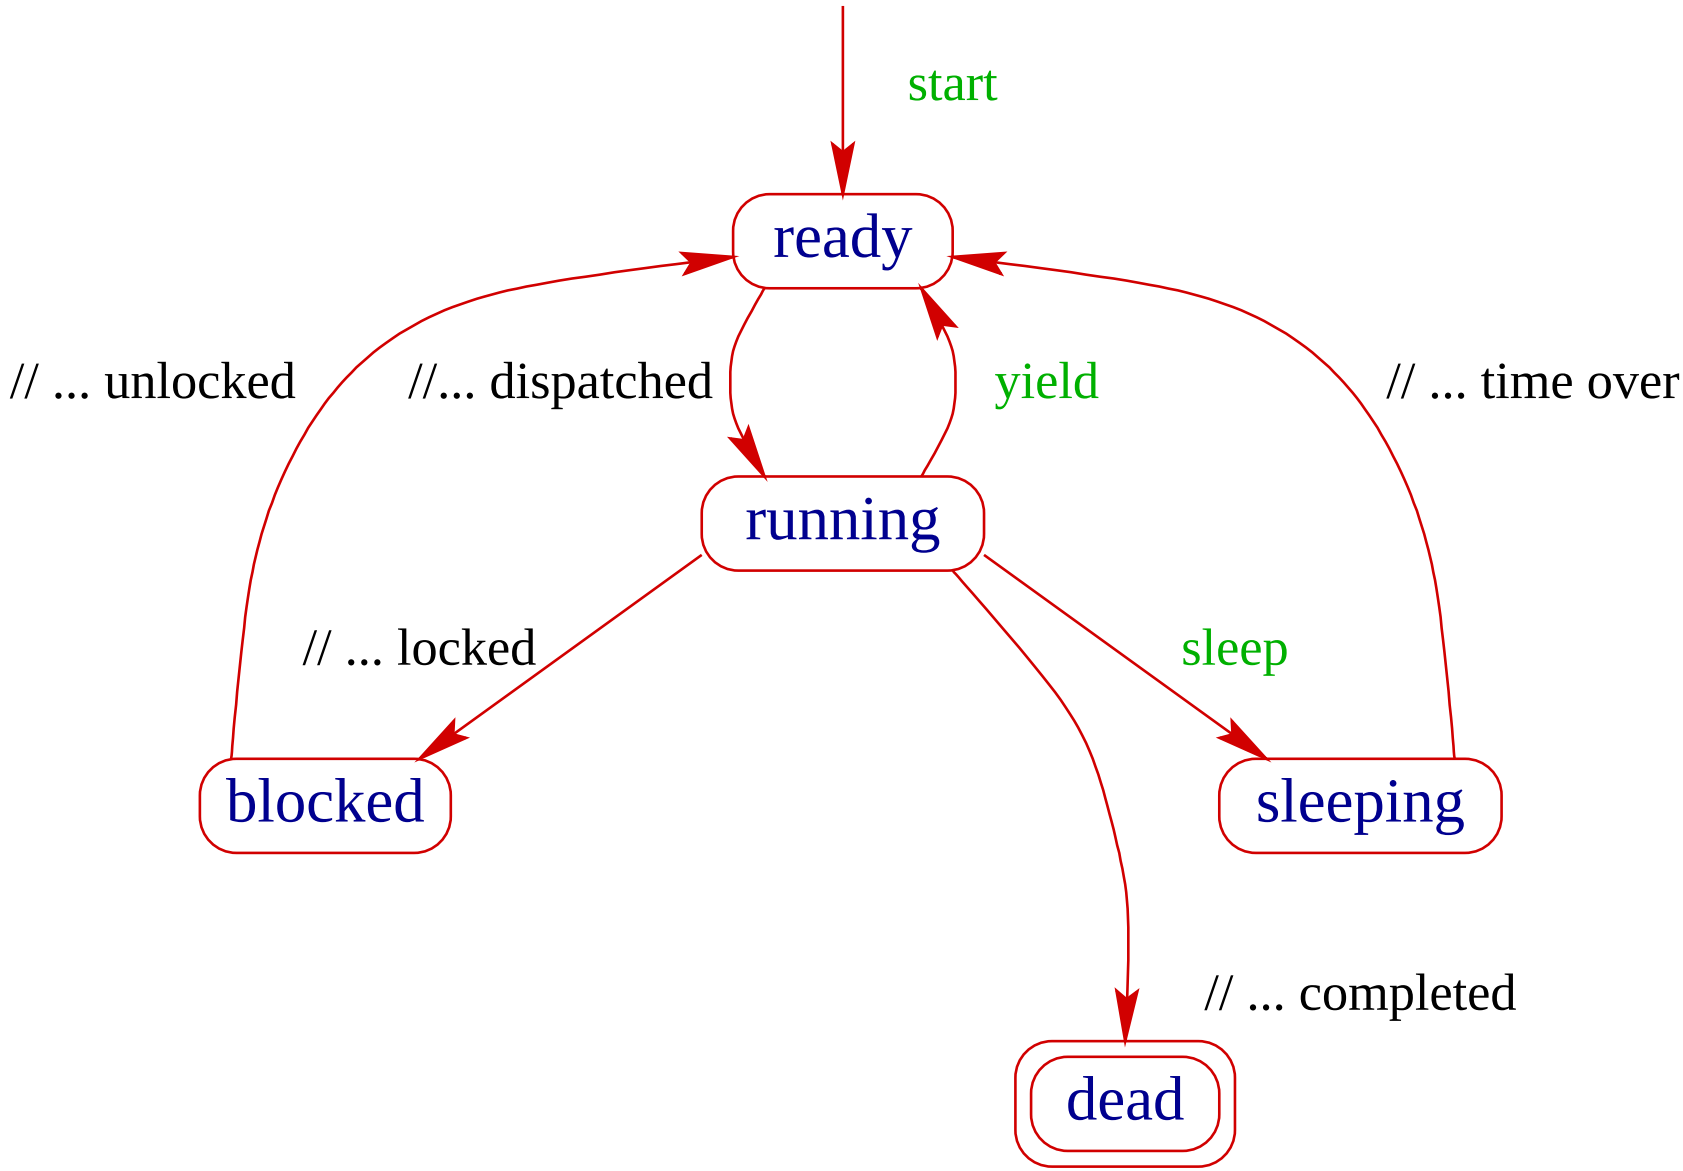
start
ready
// ... unlocked
//... dispatched
yield
// ... time over
running
// ... locked
sleep
blocked
sleeping
// ... completed
dead

