Методы и системы обработки больших данных

# 9. Реализация исполнителя запросов

# Итераторы

Физическая операция реализуется в виде итератора, представляющего собой группу из трех методов *open*, *next*, *close*, которые позволяют потребителю результата физической операции получать *покортежно* (по одному кортежу за один раз).

1. ***open***() – выделяет память для внутренних структур данных итератора; инициализирует структуры данных, необходимые для работы итератора и вызывает метод *open*() для дочерних узлов. При необходимости может вызывать методы *next* и *close* для дочерних узлов.

2. ***next***() – помещает очередной кортеж результата в выходной буфер своего узла; модифицирует внутренние структуры данных, подготавливая выдачу следующего кортежа; вызывает метод *next* (возможно многократно) для дочерних улов. При необходимости может вызывать методы *open* и *close* для дочерних узлов. Если множество кортежей исчерпано, помещает в выходной буфер специальный кортеж ***EOF***, который невозможно спутать ни с каким другим.

3. ***close***() – освобождает память; вызывает *close*() для дочерних узлов.

# Итераторная модель

```
root.open();
root.next();
while(root.buf!=EOF){
    print(root.buf);
    root.next();
};
root.close();
```

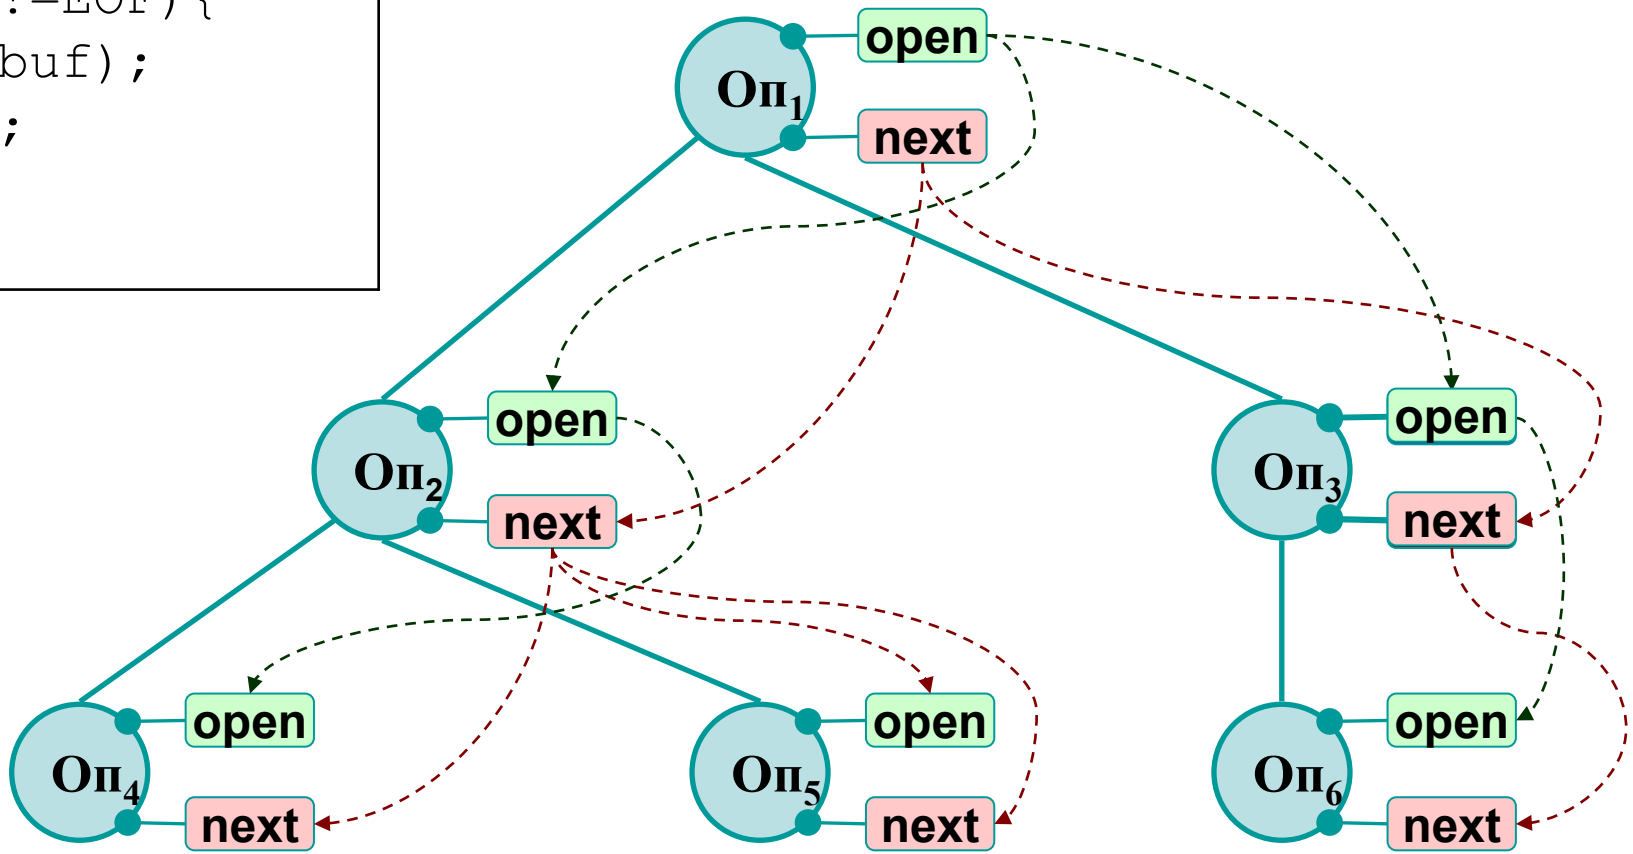

# Реализация итератора для операции *scan*, считывающей кортежи отношения R

```
void open(R){
   b = первый блок отношения R;
   t = первый кортеж блока b;
};

void next(R){
   if(t == NULL){
      b = следующий блок отношения R;
      if (b == NULL){
         node.buf = EOF;
         return;
      };
      t = первый кортеж блока b;
   };
   node.buf = t;
   t = следующий кортеж блока b;
   return;
};

void close(R){};
```

Методы и системы обработки больших данных

# Алгоритмы соединений

# Порядок операндов соединения

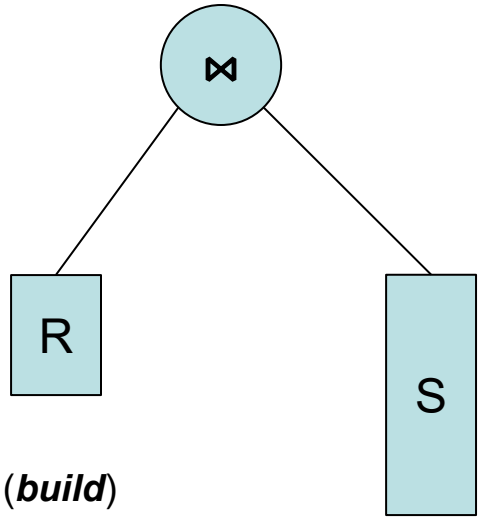


Левое отношение:
**меньшее** ⇔ ***опорное*** (***build***)

Правое отношение:
**большее** ⇔ ***тестируемое*** (***probe***)

# NLMJ (Nested Loops Memory Join)

## Реализация соединения вложенными циклами в оперативной памяти

- $R \underset{(A)}{\bowtie} S$
- $R$ – опорное отношение целиком помещается в оперативную память
- $S$ – тестируемое отношение
- Структура внутренних данных:
  - $M$ – массив в оперативной памяти (для $R$)
  - $m$ – указатель на текущий элемент в M

# Схема алгоритма NLMJ

1. Загрузить в память опорное (меньшее) отношение
2. Во внешнем цикле однократно сканируется тестируемое (большее) отношение
   - Во внутреннем цикле многократно сканируется образ опорного отношения в оперативной памяти

```
for r ∈ R do M ← r; // Поместить кортеж в массив
for s ∈ S do
    for r ∈ M do
        if r.A = s.A then
            print (r ⋈ s); // Соединить кортежи
```

# NLMJ: схема реализации метода open

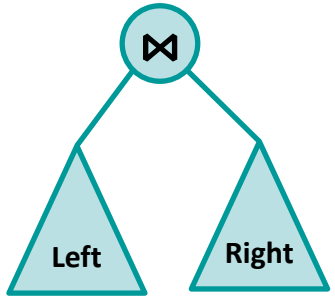


```
void open(node){
    выделить память для M;
    node.leftSon.open();
    m = 0; /* Номер текущего элемента в массиве M */
    do{/* Заполняем массив M кортежами опорного (левого) отношения */
      node.leftSon.next();
      M[m] = node.leftSon.buf;
      m++;
    } while (node.leftSon.buf!=EOF);
    m = 0;
    node.rightSon.open();
    node.rightSon.next();
};
```

# NLMJ: схема реализации метода next

```
void next(node){
    while(node.rightSon.buf!=EOF){// Сканируем тестируемое (правое) отношение
        while(M[m]!=EOF){ // Сканируем опорное (левое) отношение
            if(MATCH_A(M[m],node.rightSon.buf)){
                node.buf=JOIN_A(M[m],node.rightSon.buf);
                m++;
                return;
            };
            m++;
        };
        m=0;
        node.rightSon.next();
    };
    node.buf=EOF;
};
```

Проверяет на совпадение значений атрибута A у двух кортежей

Выполняет естественное соединение двух кортежей по атрибуту A

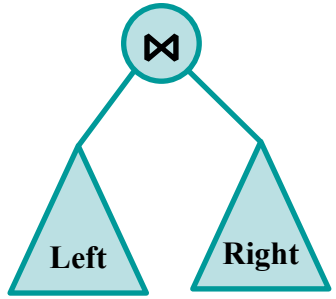

# NLMJ: схема реализации метода close

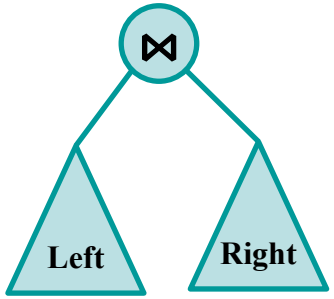


```
void close(node){
    освободить память для M;
    node.leftSon.close();
    node.rightSon.close();
};
```

# Оценка эффективности алгоритма

- Считаем только дисковые операции
- Более эффективным является тот алгоритм, который выполняет меньшее число дисковых операций

# Оценка эффективности *NLMJ*

$$R(A,B) \bowtie S(C,A) \quad T(R) = 150 \quad T(S) = 3000$$

| Атрибут | Тип | Семантика | Длина (байт) |
|---|---|---|---|
| A | int | Целое | 16 |
| B | int | Целое | 16 |
| C | string | Строка | 176 |

| Объект | Длина (байт) |
|---|---|
| Заголовок записи | 8 |
| Длина блока | 3024 |
| Заголовок блока | 24 |

| | $R$ | $S$ |
|---|---|---|
| Длина записи | ?? | ?? |
| Записей в блоке | ?? | ?? |
| Количество блоков | ?? | ?? |

| **Число обменов с диском*** | ?? |
|---|---|

*) Без учета записи результата.

# NLDJ (Nested Loops Disk Join)

## Соединения вложенными циклами на диске

- Во внешнем цикле однократно сканируется тестируемое (большее) отношение
- Во внутреннем цикле многократно сканируется опорное (меньшее) отношение
- Алгоритм применим к отношениям любых размеров
- Один из самых неэффективных алгоритмов

# Реализация NLDJ

$$R(A, B) \bowtie S(C, A)$$

- $R$ – опорное (меньшее) отношение
- $S$ – тестируемое (большее) отношение

**FOR** $s \in S$ **DO**
    **FOR** $r \in R$ **DO**
        **IF** $r.A = s.A$ **THEN** output $(r \bowtie s)$ ;

- Тестируемое отношение $S$ считывается с диска один раз во внешнем цикле
- Опорное отношение $R$ считывается с диска $T(S)$ раз во внутреннем цикле

# NLDJ: схема реализации метода open

```
void* open(node){
    node.leftSon.open();
    node.rightSon.open();
    node.leftSon.next();
    node.rightSon.next();
};
```

# NLDJ: схема реализации метода next

Проверяет на совпадение значений атрибута A у двух кортежей

```
void next(node){
   while(node.rightSon.buf!=EOF){// Сканируем тестируемое (правое) отношение
      while(node.leftSon.buf!=EOF){// Сканируем опорное (левое) отношение
         if(MATCH_A(node.leftSon.buf,node.rightSon.buf)){
            node.buf=JOIN_A(node.leftSon.buf,node.rightSon.buf);
            node.leftSon.next();
            return;
         };
         node.leftSon.next();
      };
      node.leftSon.close();
      node.leftSon.open();
      node.leftSon.next();
      node.rightSon.next();
   };
   node.buf=EOF;
};
```

Выполняет естественное соединение двух кортежей по атрибуту A

# Оценка эффективности *NLDJ*

$$R(A,B) \bowtie S(C,A) \quad T(R) = 150 \quad T(S) = 3000$$

| Атрибут | Тип | Семантика | Длина (байт) |
|---|---|---|---|
| A | int | Целое | 16 |
| B | int | Целое | 16 |
| C | string | Строка | 176 |

| Объект | Длина (байт) |
|---|---|
| Заголовок записи | 8 |
| Длина блока | 3024 |
| Заголовок блока | 24 |

| | $R$ | $S$ |
|---|---|---|
| Длина записи | $2 \cdot 16 + 8 = 40$ | $16 + 176 + 8 = 200$ |
| Записей в блоке | $(3024 - 24)/40 = 75$ | $(3024 - 24)/200 = 15$ |
| Количество блоков | $150/75 = 2$ | $3000/15 = 200$ |

| | $R$ сканируется во внутреннем цикле | $R$ сканируется во внешнем цикле |
|---|---|---|
| Число обменов с диском* | ?? | ?? |

*) Без учета записи результата.

# HJ (Hash Join)

## Соединение хешированием

$$Q = R(A, B) \bowtie S(C, A)$$

Задается хеш-функция $h$: $D_A \rightarrow \{1, \dots, k\}$

- $R_i = \{r | r \in R \wedge h(r.A) = i\}$ – $i$-тый сегмент отношения $R$
- $S_i = \{s | s \in S \wedge h(s.A) = i\}$ – $i$-тый сегмент отношения $S$
- $k$ выбирается так, что $R_i$ целиком помещается в оперативную память $\forall i = 1, \dots, k$

**I проход**:

1. Разбить $R$ на $R_1 \dots R_k$
2. Разбить $S$ на $S_1 \dots S_k$

**II проход**:

1. **for** $i$ **from** $1$ **to** $k$ **do** $Q_i = NLMJ(R_i, Si)$
2. $Q = \bigcup_{i=1}^{k} Q_i$

**R**

| A* | B | C |
|---|---|---|
| **1** | 20 | 100 |
| **2** | 40 | 300 |
| **3** | 20 | 100 |
| **4** | 10 | 300 |
| **5** | 10 | 200 |
| **6** | 30 | 100 |

**S**

| D* | A# | E |
|---|---|---|
| 1 | **3** | 0.2 |
| 2 | **1** | 0.5 |
| 3 | **1** | 0.5 |
| 4 | **1** | 0.6 |
| 5 | **6** | 0.4 |
| 6 | **3** | 0.9 |
| 7 | **5** | 0.1 |
| 8 | **3** | 0.1 |
| 9 | **5** | 0.5 |
| 10 | **1** | 0.7 |
| 11 | **2** | 0.4 |
| 12 | **2** | 0.3 |