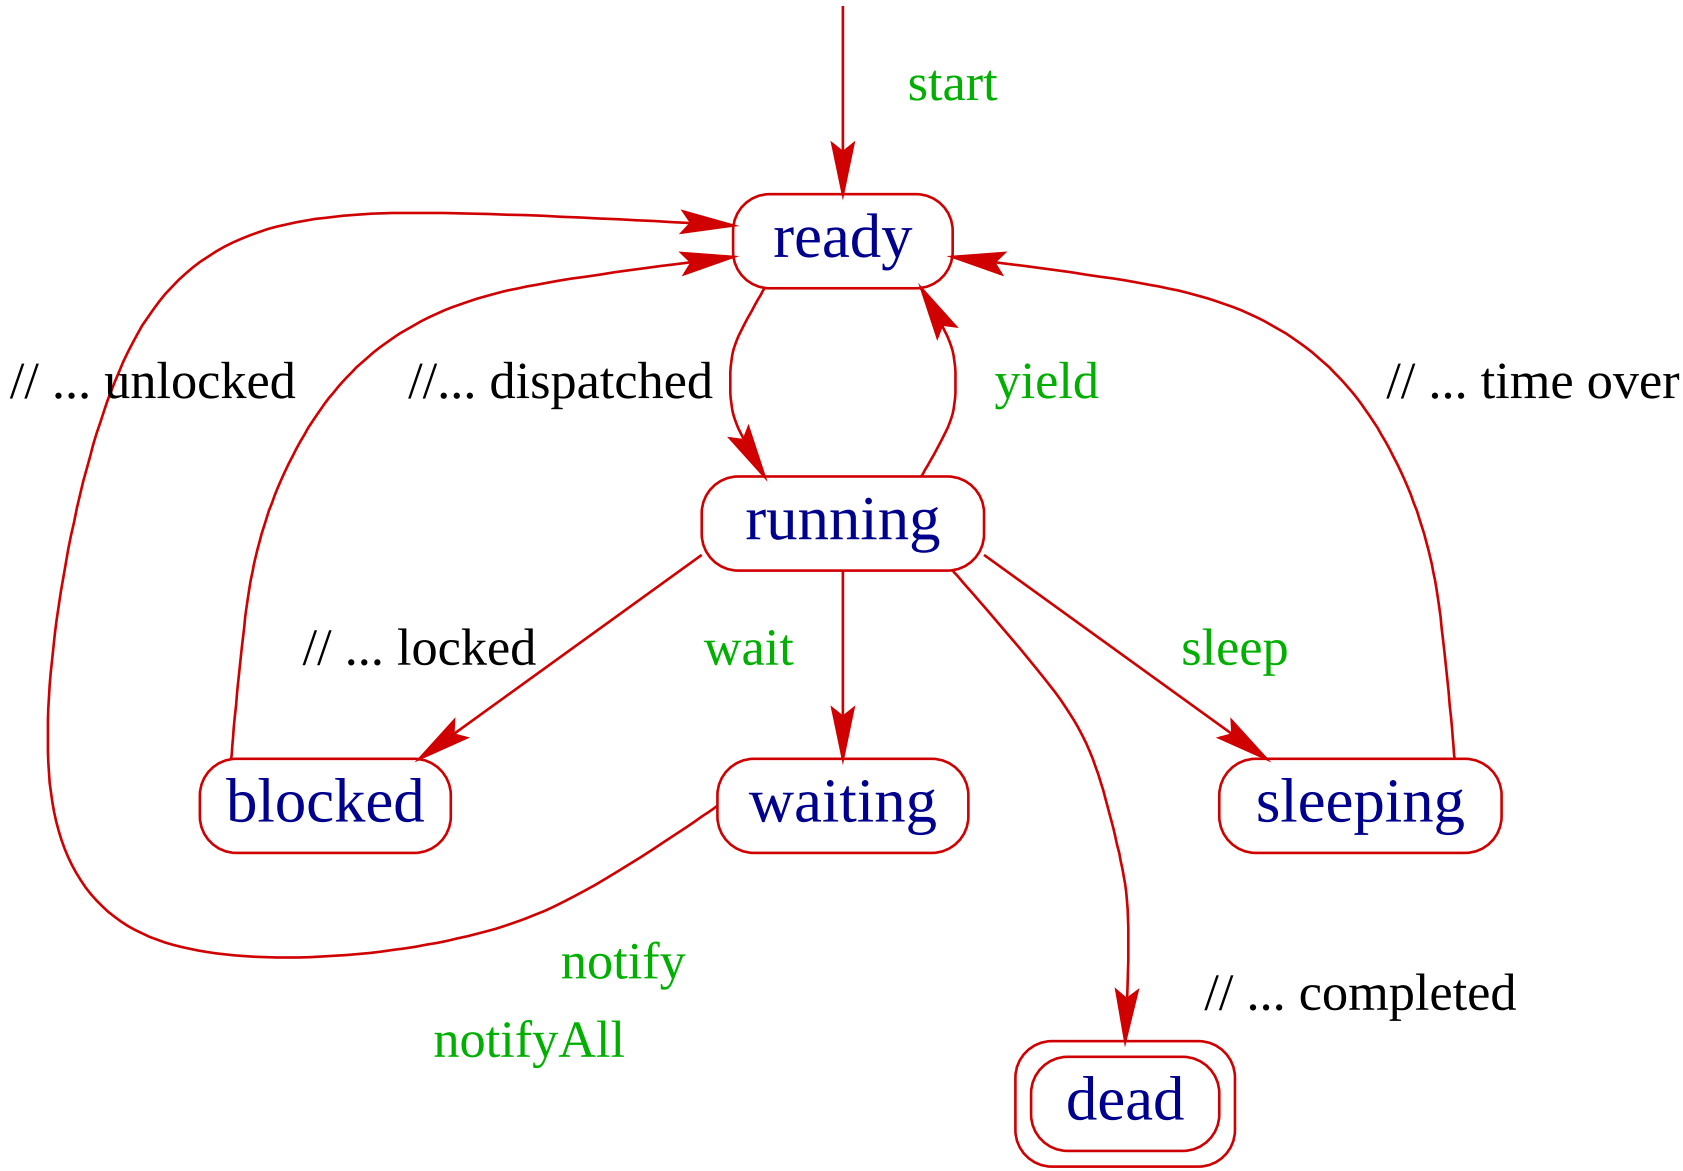
start
ready
// ... unlocked
//... dispatched
yield
// ... time over
running
// ... locked
wait
sleep
blocked
waiting
sleeping
notify
notifyAll
// ... completed
dead