$h(r.A) = (r.A \bmod 3) + 1$

$h(a) = (a \bmod 3) + 1$

$h(s.A) = (s.A \bmod 3) + 1$

**$R_1$**

| A* | B | C |
|---|---|---|
| **3** | 20 | 100 |
| **6** | 30 | 100 |

**$R_2$**

| A* | B | C |
|---|---|---|
| **1** | 20 | 100 |
| **4** | 10 | 300 |

**$R_3$**

| A* | B | C |
|---|---|---|
| **2** | 40 | 300 |
| **5** | 10 | 200 |

**$S_1$**

| D* | A# | E |
|---|---|---|
| 1 | **3** | 0.2 |
| 5 | **6** | 0.4 |
| 6 | **3** | 0.9 |
| 8 | **3** | 0.1 |

**$S_2$**

| D* | A# | E |
|---|---|---|
| 2 | **1** | 0.5 |
| 3 | **1** | 0.5 |
| 4 | **1** | 0.6 |
| 10 | **1** | 0.7 |

**$S_3$**

| D* | A# | E |
|---|---|---|
| 7 | **5** | 0.1 |
| 11 | **2** | 0.4 |
| 12 | **2** | 0.3 |
| 9 | **5** | 0.5 |

Сегменты

# HJ. 1-й проход

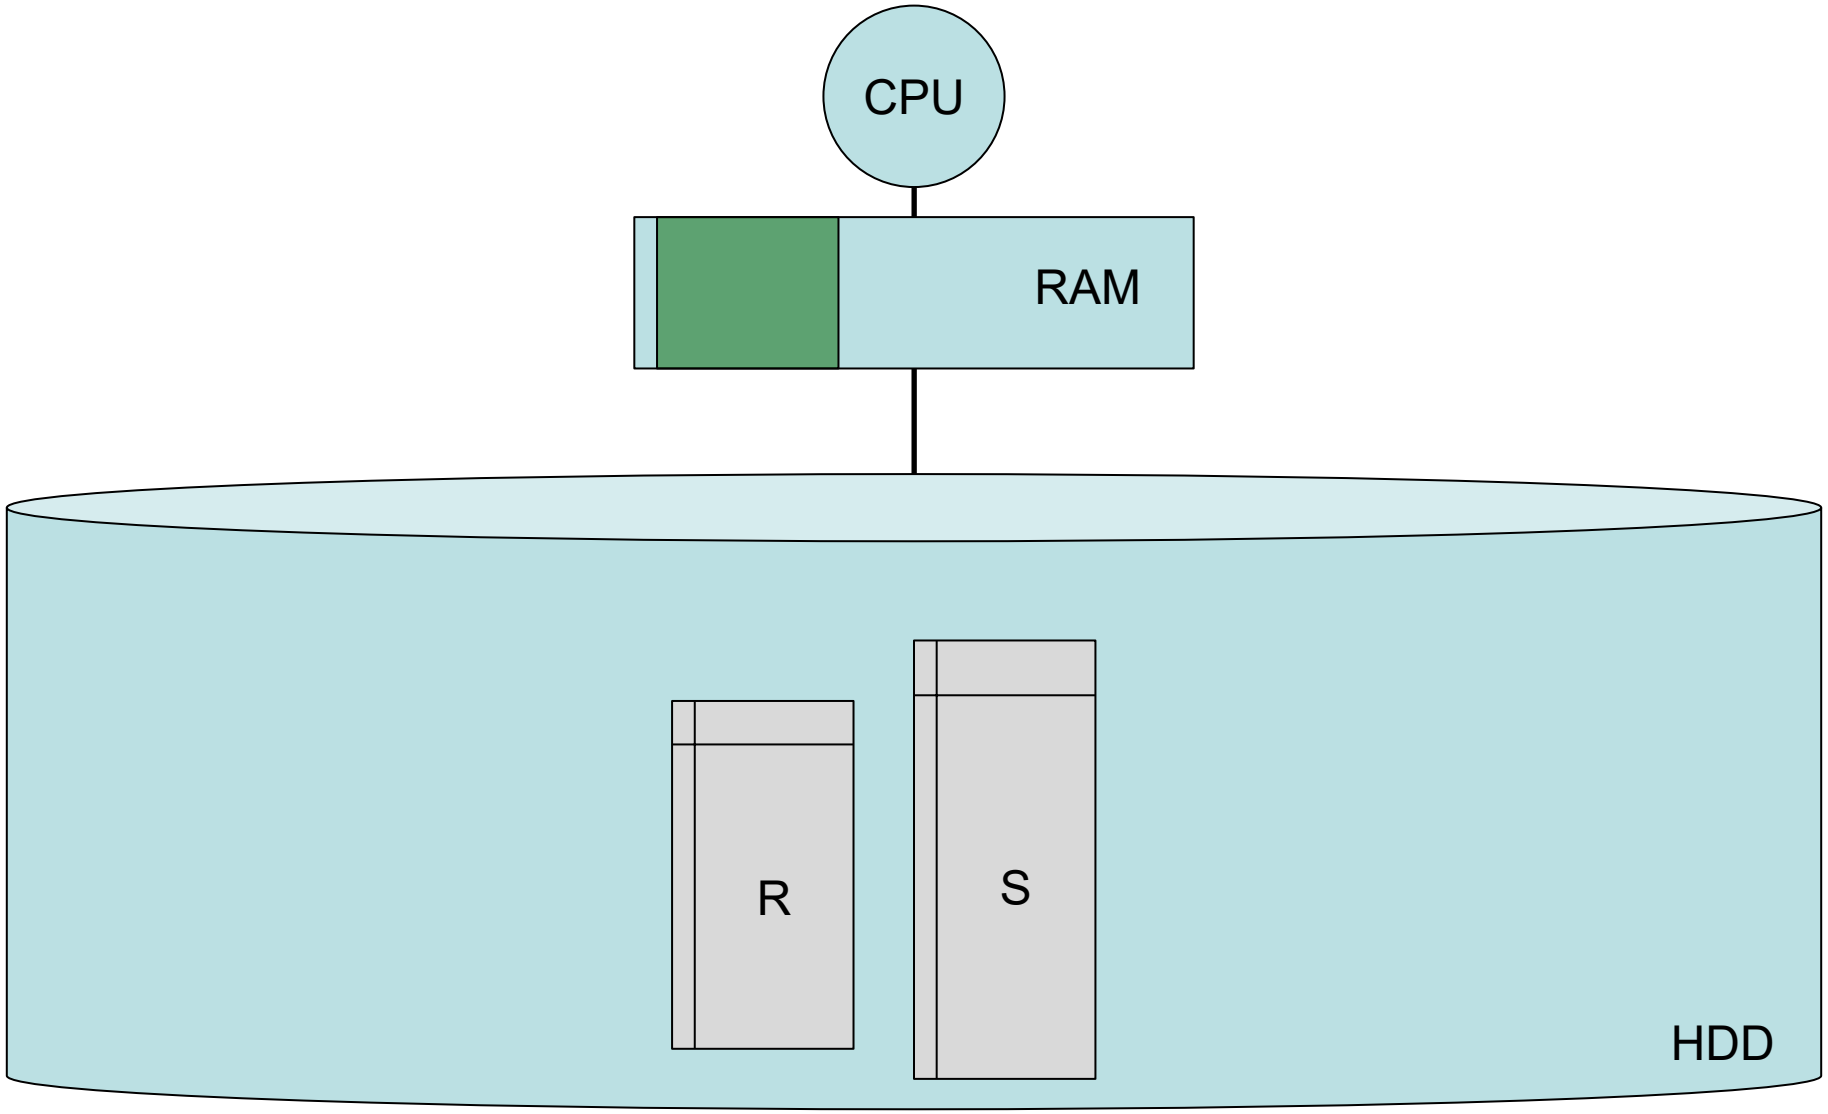

# HJ. 1-й проход

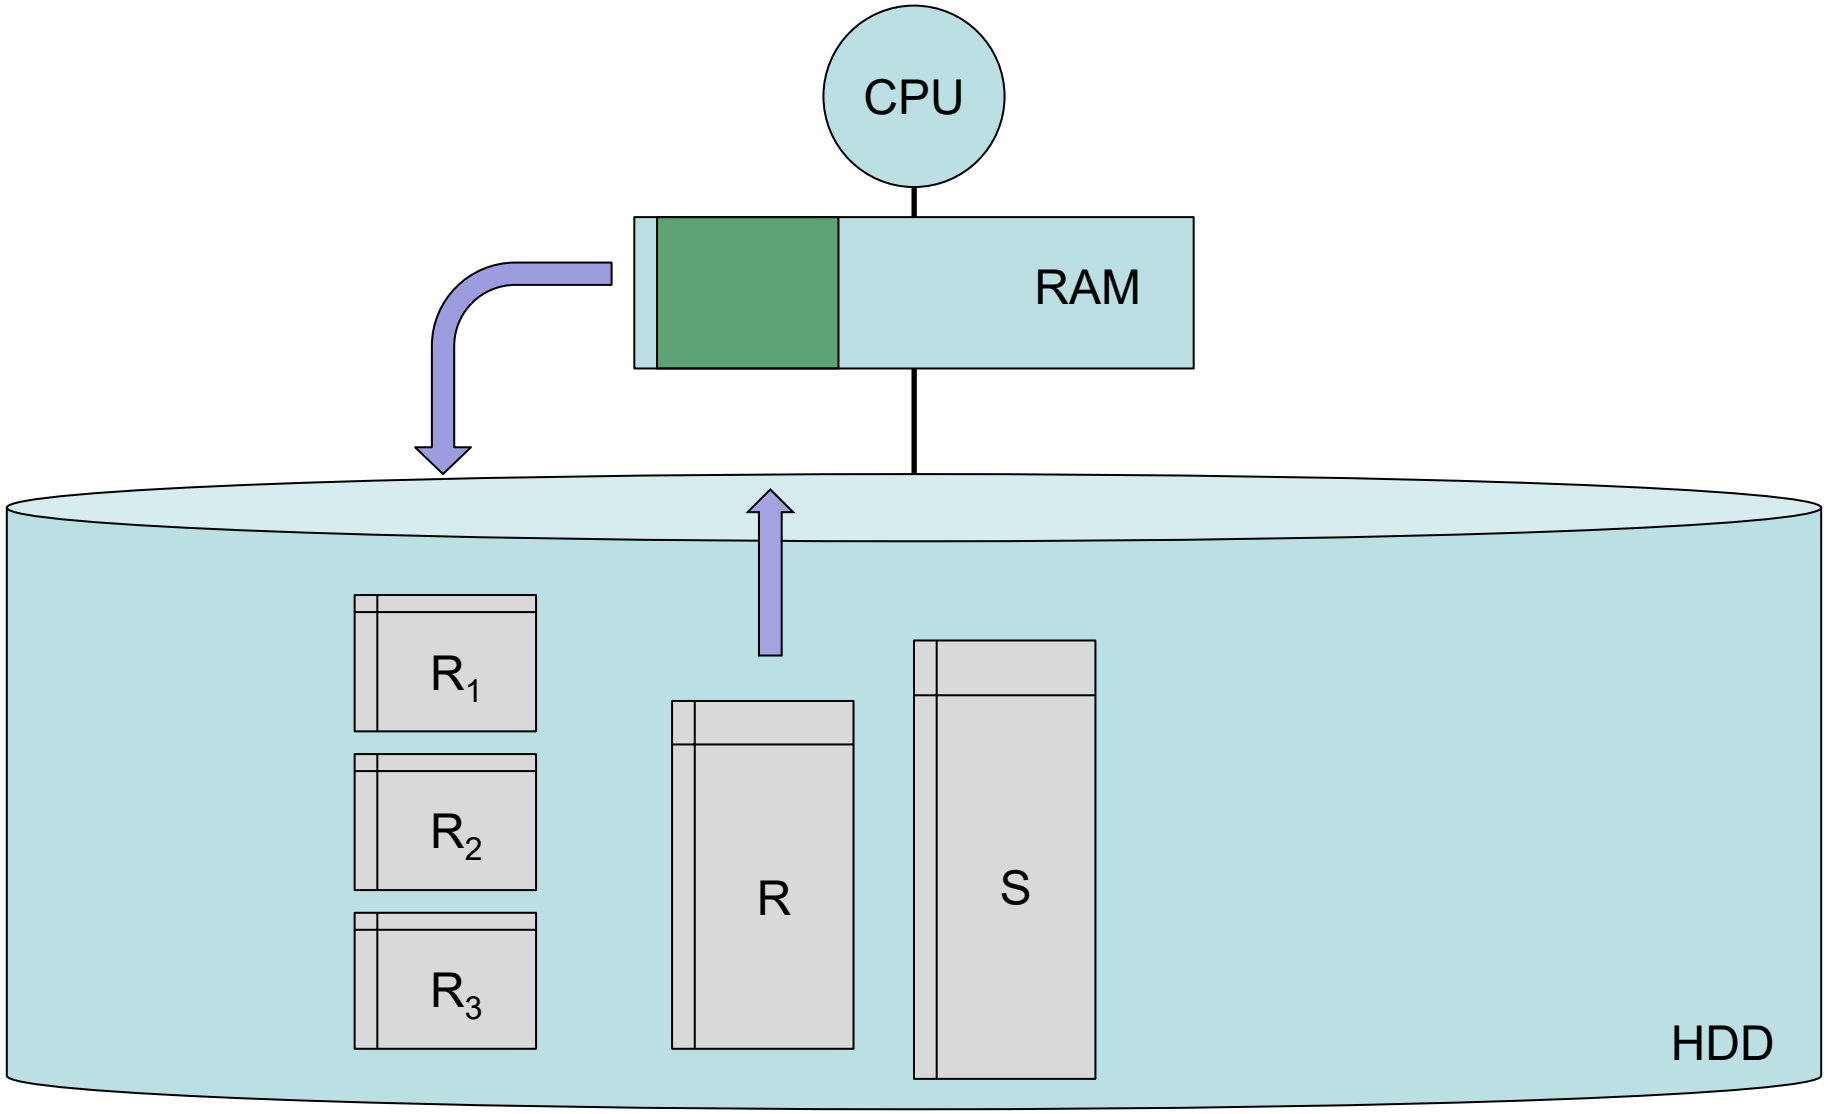

# HJ. 1-й проход

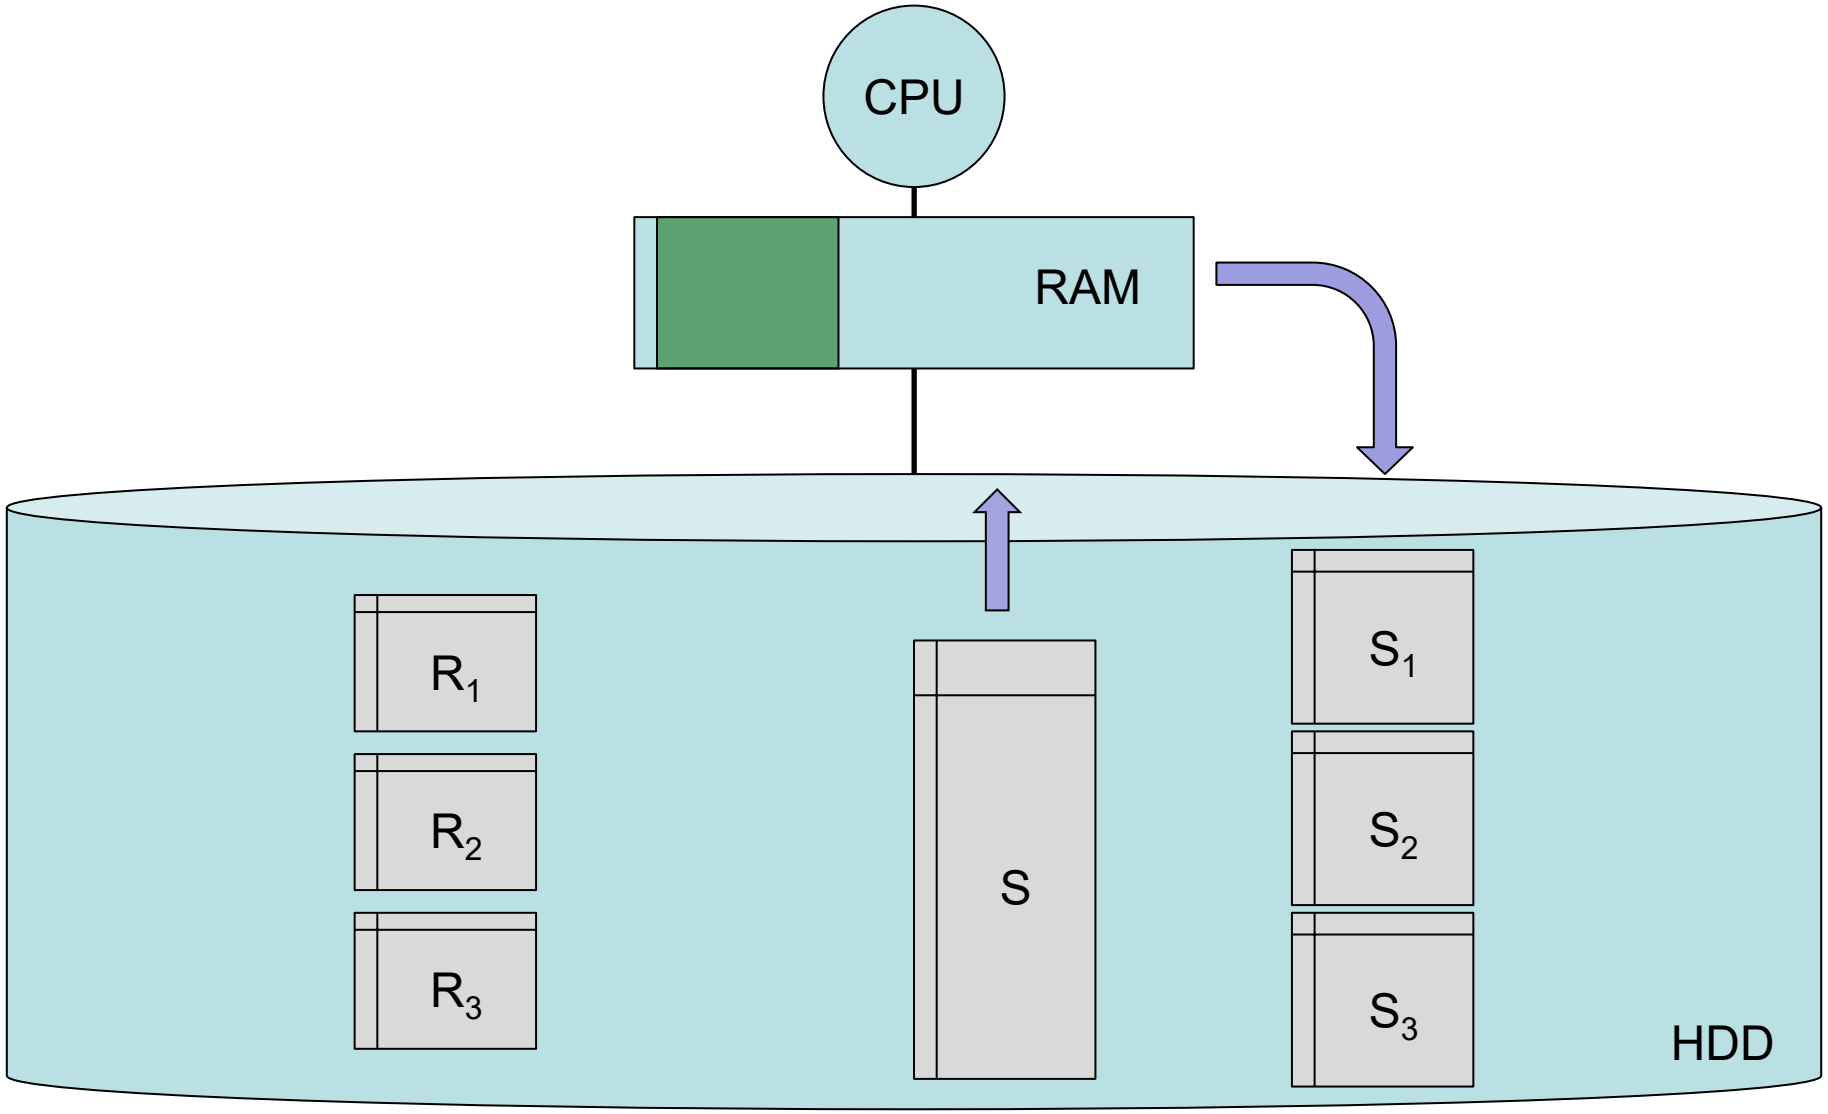