# Anwendung:

```
   ...
   public synchronized void produce(Data d) throws InterruptedException {
      if (free==0) wait(); free--;
      a[last] = d;
      last = (last+1)%cap;
      notify();
   }
   public synchronized Data consume() throws InterruptedException {
      if (free==cap) wait(); free++;
      Data result = a[first];
      first = (first+1)%cap;
      notify(); return result;
   }
}  // end of class Buffer2
```

- Ist der Puffer voll, d.h. keine Zelle frei, legt sich der Producer schlafen.
- Ist der Puffer leer, d.h. alle Zellen frei, legt sich der Consumer schlafen.
- Gibt es für einen Puffer genau einen Producer und einen Consumer, weckt das `notify()` des Consumers (wenn überhaupt, dann) stets den Producer ...

  ... und umgekehrt.
- Was aber, wenn es mehrere Producers gibt? Oder mehrere Consumers ???

# 2. Idee: Wiederholung der Tests

- Teste nach dem Aufwecken erneut, ob Zellen frei sind.
- Wecke nicht einen, sondern alle wartenden Threads auf ...

```
...
public synchronized void produce(Data d)
                                 throws InterruptedException {
   while (free==0) wait(); free--;
   a[last] = d;
   last = (last+1)%cap;
   notifyAll();
}
...
```

```
    ...
    public synchronized Data consume() throws InterruptedException {
        while (free==cap) wait();
        free++;
        Data result = a[first];
        first = (first+1)%cap;
        notifyAll();
        return result;
    }
}   // end of class Buffer2
```

- Wenn ein Platz im Puffer frei wird, werden sämtliche Threads aufgeweckt – obwohl evt. nur einer der Producer bzw. nur einer der Consumer aktiv werden kann :-(

# 3. Idee: Semaphore

- Producers und Consumers warten in verschiedenen Schlangen.
- Die Producers warten darauf, dass `free > 0` ist.
- Die Consumers warten darauf, dass `cap-free > 0` ist.