# HJ. 2-й проход

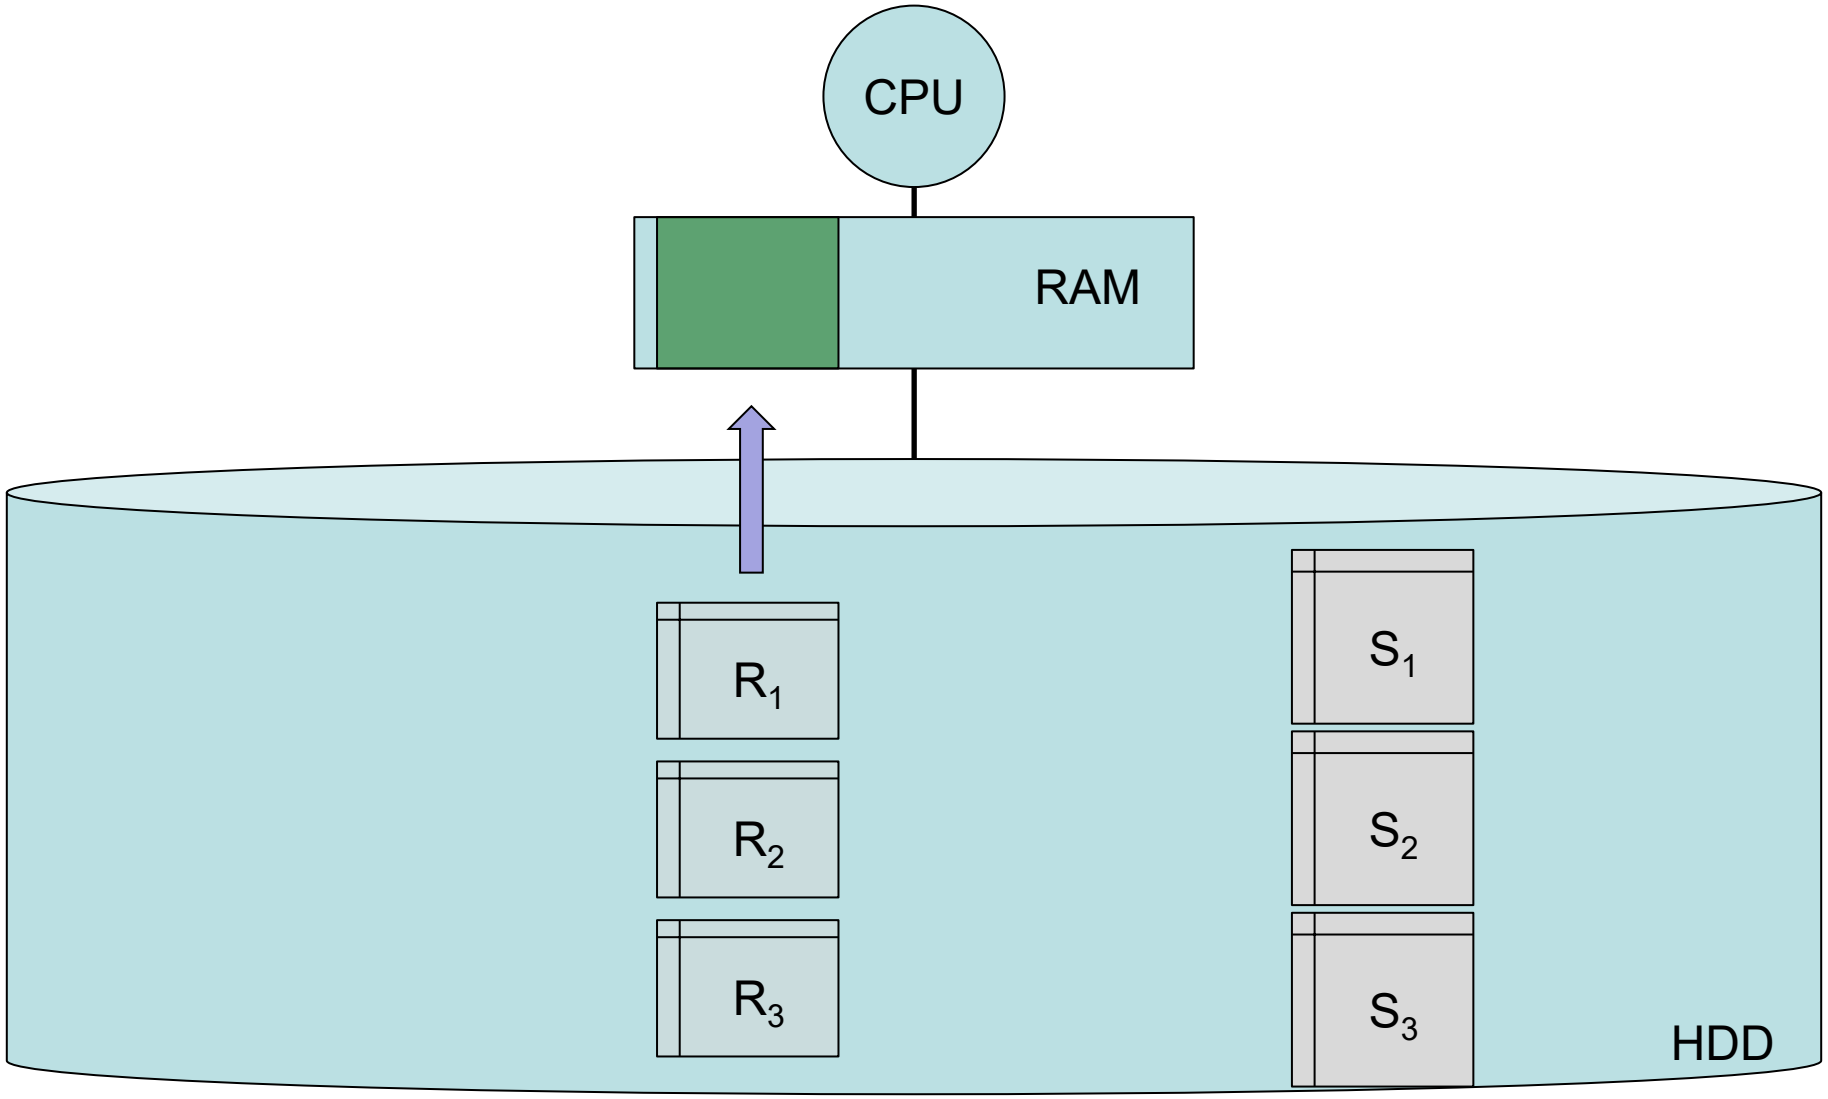

# HJ. 2-й проход

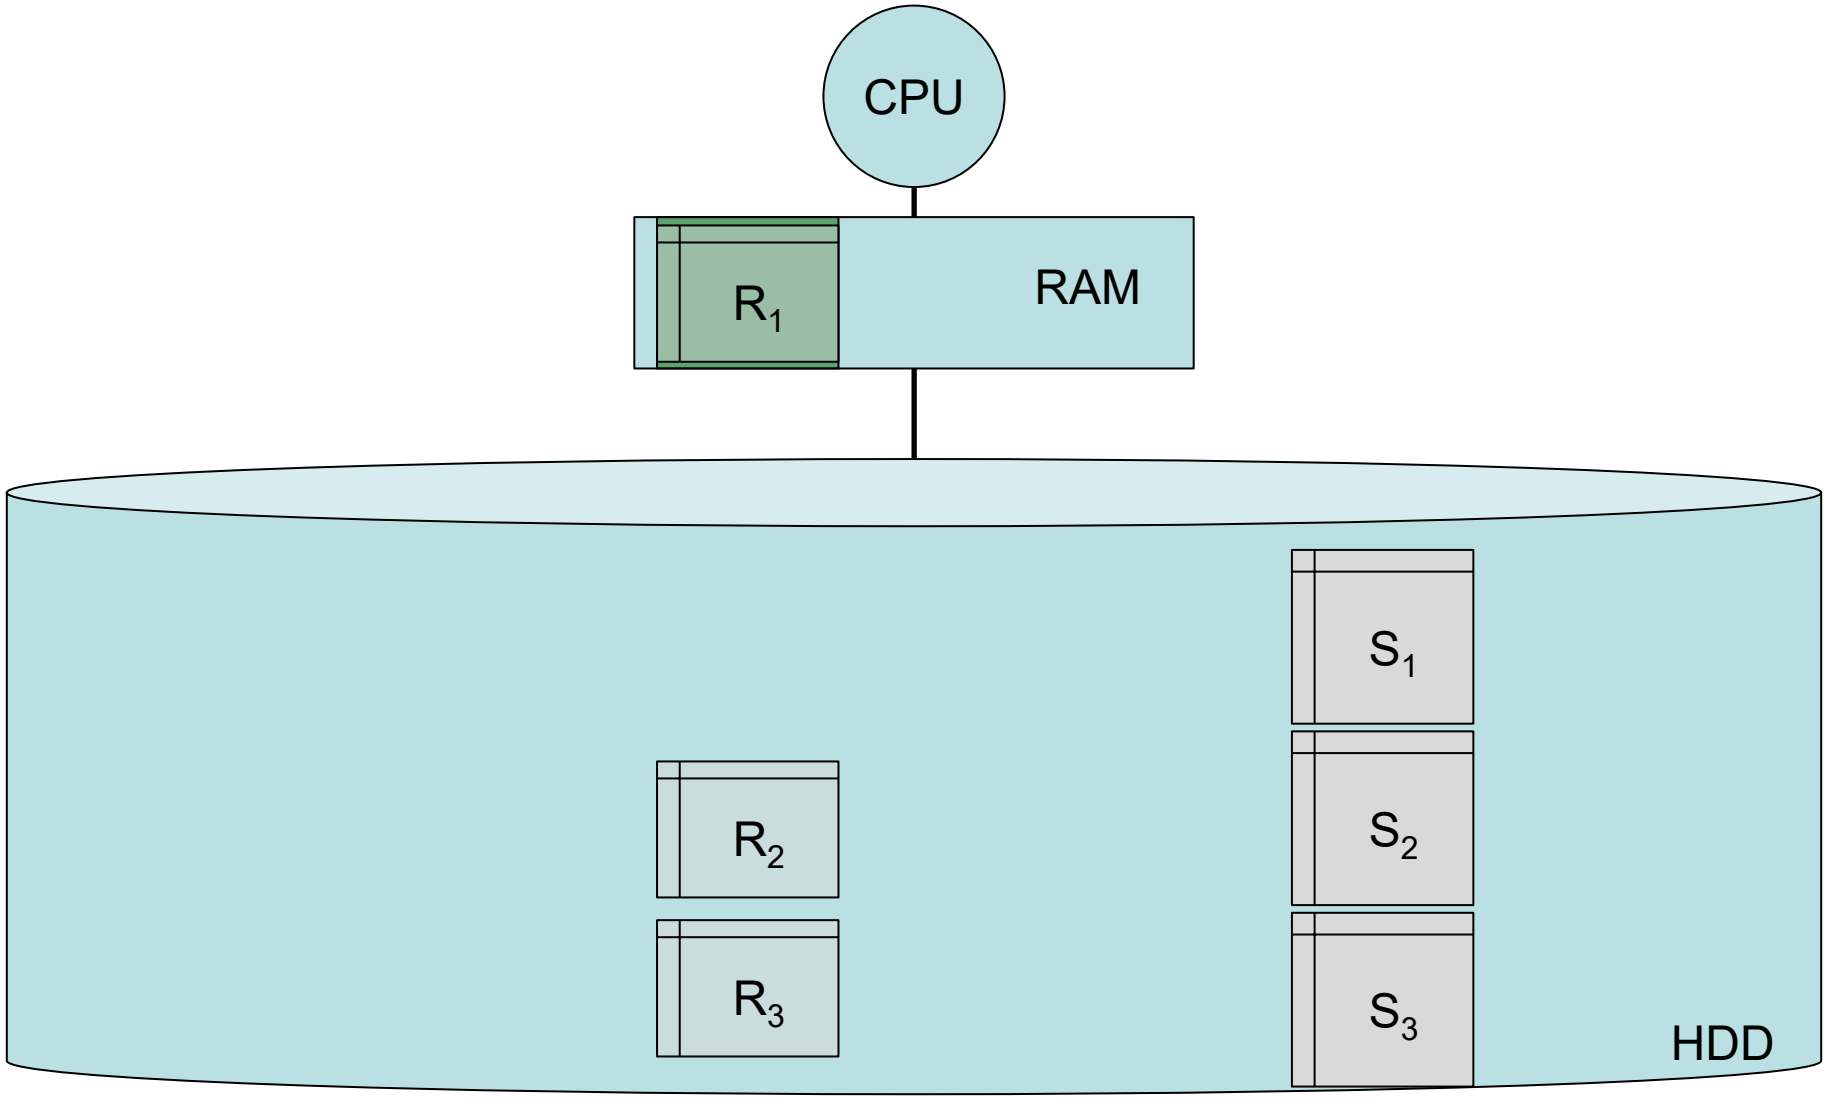

# HJ. 2-й проход

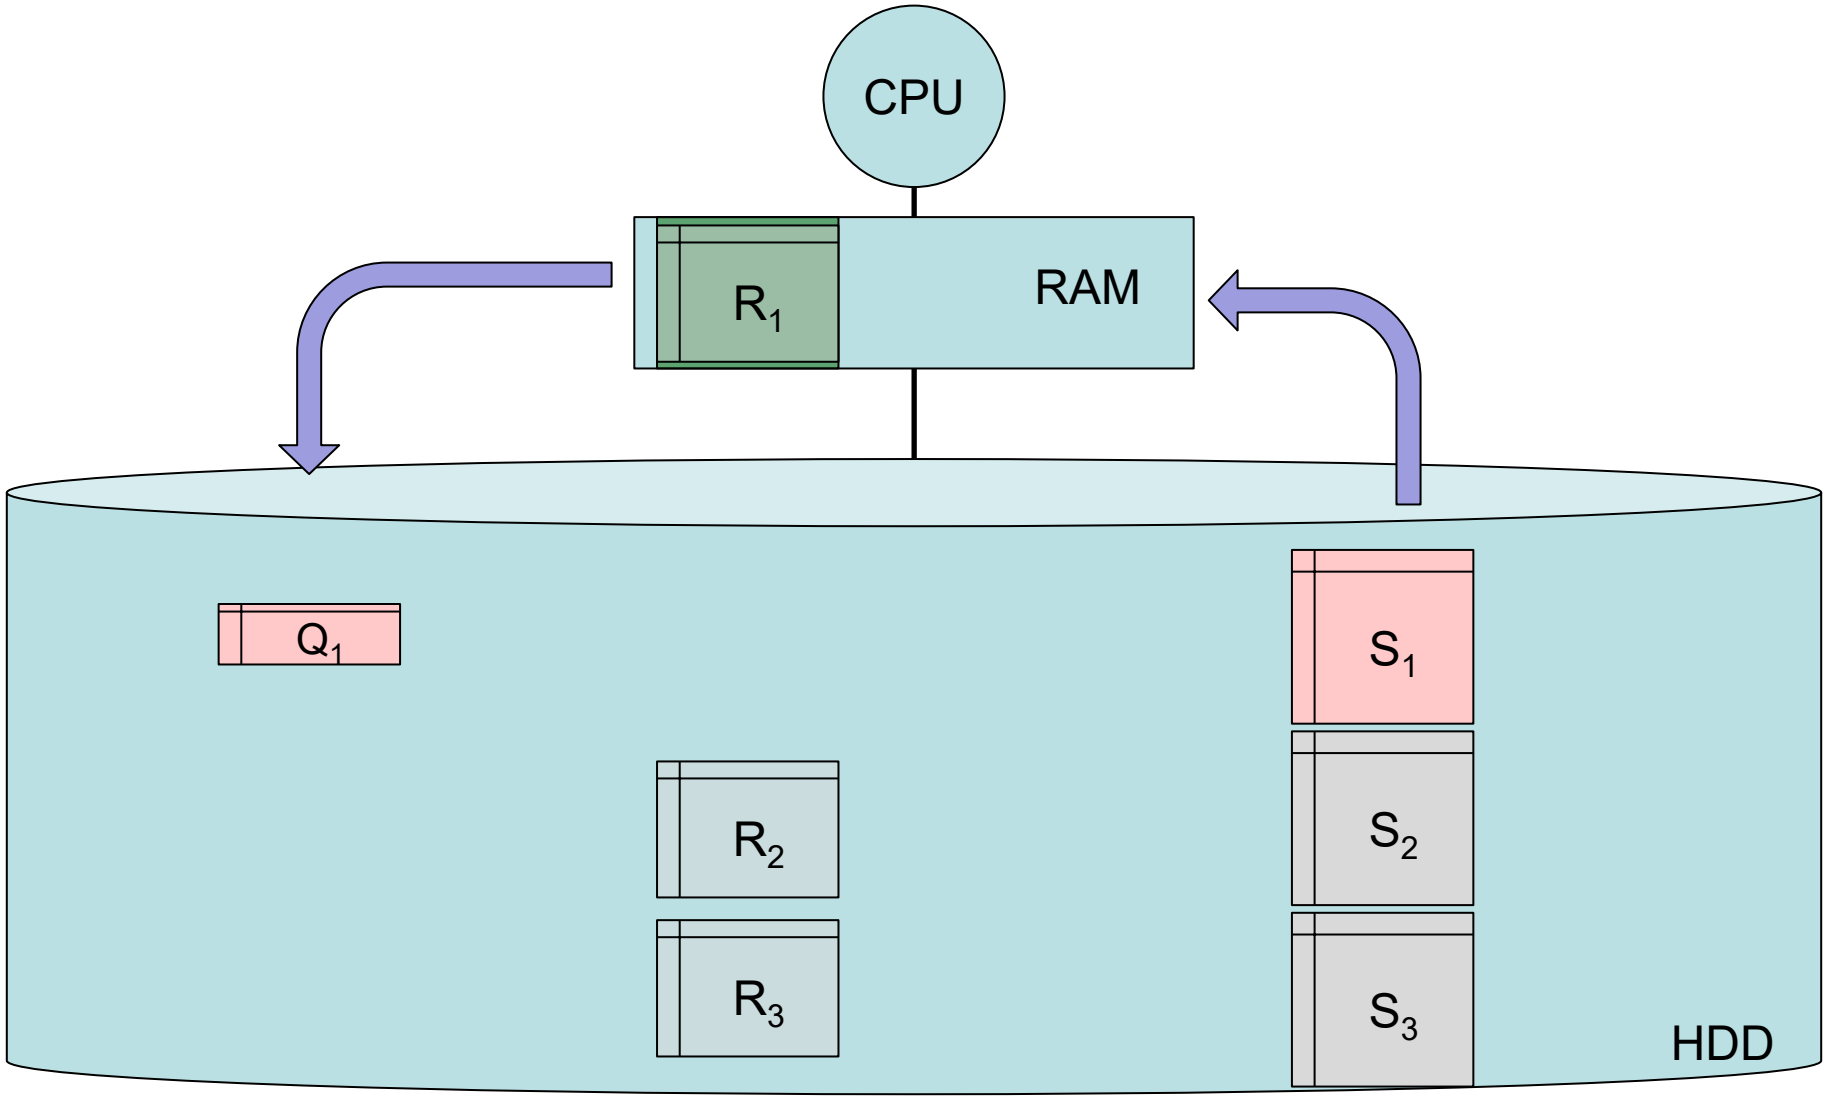

# HJ. 2-й проход

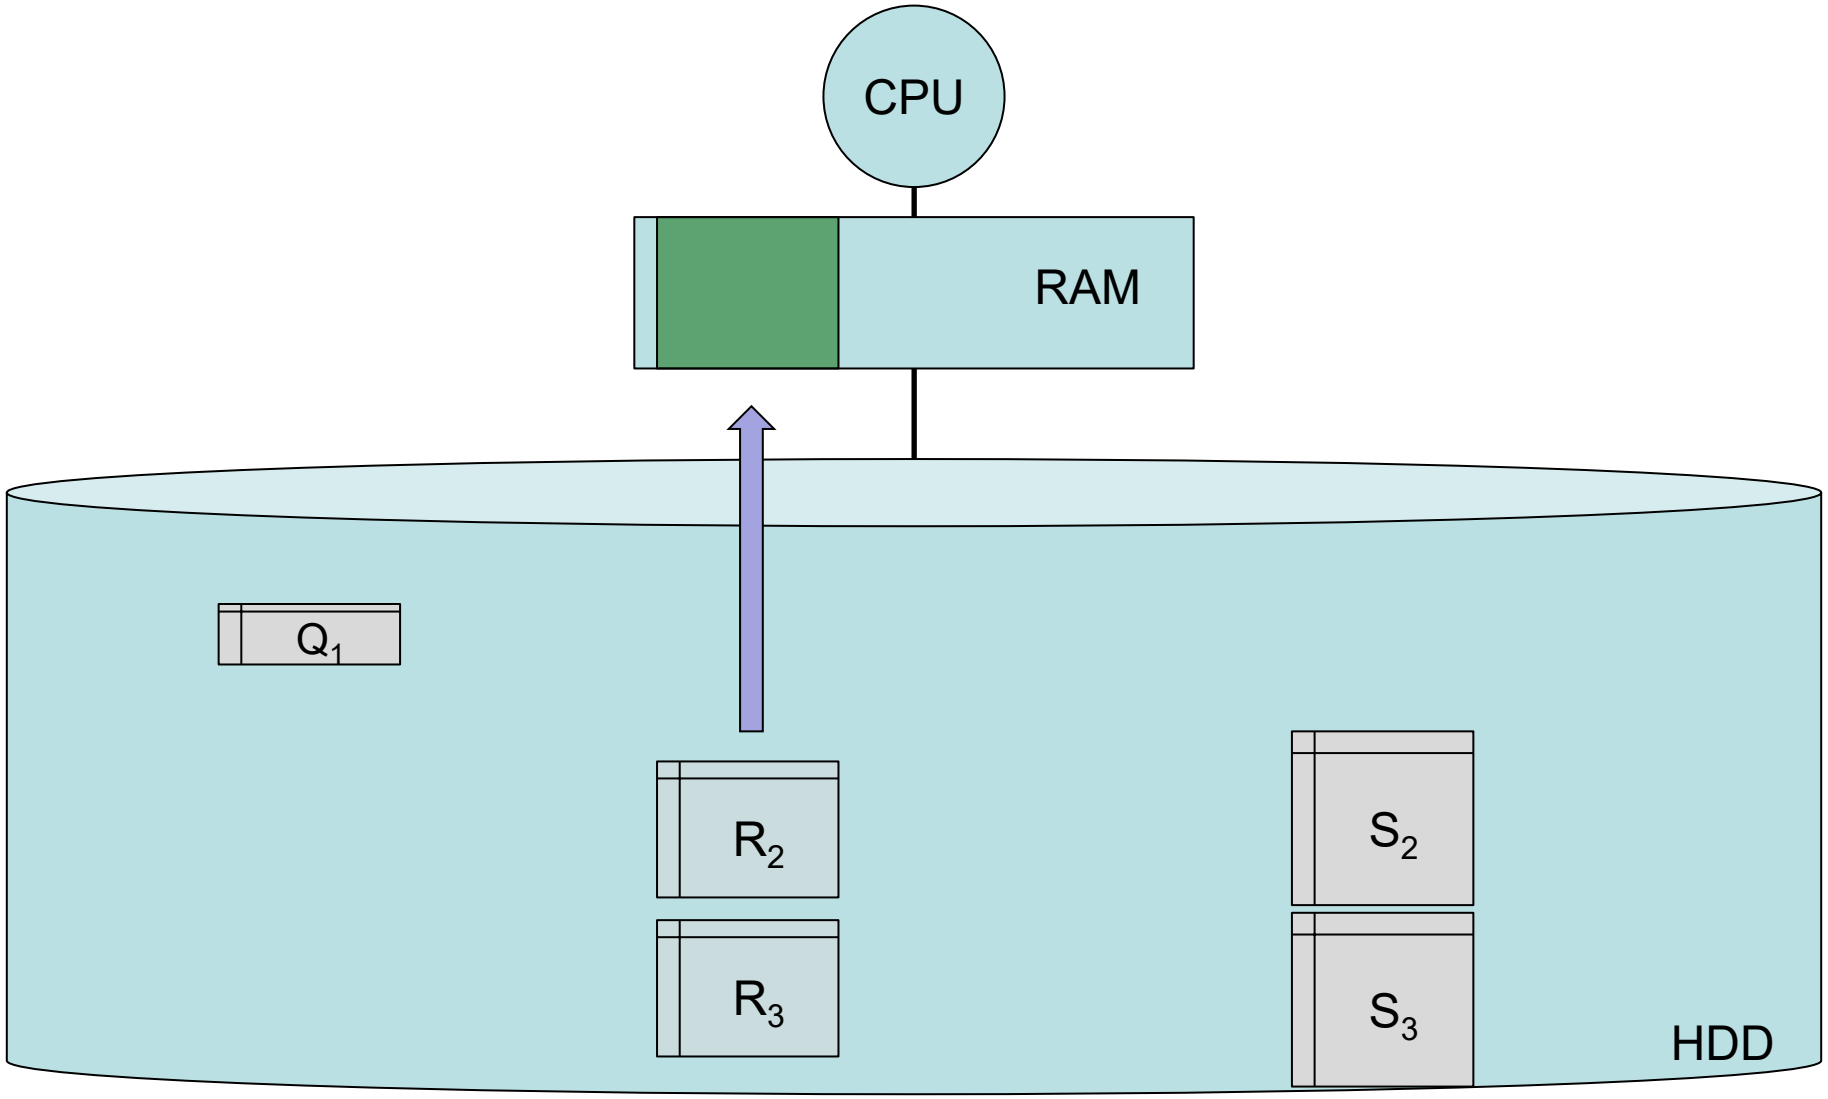

# HJ. 2-й проход

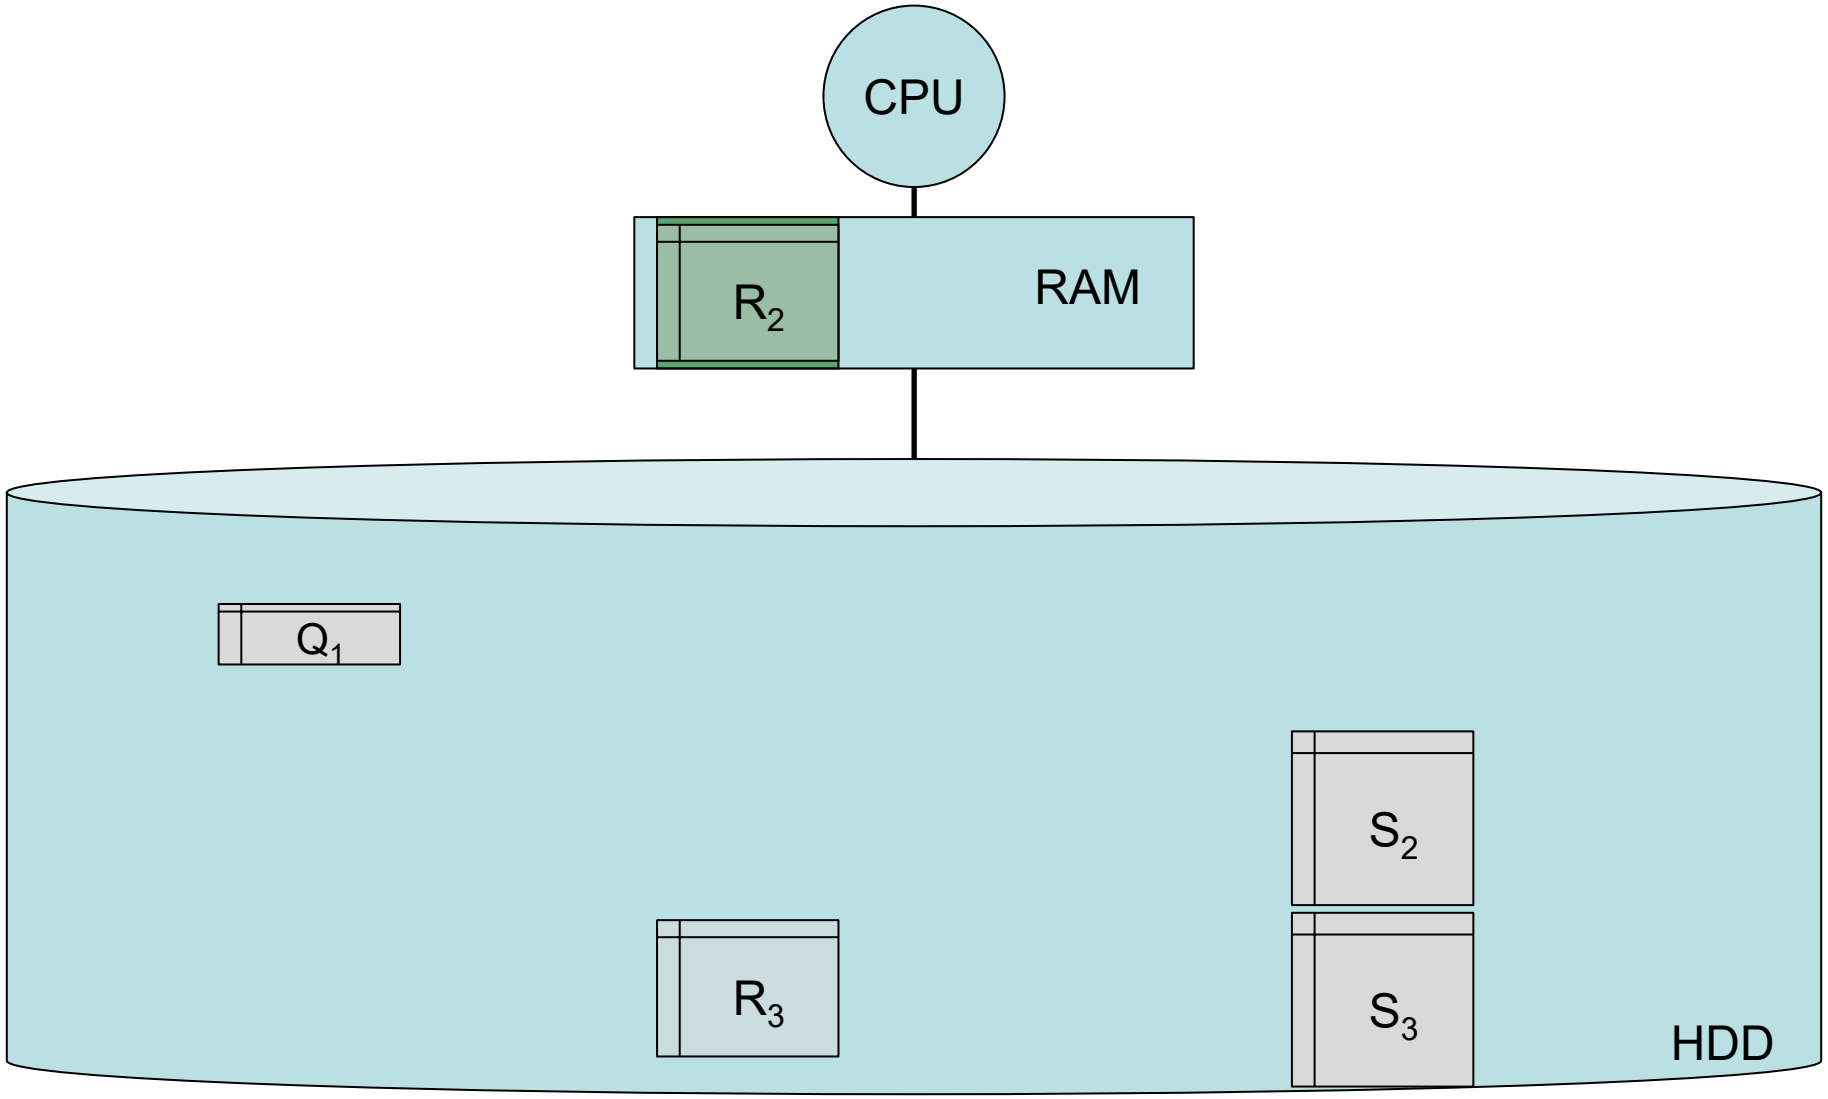

# HJ. 2-й проход

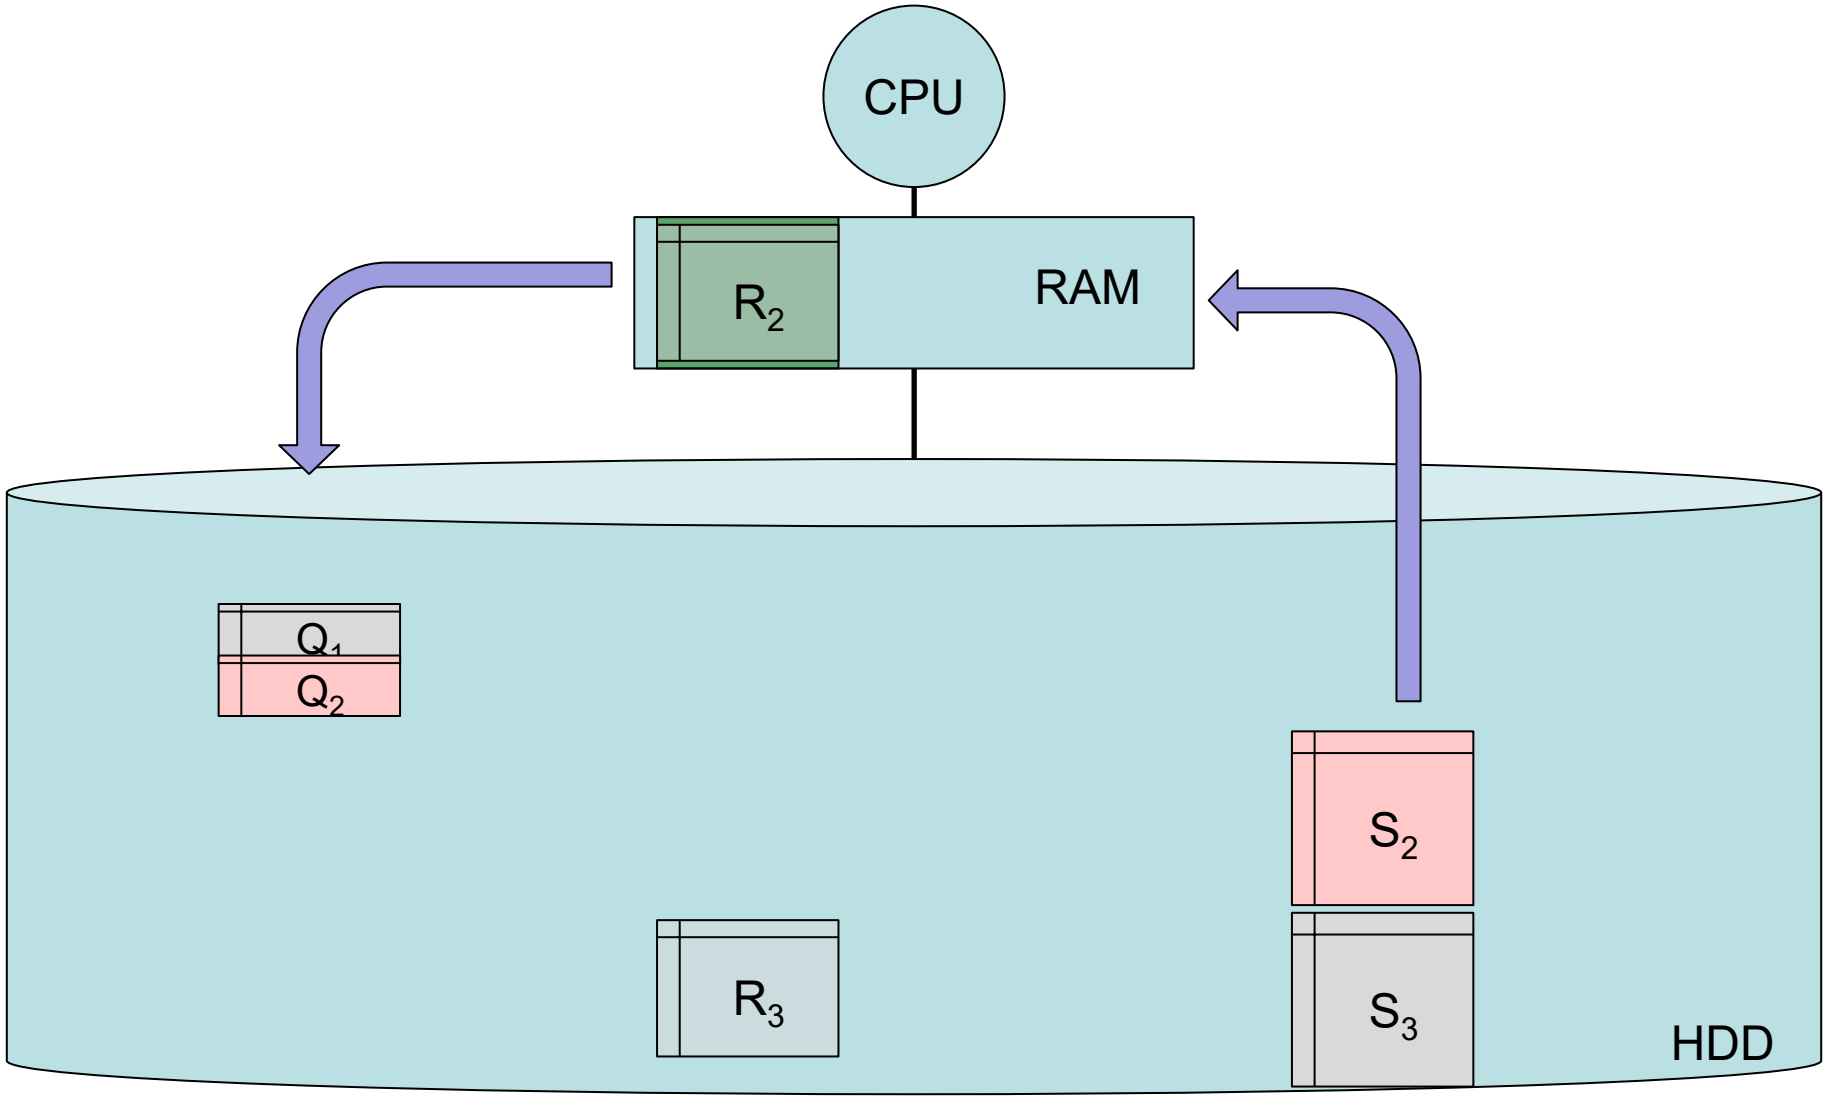

# HJ. 2-й проход

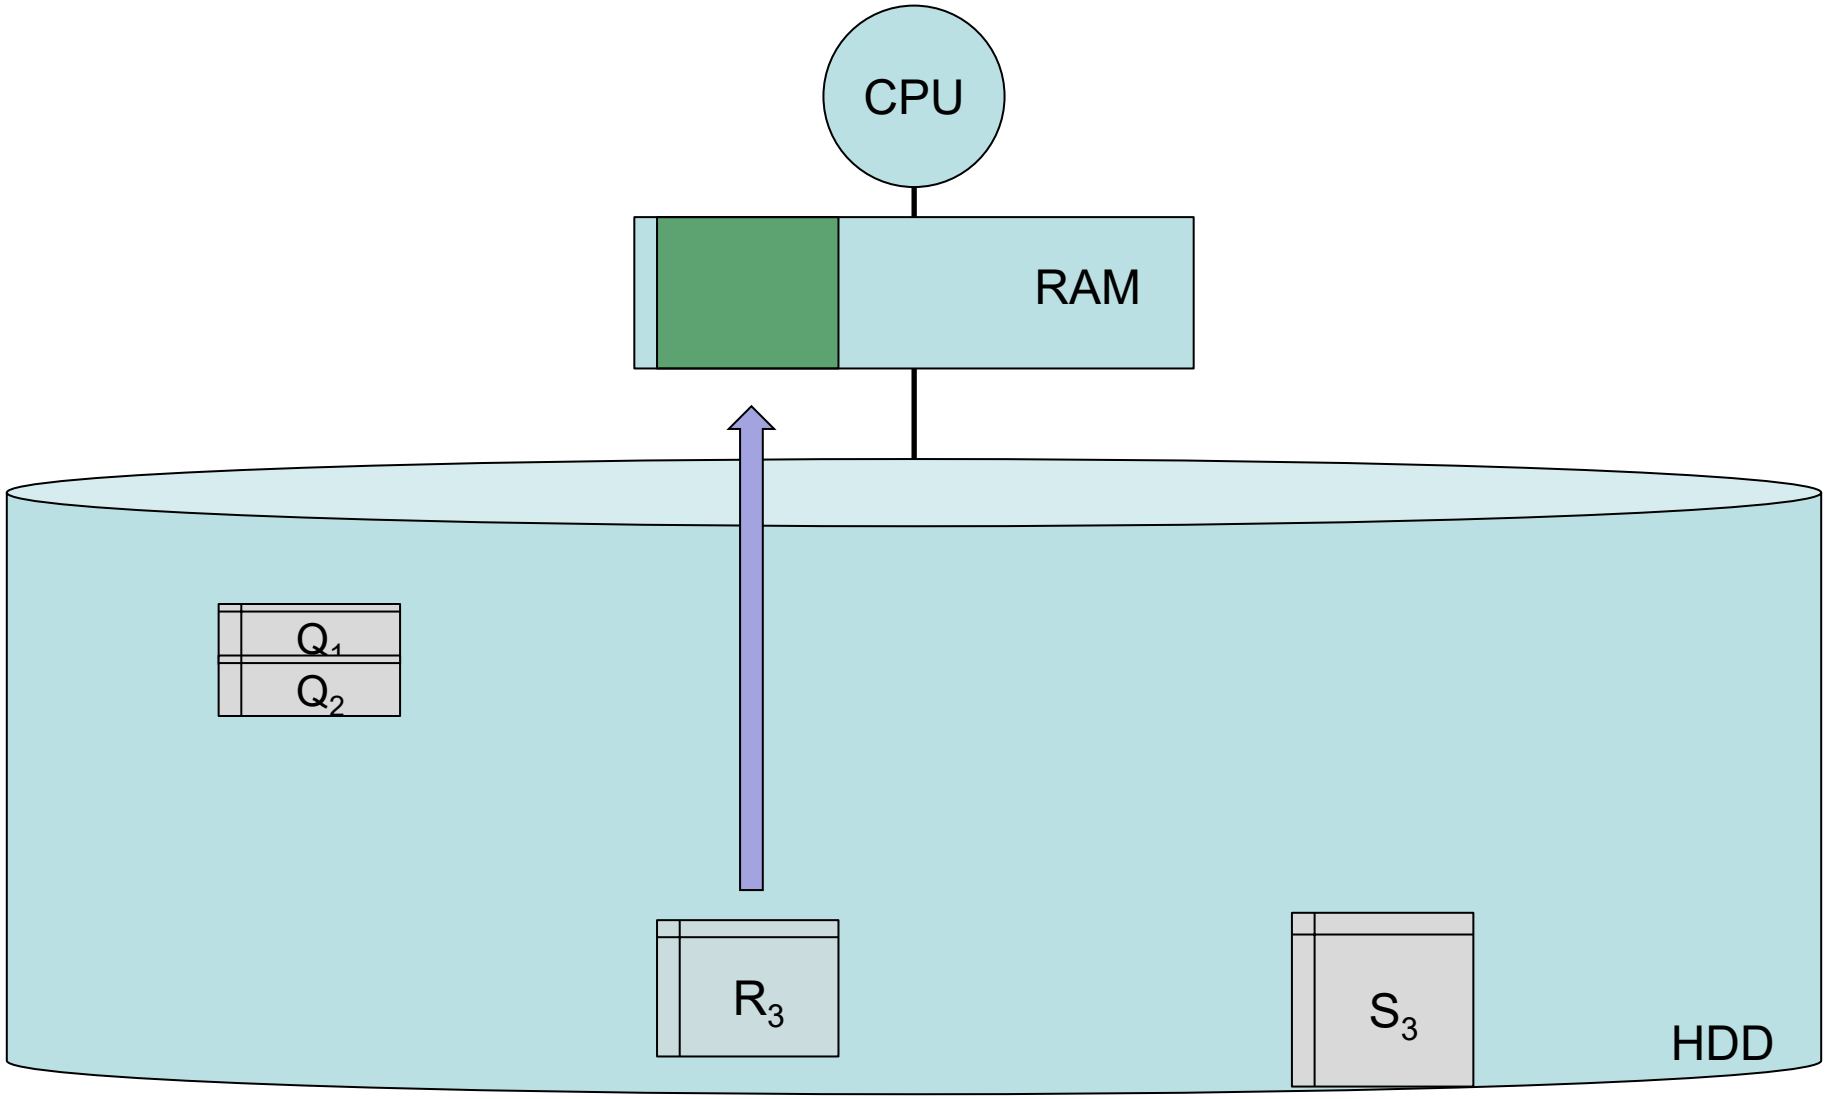

# HJ. 2-й проход

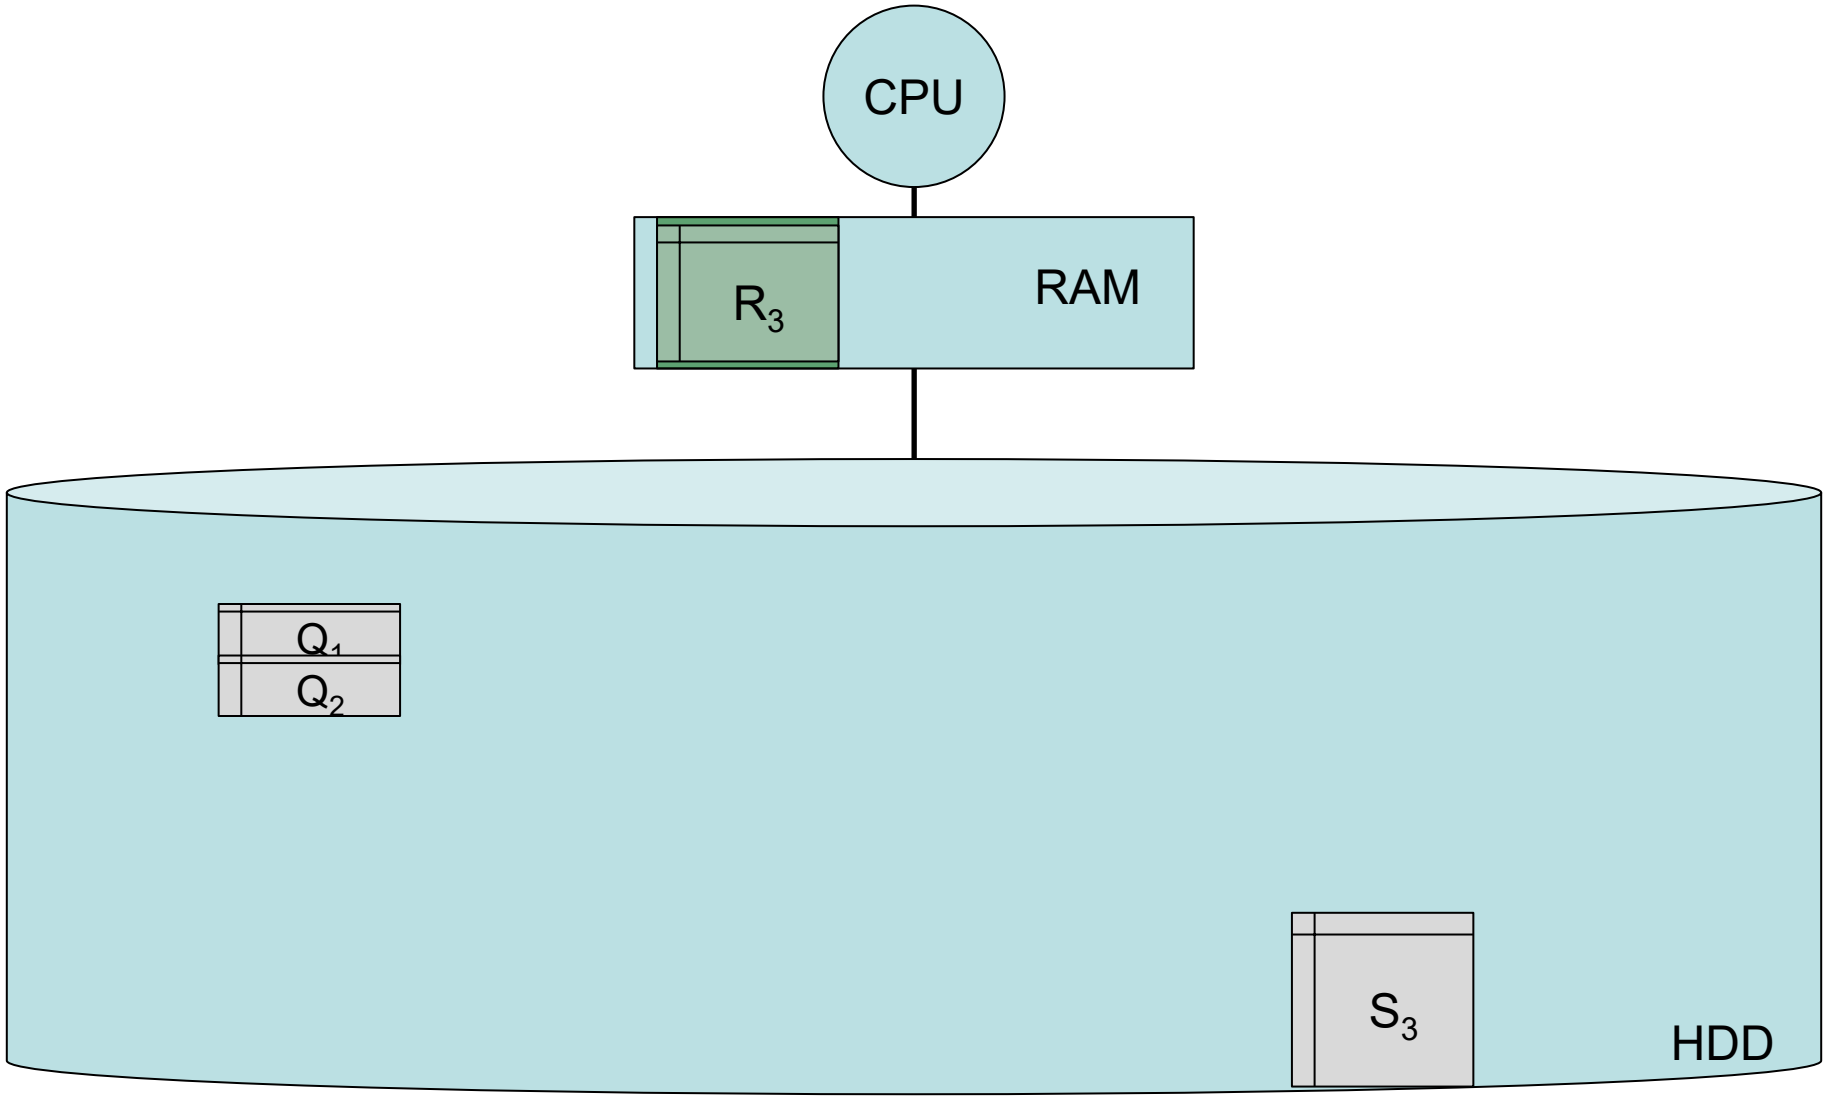

# HJ. 2-й проход

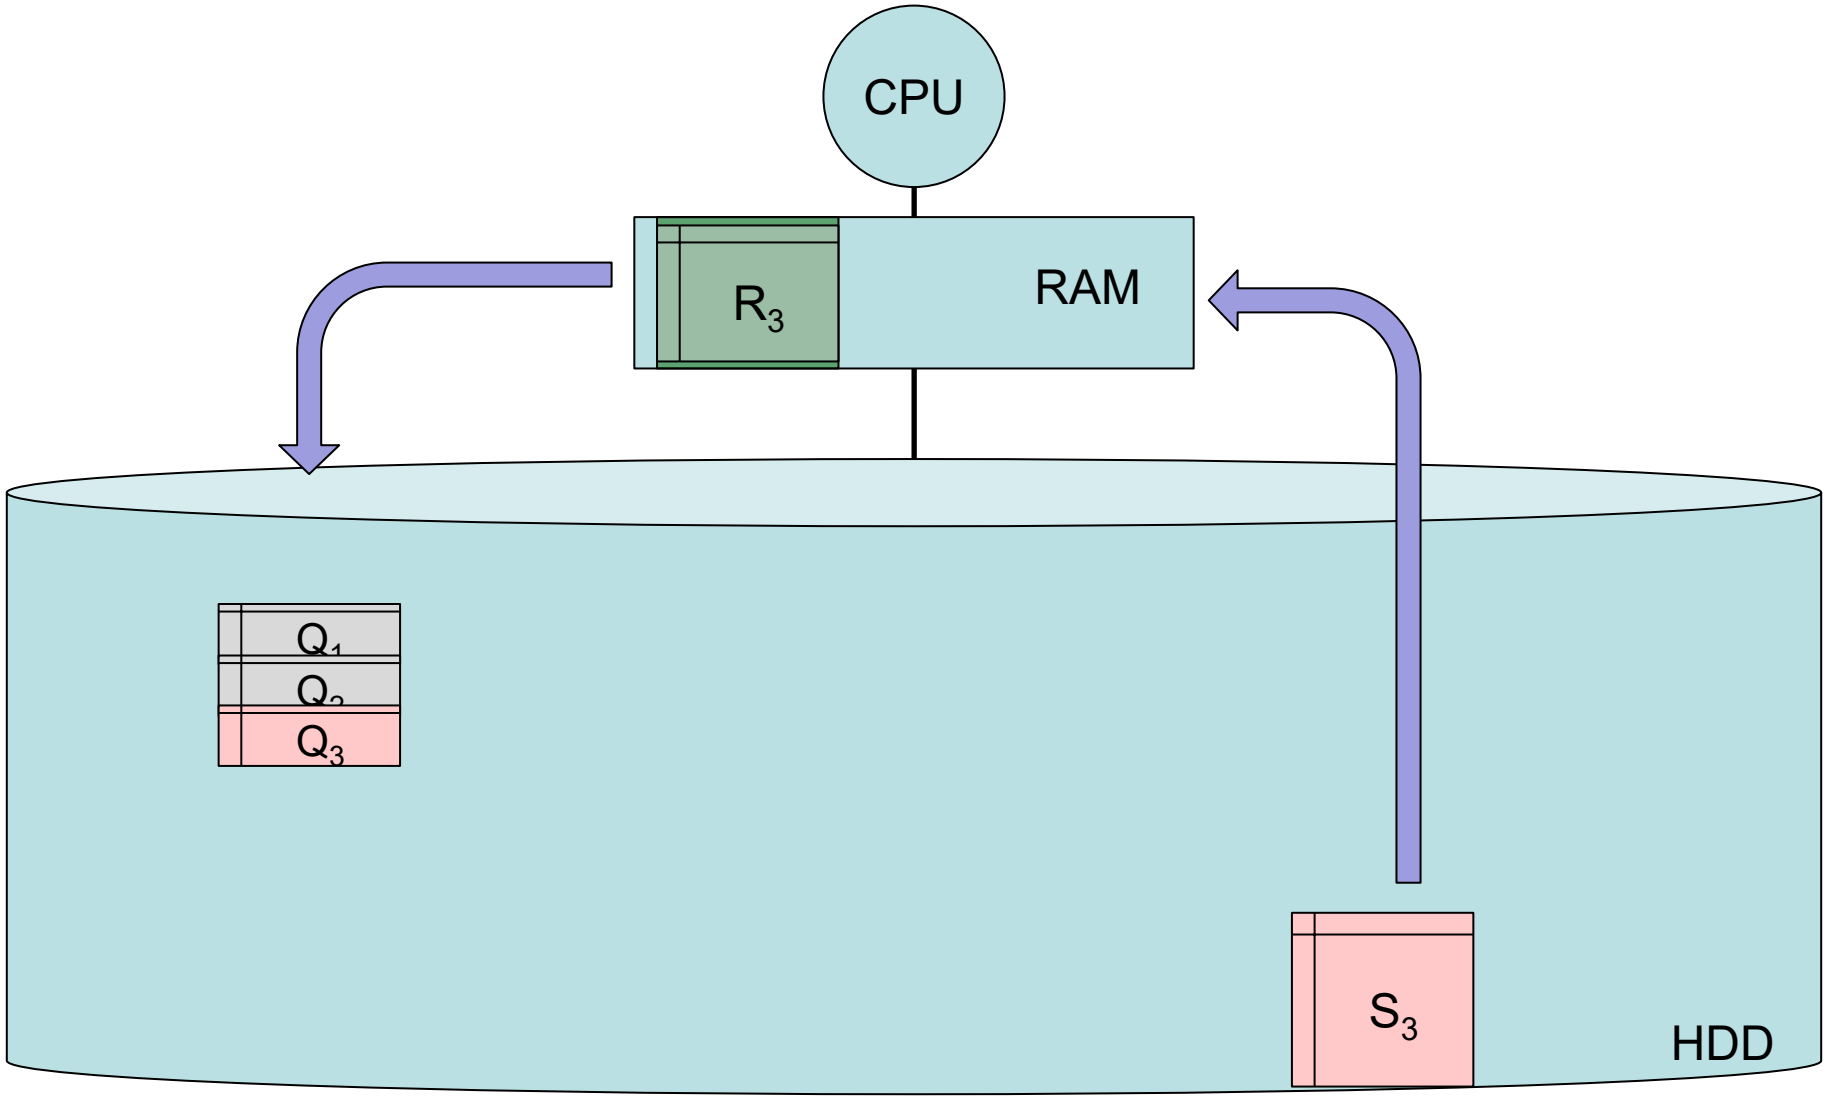

# HJ. 2-й проход

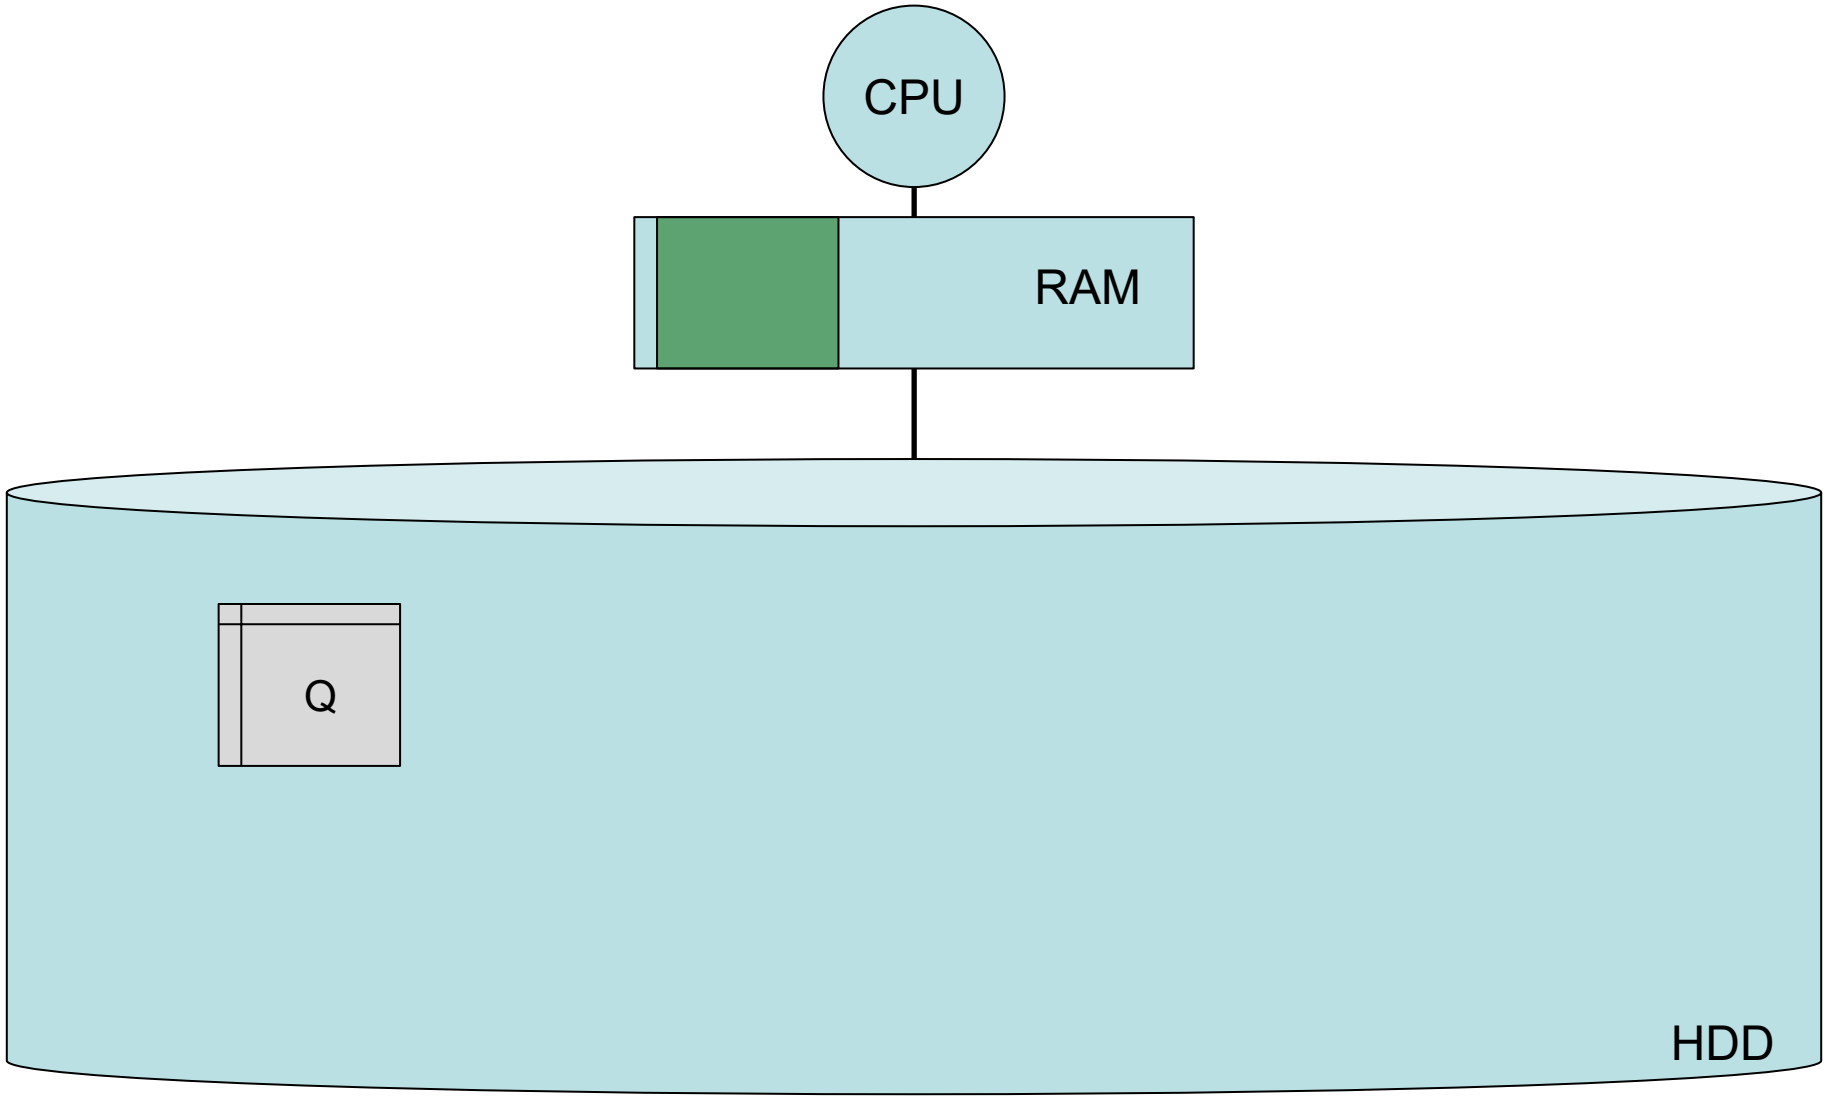

# Оценка эффективности *HJ*

$$R(A,B) \bowtie S(C,A) \quad T(R) = 150 \quad T(S) = 3000$$

| Атрибут | Тип | Семантика | Длина (байт) |
|---|---|---|---|
| A | int | Целое | 16 |
| B | int | Целое | 16 |
| C | string | Строка | 176 |