# 3. Idee: Semaphore

- Producers und Consumers warten in verschiedenen Schlangen.
- Die Producers warten darauf, dass `free > 0` ist.
- Die Consumers warten darauf, dass `cap-free > 0` ist.

```
public class Sema { private int x;
   public Sema(int n) { x = n; }
   public synchronized void up() {
      x++; if (x<=0) notify();
   }
   public synchronized void down() throws InterruptedException {
      x--; if (x<0) wait();
   }
}  // end of class Sema
```

- Ein Semaphor enthält eine private `int`-Objekt-Variable und bietet die `synchronized`-Methoden `up()` und `down()` an.
- `up()` erhöht die Variable, `down()` erniedrigt sie.
- Ist die Variable positiv, gibt sie die Anzahl der verfügbaren Resourcen an.

  Ist sie negativ, zählt sie die Anzahl der wartenden Threads.
- Eine `up()`-Operation weckt genau einen wartenden Thread auf.

# Anwendung (1. Versuch :-)

```
public class Buffer {
   private int cap, first, last;
   private Sema free, occupied;
   private Data[] a;
   public Buffer(int n) {
      cap = n; first = last = 0;
      a = new Data[n];
      free = new Sema(n);
      occupied = new Sema(0);
   }
   ...
```

```
   ...
   public synchronized void produce(Data d) throws InterruptedException {
      free.down();
      a[last] = d;
      last = (last+1)%cap;
      occupied.up();
   }
   public synchronized Data consume() throws InterruptedException {
      occupied.down();
      Data result = a[first];
      first = (first+1)%cap;
      free.up();
      return result;
   }
}  // end of faulty class Buffer
```

- Gut gemeint – aber leider fehlerhaft ...
- Jeder Producer benötigt zwei Locks gleichzeitig, um zu produzieren:
  1. dasjenige für den Puffer;
  2. dasjenige für einen Semaphor.
- Muss er für den Semaphor ein `wait()` ausführen, gibt er das Lock für den Semaphor wieder zurück ... nicht aber dasjenige für den Puffer !!!
- Die Folge ist, dass niemand mehr eine Puffer-Operation ausführen kann, insbesondere auch kein `up()` mehr für den Semaphor $\Longrightarrow$ Deadlock

- Gut gemeint – aber leider fehlerhaft ...
- Jeder Producer benötigt zwei Locks gleichzeitig, um zu produzieren:
  1. dasjenige für den Puffer;
  2. dasjenige für einen Semaphor.
- Muss er für den Semaphor ein `wait()` ausführen, gibt er das Lock für den Semaphor wieder zurück ... nicht aber dasjenige für den Puffer !!!
- Die Folge ist, dass niemand mehr eine Puffer-Operation ausführen kann, insbesondere auch kein `up()` mehr für den Semaphor $\Longrightarrow$ Deadlock

## Anwendung (2. Versuch :-) Entkopplung der Locks

```
    ...
    public void produce(Data d) throws InterruptedException {
       free.down();
       synchronized (this) {
          a[last] = d; last = (last+1)%cap;
       }
       occupied.up();
    }
    public Data consume() throws InterruptedException {
       occupied.down();
       synchronized (this) {
          Data result = a[first]; first = (first+1)%cap;
       }
       free.up(); return result;
    }
}   // end of corrected class Buffer
```

- Das Statement `synchronized ( obj ) { stmts }` definiert einen kritischen Bereich für das Objekt obj, in dem die Statement-Folge stmts ausgeführt werden soll.
- Threads, die die neuen Objekt-Methoden `void produce(Data d)` bzw. `Data consume()` ausführen, benötigen zu jedem Zeitpunkt nur genau ein Lock :-)

# Warnung:

Threads sind nützlich, sollten aber nur mit Vorsicht eingesetzt werden. Es ist besser,

- ... wenige Threads zu erzeugen als mehr.
- ... unabhängige Threads zu erzeugen als sich wechselseitig beeinflussende.
- ... kritische Abschnitte zu schützen, als nicht synchronisierte Operationen zu erlauben.
- ... kritsche Abschnitte zu entkoppeln, als sie zu schachteln.