| Объект | Длина (байт) |
|---|---|
| Заголовок записи | 8 |
| Длина блока | 3024 |
| Заголовок блока | 24 |

| | $R$ | $S$ |
|---|---|---|
| Длина записи | $2 \cdot 16 + 8 = 40$ | $16 + 176 + 8 = 200$ |
| Записей в блоке | $(3024 - 24)/40 = 75$ | $(3024 - 24)/200 = 15$ |
| Количество блоков | $150/75 = 2$ | $3000/15 = 200$ |

| **Число обменов с диском*** | **?** |
|---|---|

*) Без учета записи результата.

# HHJ (Hybrid Hash Join)

## Гибридное соединение с хешированием

**I проход**:

**for** $r \in R$ **do**

Если $h(r.A) = 1$ поместить $r$ в RAM

Если $h(r.A) = 2$ записать $r$ в $R_2$

…

Если $h(r.A) = k$ записать $r$ в $R_k$

**for** $s \in S$ **do**

Если $h(s.A) = 1$ найти в RAM все $r$ такие, что $s.A = r.A$;

для каждой такой пары построить кортеж-соединение

Если $h(s.A) = 2$ записать $r$ в $S_2$

…

Если $h(s.A) = k$ записать $r$ в $S_k$

**II проход**:

**for** $i$ **from** 2 **to** $k$ **do**

Загрузить $R_i$ в RAM

**for** $s \in \boldsymbol{S_i}$ **do**

Найти в RAM все $r$ такие, что $s.A = r.A$;

для каждой такой пары построить кортеж-соединение

# HJ. 1-й проход

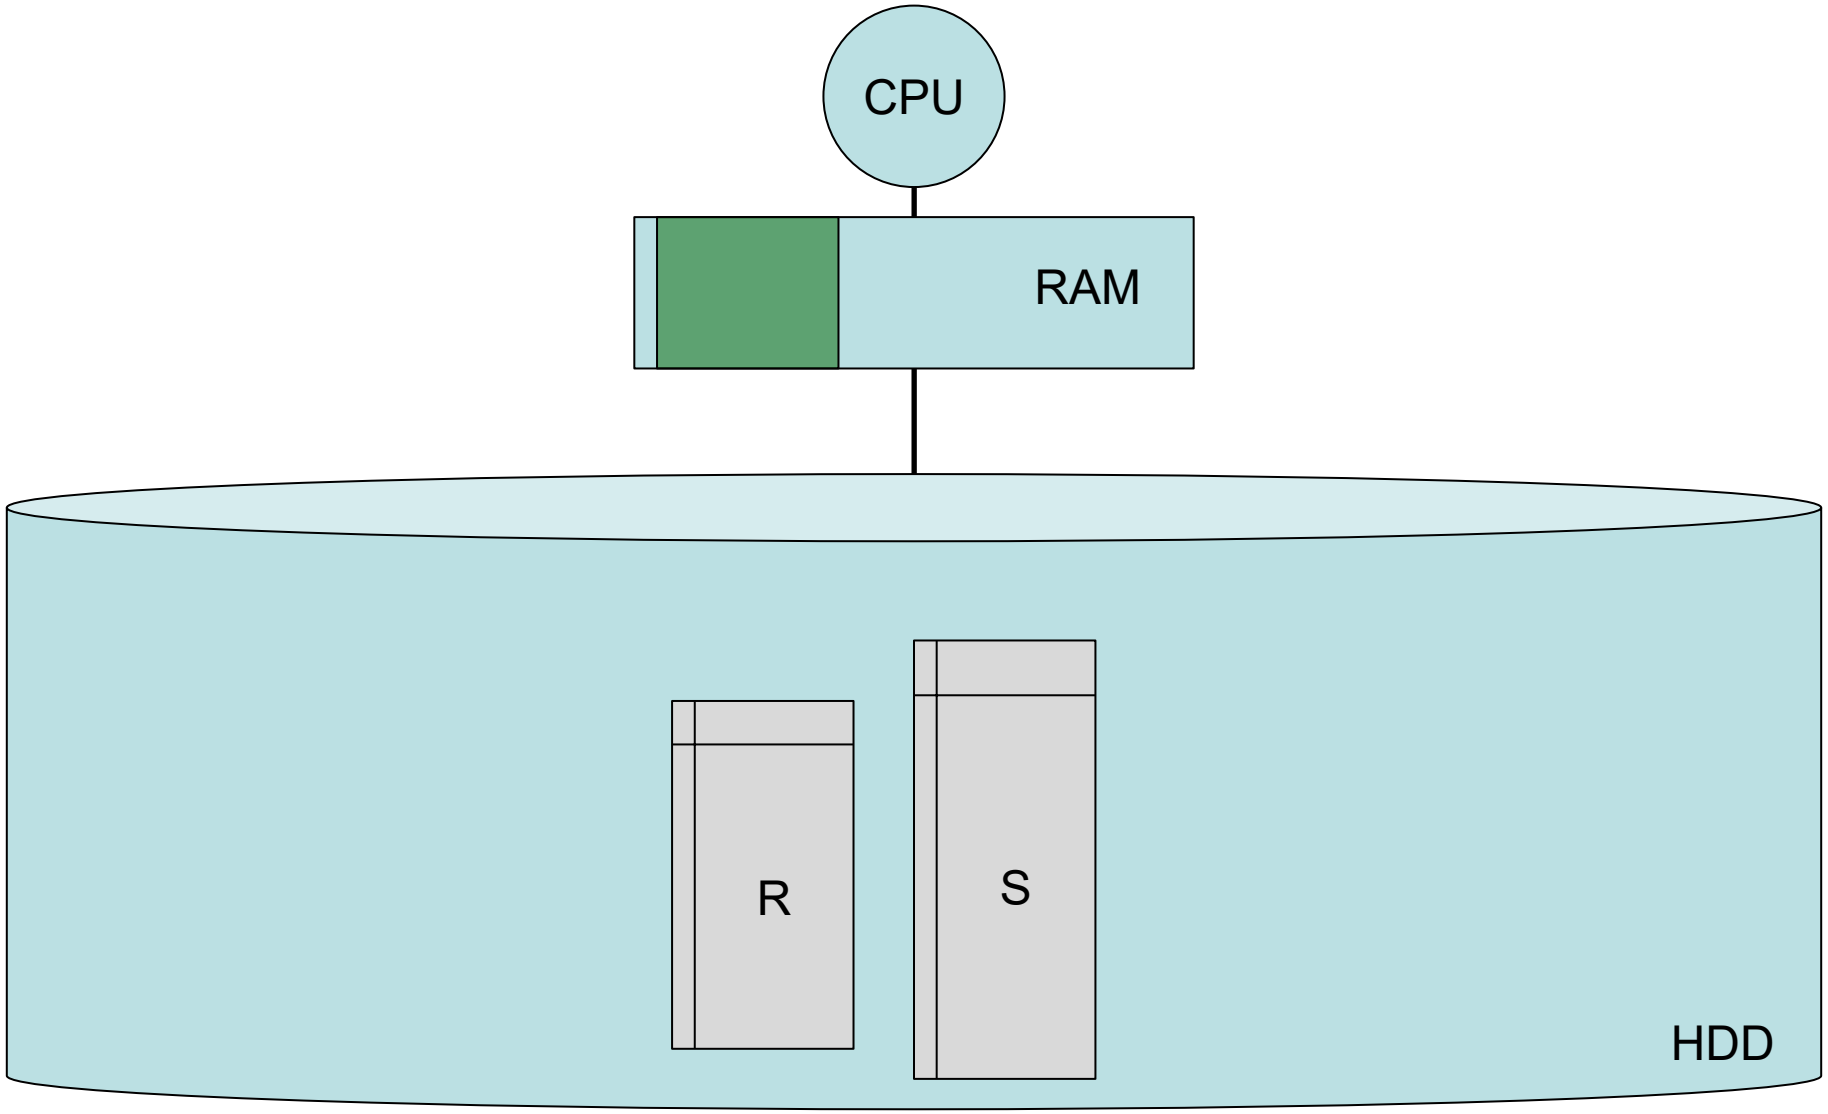

# HJ. 1-й проход

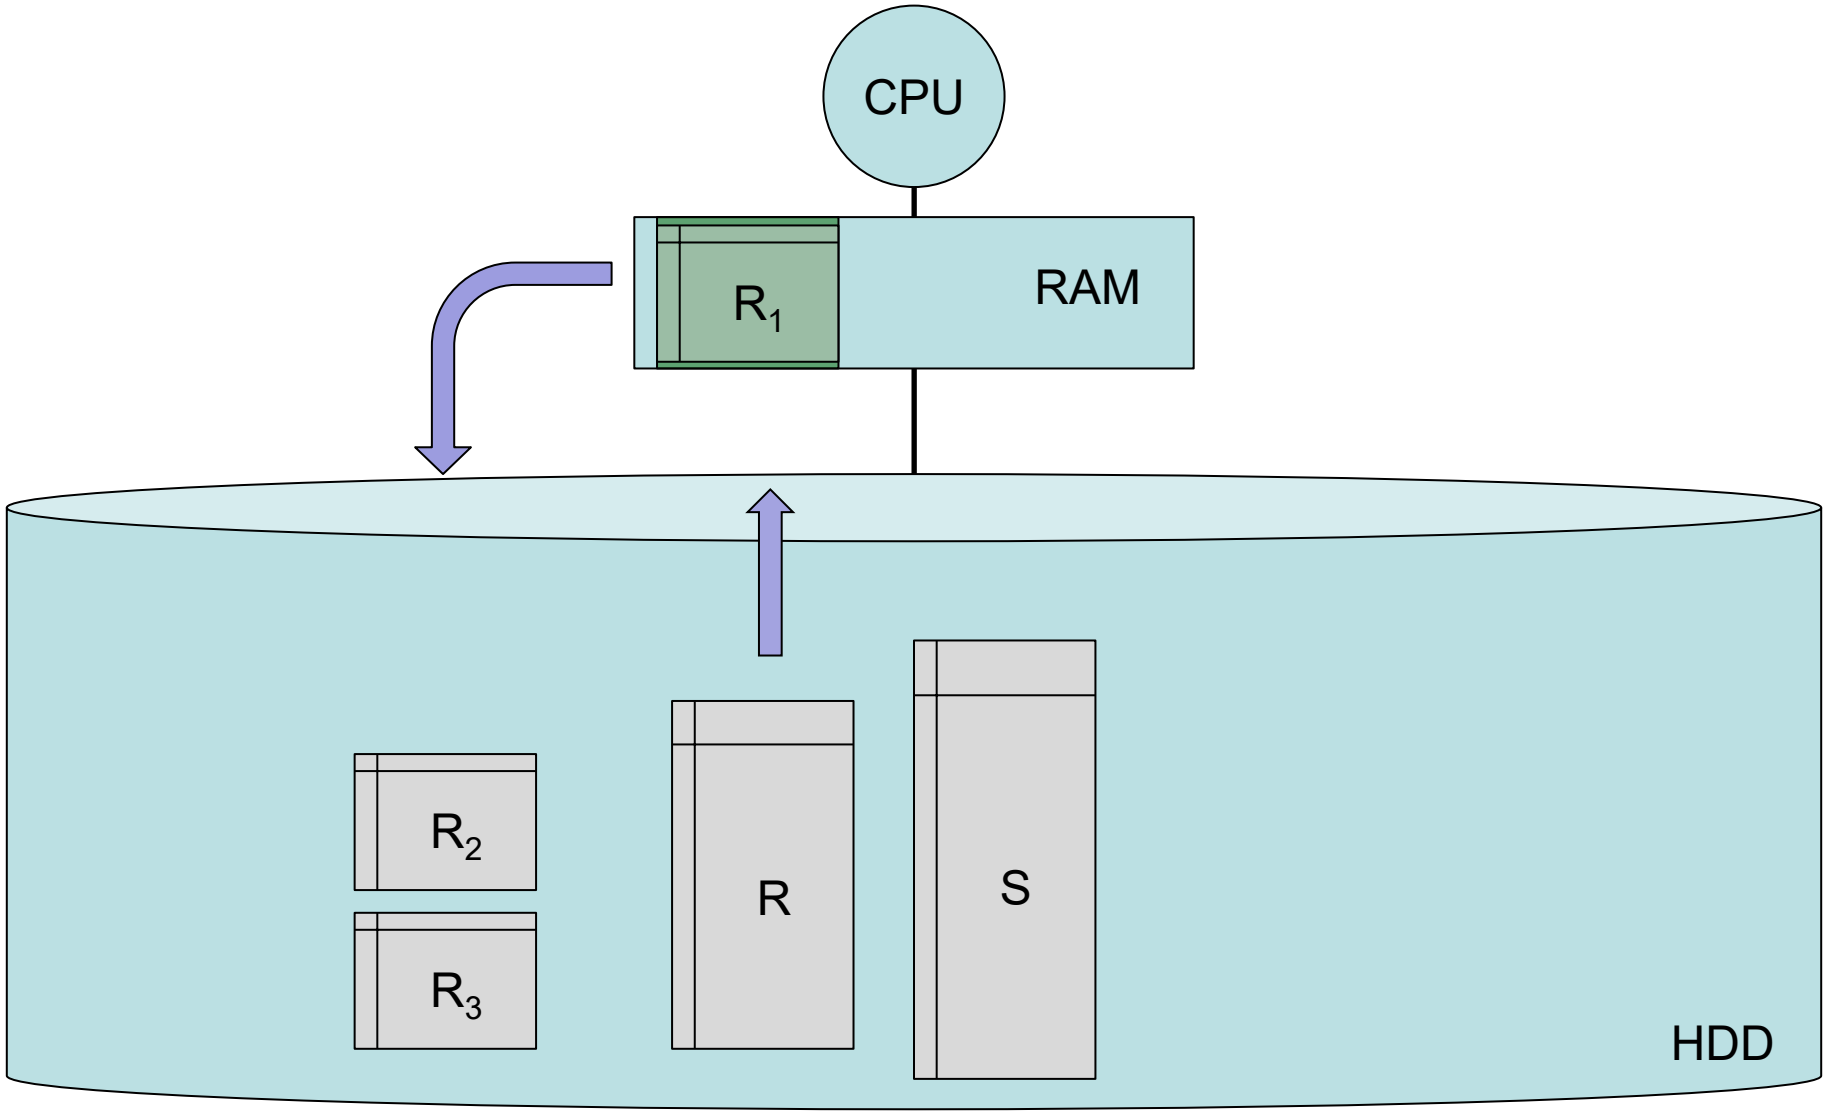

# HJ. 1-й проход

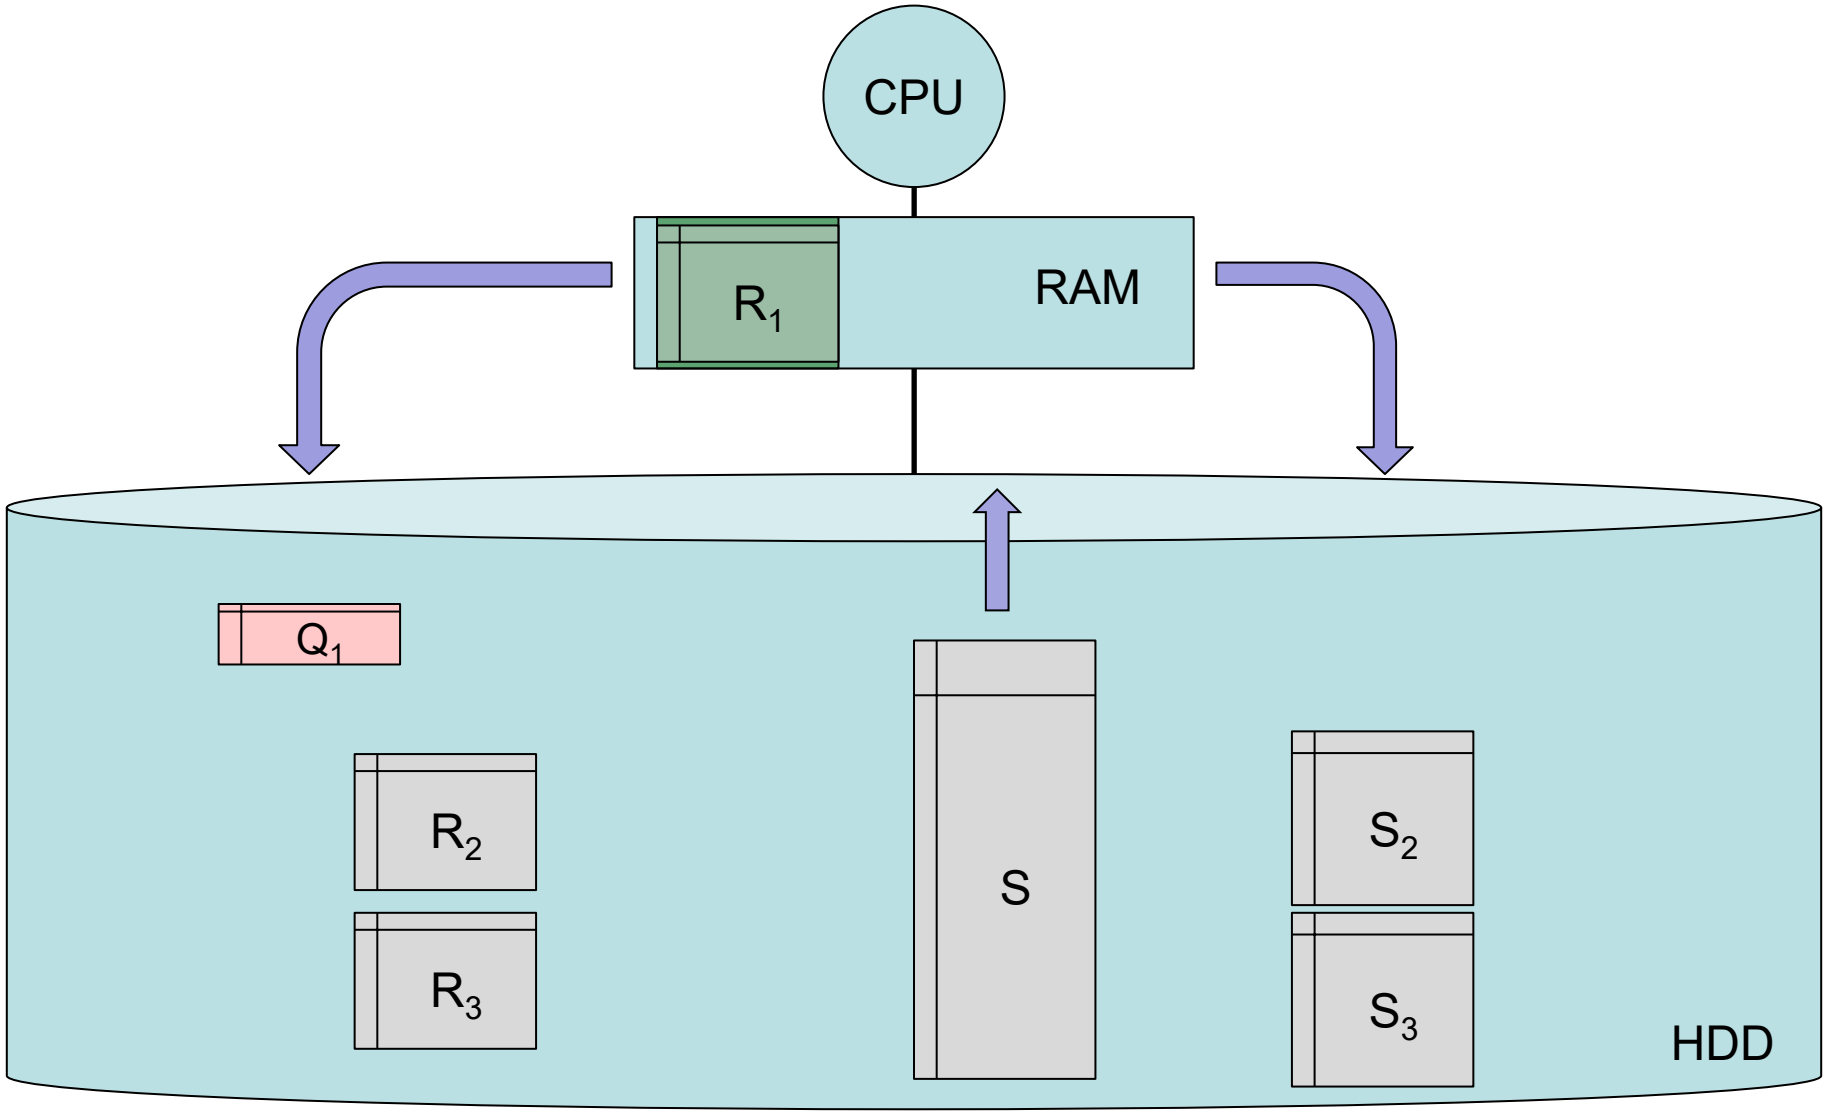

# HJ. 2-й проход

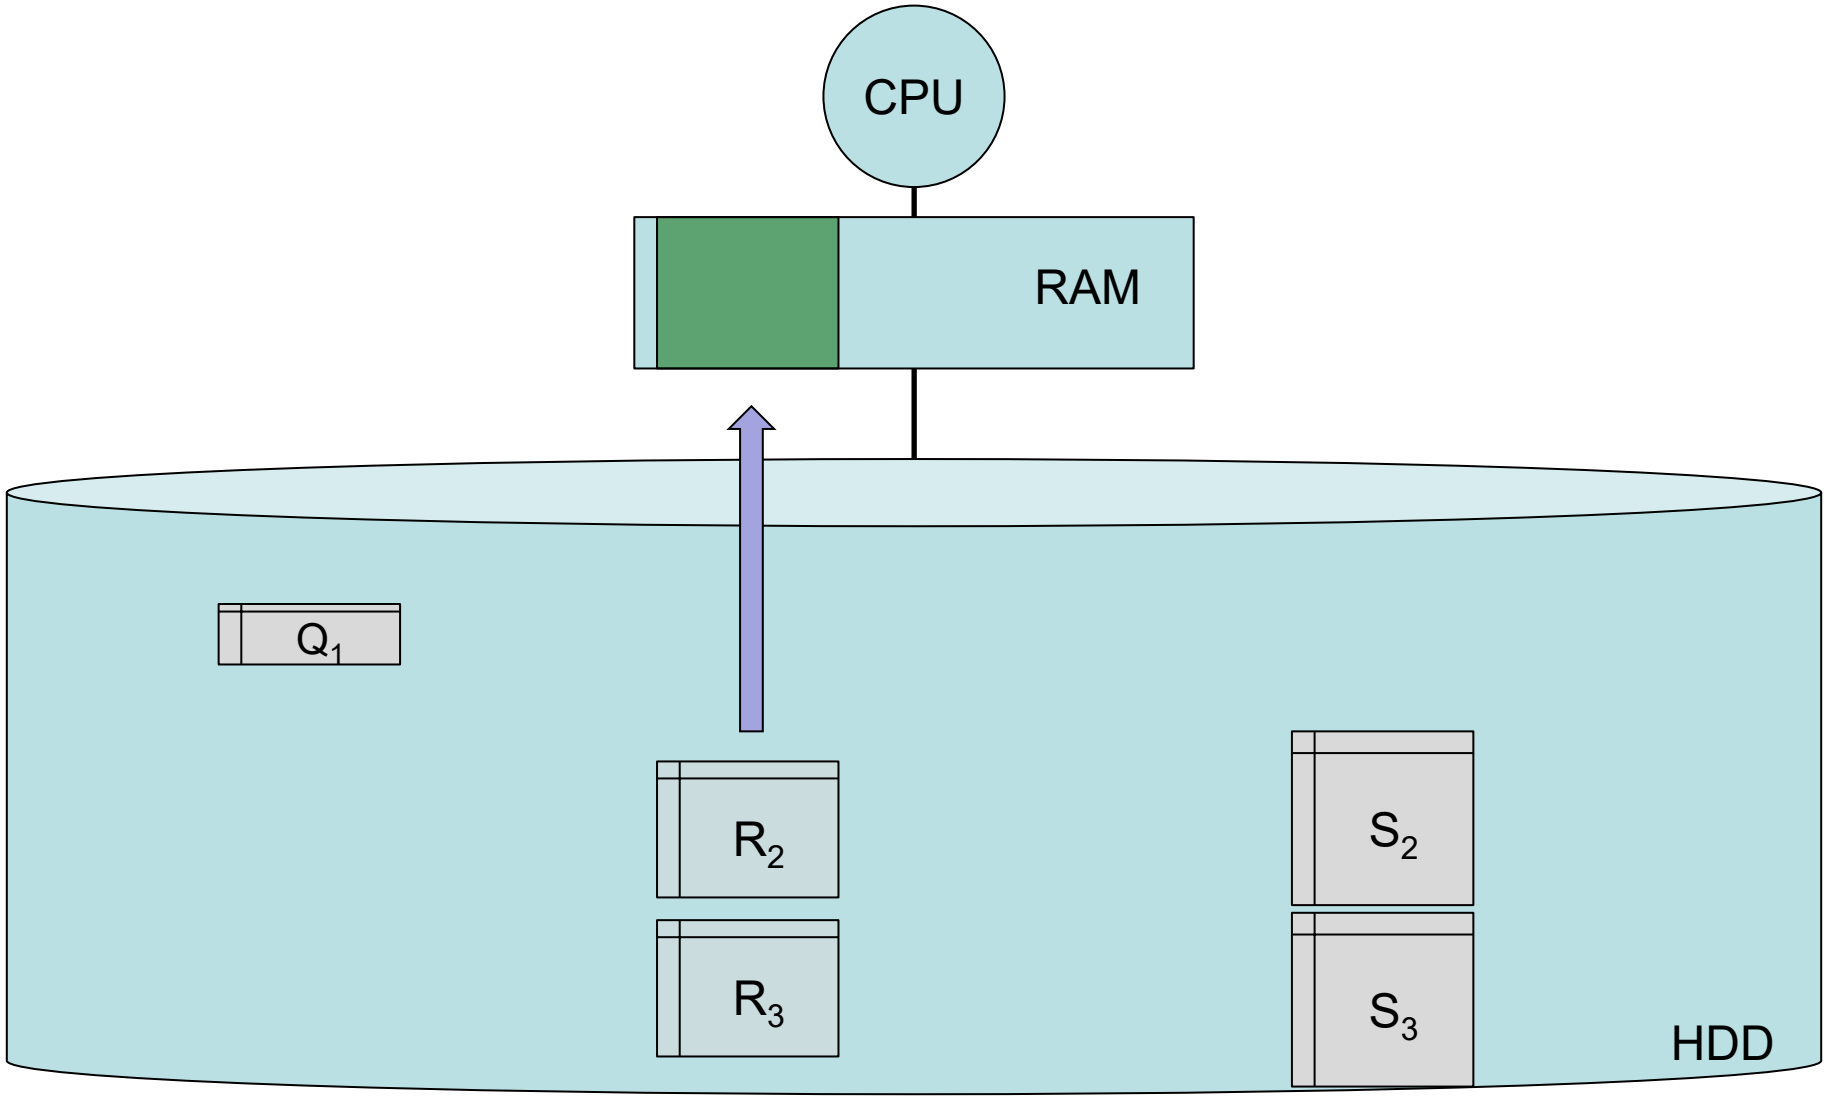

# HJ. 2-й проход

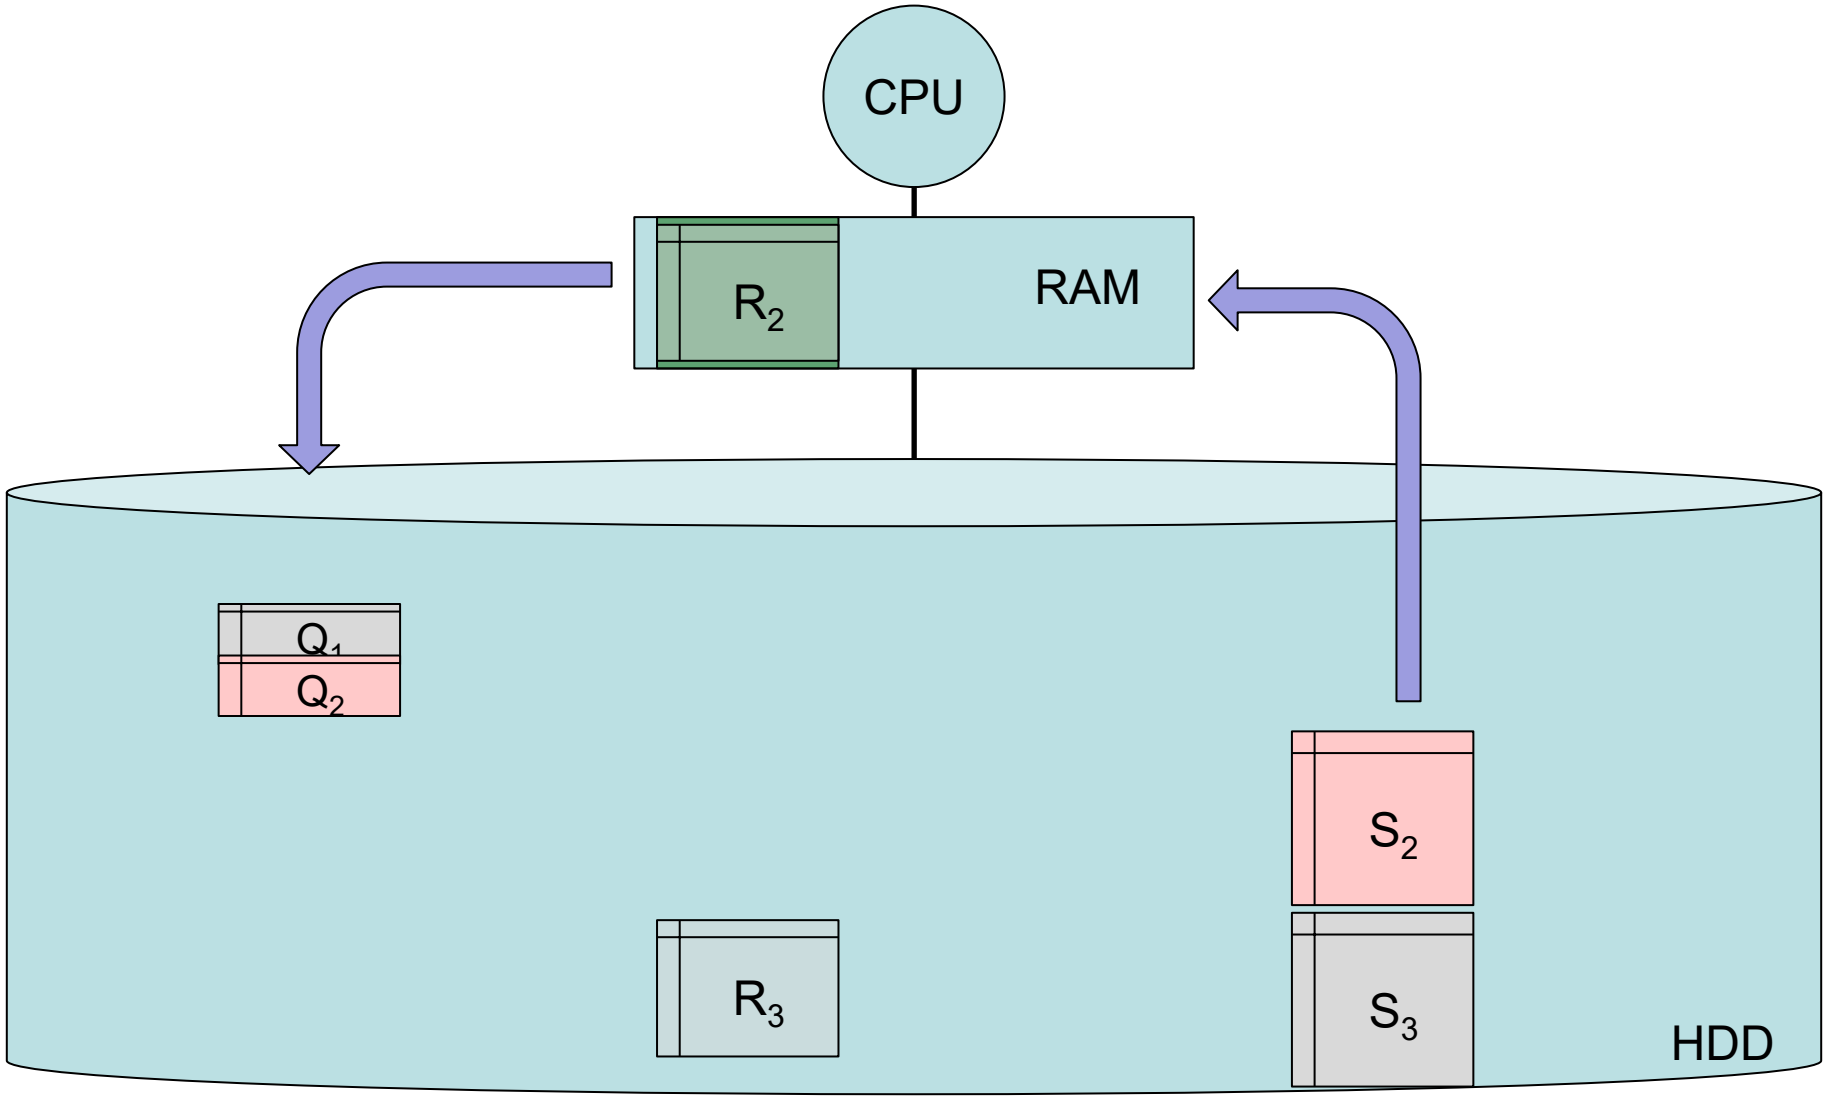

# HJ. 2-й проход

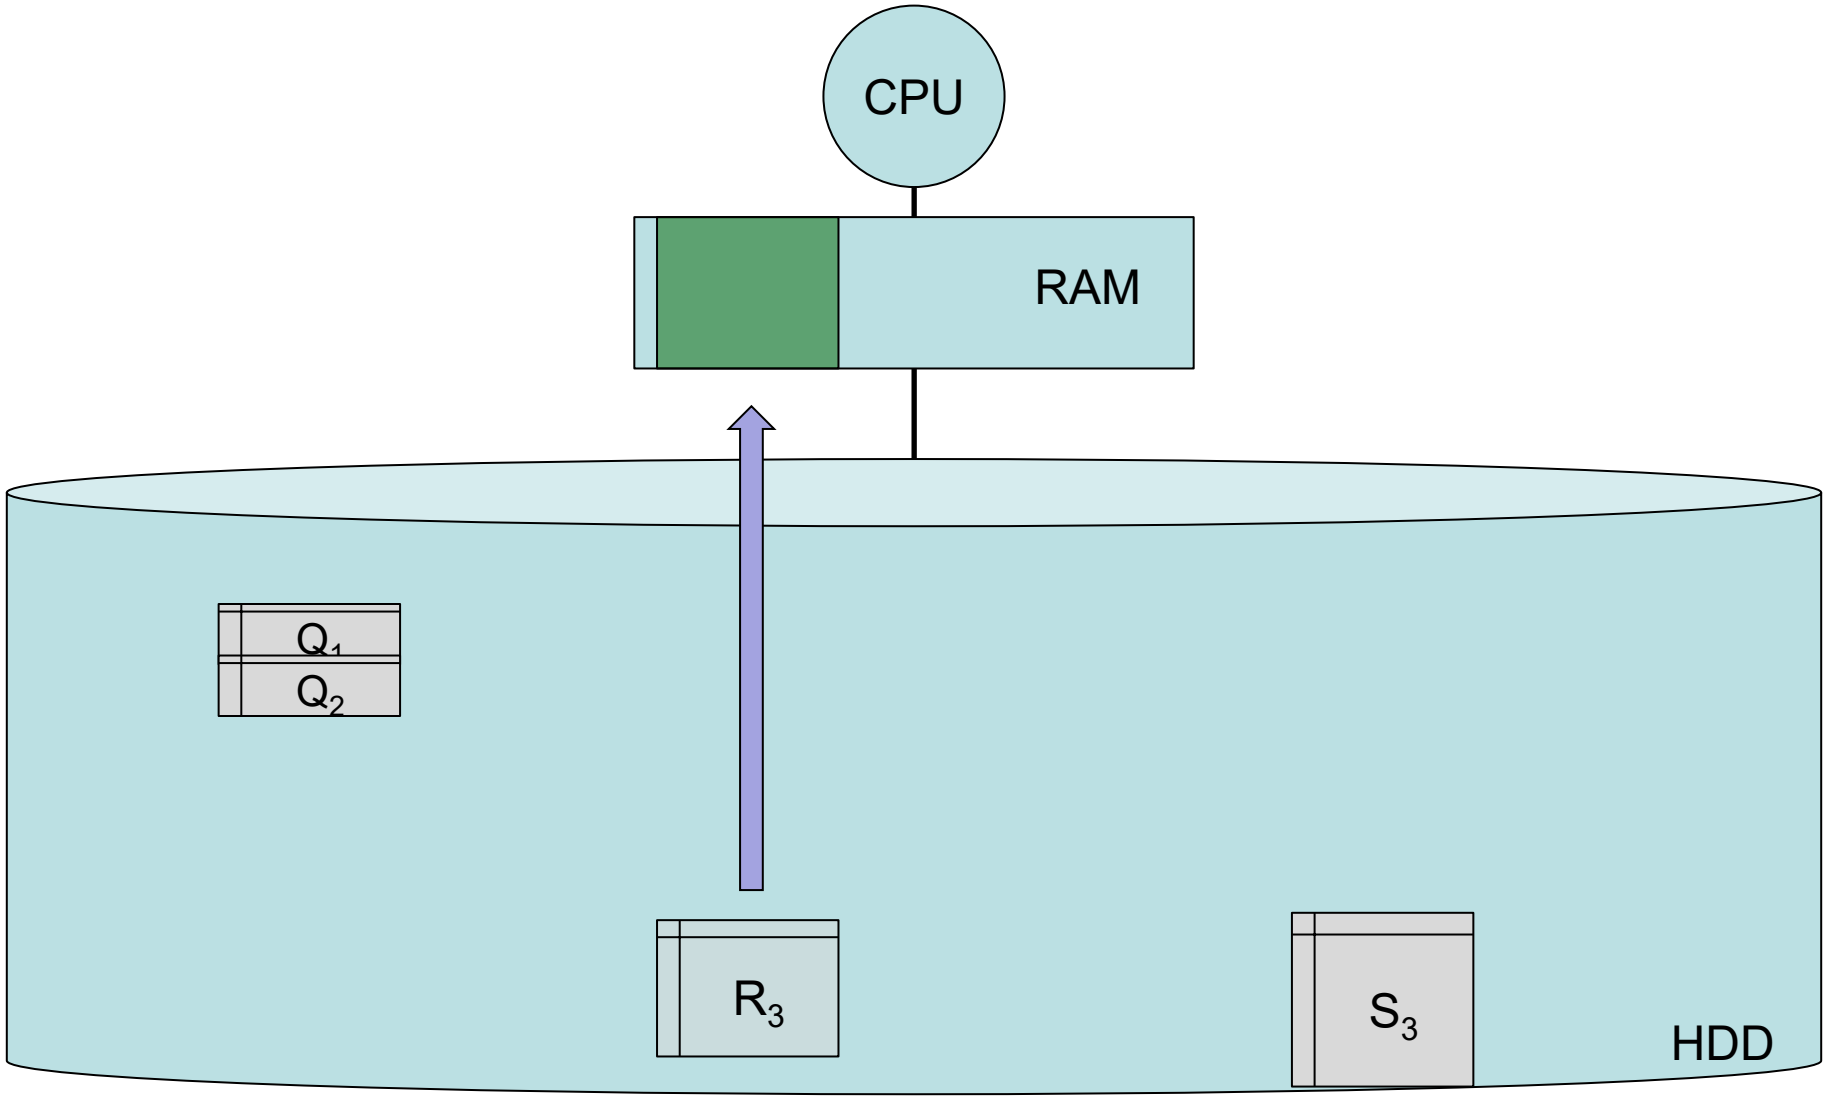

# HJ. 2-й проход

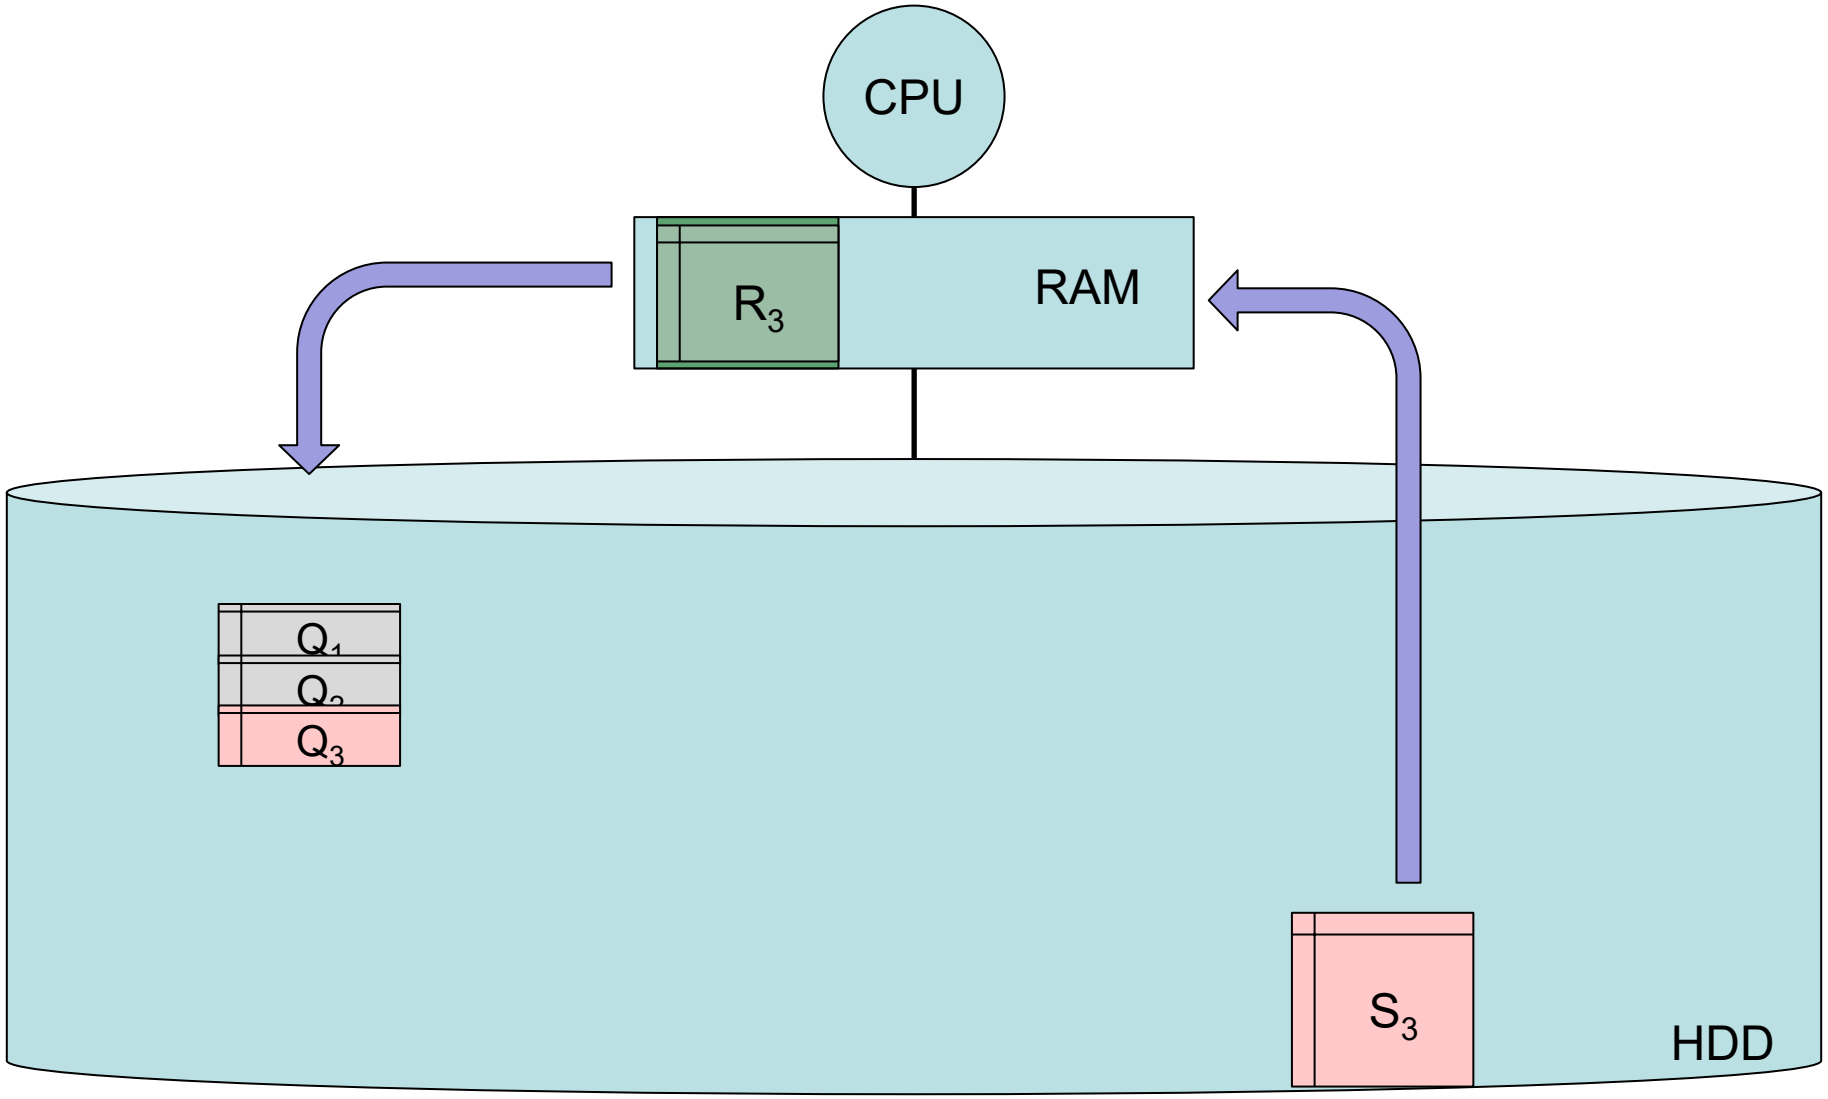

# HJ. 2-й проход

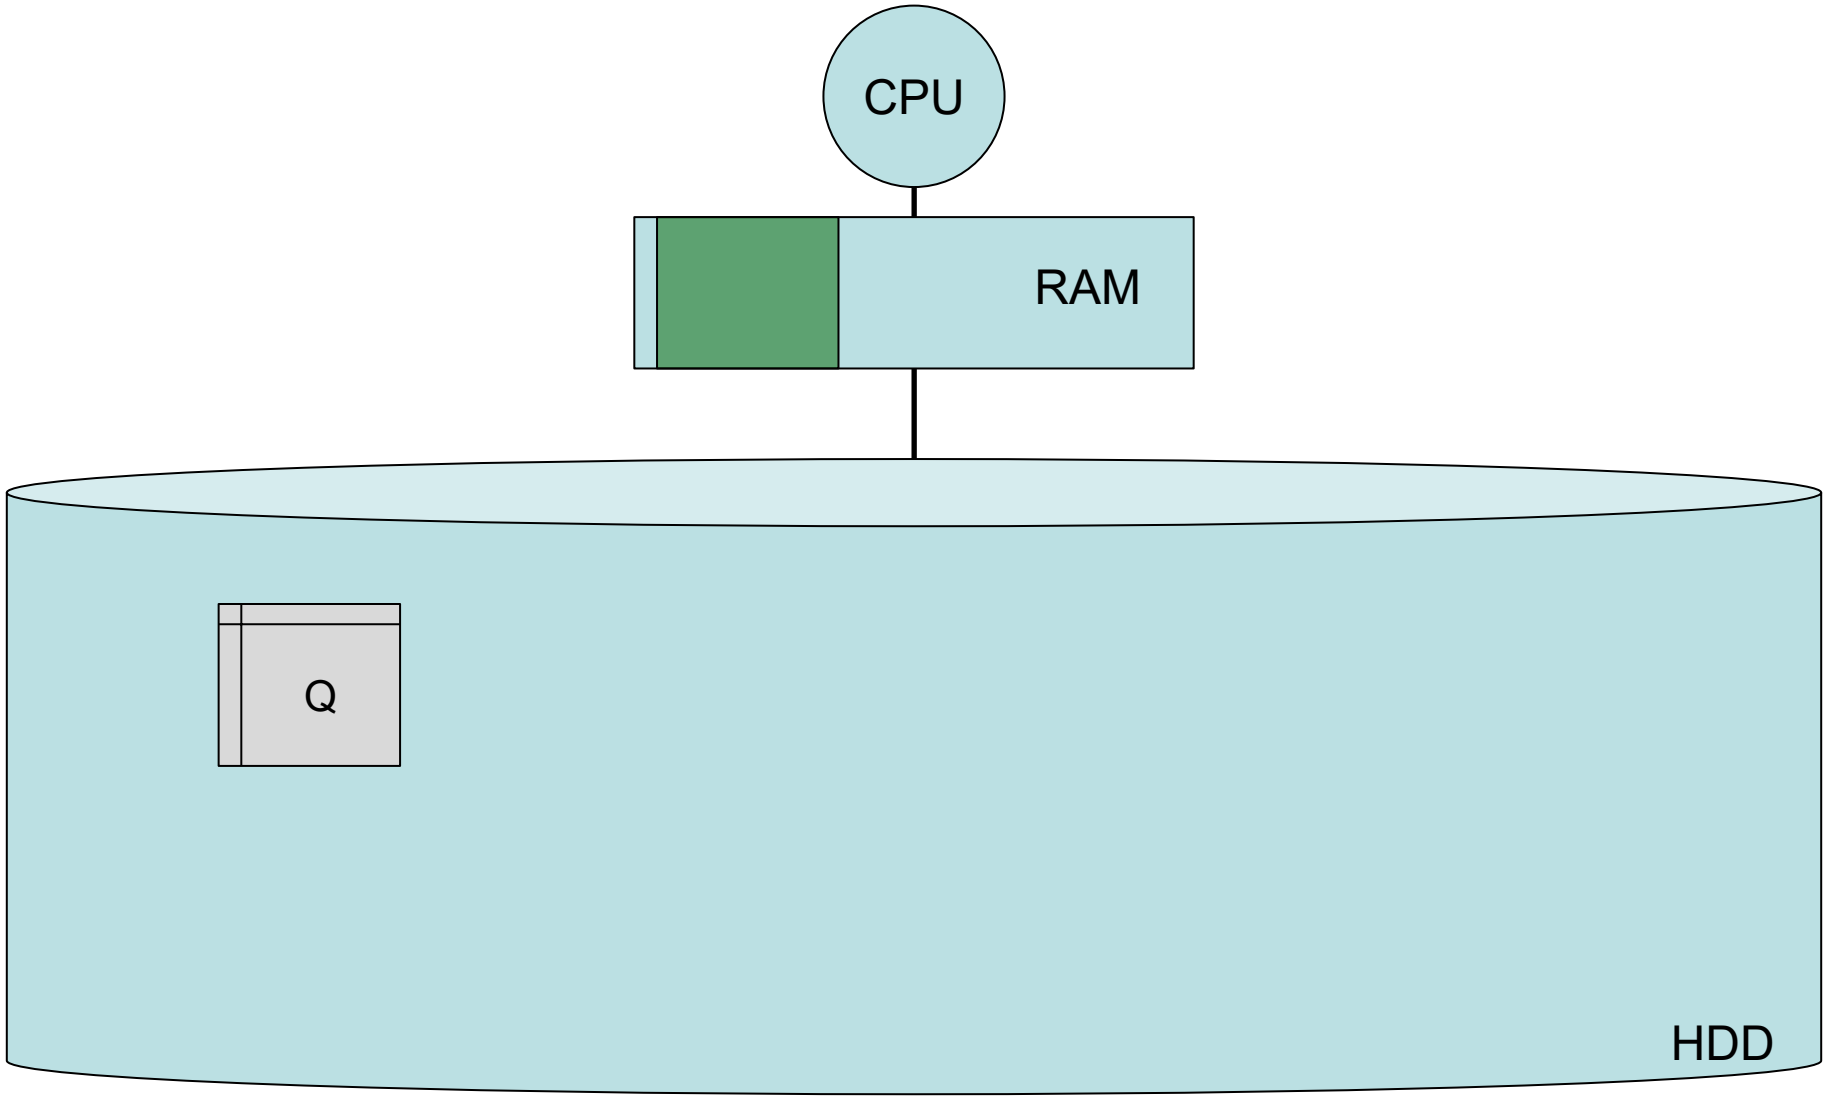

# Оценка эффективности *HHJ*

$$R(A,B) \bowtie S(C,A) \quad T(R) = 150 \quad T(S) = 3000$$

| Атрибут | Тип | Семантика | Длина (байт) |
|---|---|---|---|
| A | int | Целое | 16 |
| B | int | Целое | 16 |
| C | string | Строка | 176 |

| Объект | Длина (байт) |
|---|---|
| Заголовок записи | 8 |
| Длина блока | 3024 |
| Заголовок блока | 24 |

| | $R$ | $S$ |
|---|---|---|
| Длина записи | $2 \cdot 16 + 8 = 40$ | $16 + 176 + 8 = 200$ |
| Записей в блоке | $(3024 - 24)/40 = 75$ | $(3024 - 24)/200 = 15$ |
| Количество блоков | $150/75 = 2$ | $3000/15 = 200$ |

Для случая, когда буфер для $R$ имеет размер в 1 блок

| **Число обменов с диском*** | ? |
|---|---|

*) Без учета записи результата.

# MJPK (Merge Join by Primary Key)

Соединение слиянием по первичному ключу

$$R(A^*, B) \bowtie S(C, A^\#)$$

- $R$ и $S$ – ***отсортированы*** в порядке возрастания $A$
- $A$ – первичный ключ в $R$ и внешний ключ в $S$

# MJPK : схема реализации метода open

```
void* open(node){
    node.leftSon.open();
    node.rightSon.open();
    node.leftSon.next();
    node.rightSon.next();
};
```

# MJPK: схема реализации метода next

```
void* next(node){
   while(node.rightSon.buf!=EOF){
      if(MATCH_A(node.leftSon.buf,node.rightSon.buf)){
            node.buf=JOIN_A(node.leftSon.buf,node.rightSon.buf);
            node.rightSon.next();
            return;
      };
      node.leftSon.next();
   };
   node.buf=EOF;
};
```

# Оценка эффективности *MJPK*

$$R(A,B) \bowtie S(C,A) \quad T(R) = 150 \quad T(S) = 3000$$

| Атрибут | Тип | Семантика | Длина (байт) |
|---|---|---|---|
| A | int | Целое | 16 |
| B | int | Целое | 16 |
| C | string | Строка | 176 |

| Объект | Длина (байт) |
|---|---|
| Заголовок записи | 8 |
| Длина блока | 3024 |
| Заголовок блока | 24 |

| | $R$ | $S$ |
|---|---|---|
| Длина записи | $2 \cdot 16 + 8 = 40$ | $16 + 176 + 8 = 200$ |
| Записей в блоке | $(3024 - 24)/40 = 75$ | $(3024 - 24)/200 = 15$ |
| Количество блоков | $150/75 = 2$ | $3000/15 = 200$ |

| **Число обменов с диском*** | **?** |
|---|---|

*) Без учета записи результата.

# Конец лекции 9