쉽게 배우는 알고리즘

6장. 해시 테이블Hash Table

http://www.hanbit.co.kr

6장.해시 테이블Hash Table

사실을 많이 아는 것 보다는
이론적 틀이 중요하고,
기억력보다는
생각하는 법이 더 중요하다.

– 제임스 왓슨

학습목표

- 해시 테이블의 발생 동기를 이해한다.
- 해시 테이블의 원리를 이해한다.
- 해시 함수 설계 원리를 이해한다.
- 충돌 해결 방법들과 이들의 장단점을 이해한다.
- 해시 테이블의 검색 성능을 분석할 수 있도록 한다.

저장/검색의 복잡도

- Array
  - $O(n)$
- Binary search tree
  - 최악의 경우 $\Theta(n)$
  - 평균 $\Theta(\log n)$
- Balanced binary search tree(e.g. red-black tree)
  - 최악의 경우 $\Theta(\log n)$
- B-tree
  - 최악의 경우 $\Theta(\log n)$
  - Balanced binary search tree보다 상수 인자가 작다
- Hash table
  - 평균 $\Theta(1)$

Hash Table

- 원소가 저장될 자리가 원소의 값에 의해 결정되는 자료구조
- 평균 상수 시간에 삽입, 삭제, 검색
- 매우 빠른 응답을 요하는 응용에 유용
  - 예:
    - 119 긴급구조 호출과 호출번호 관련 정보 검색
    - 주민등록 시스템
- Hash table은 최소 원소를 찾는 것과 같은 작업은 지원하지 않는다

주소 계산

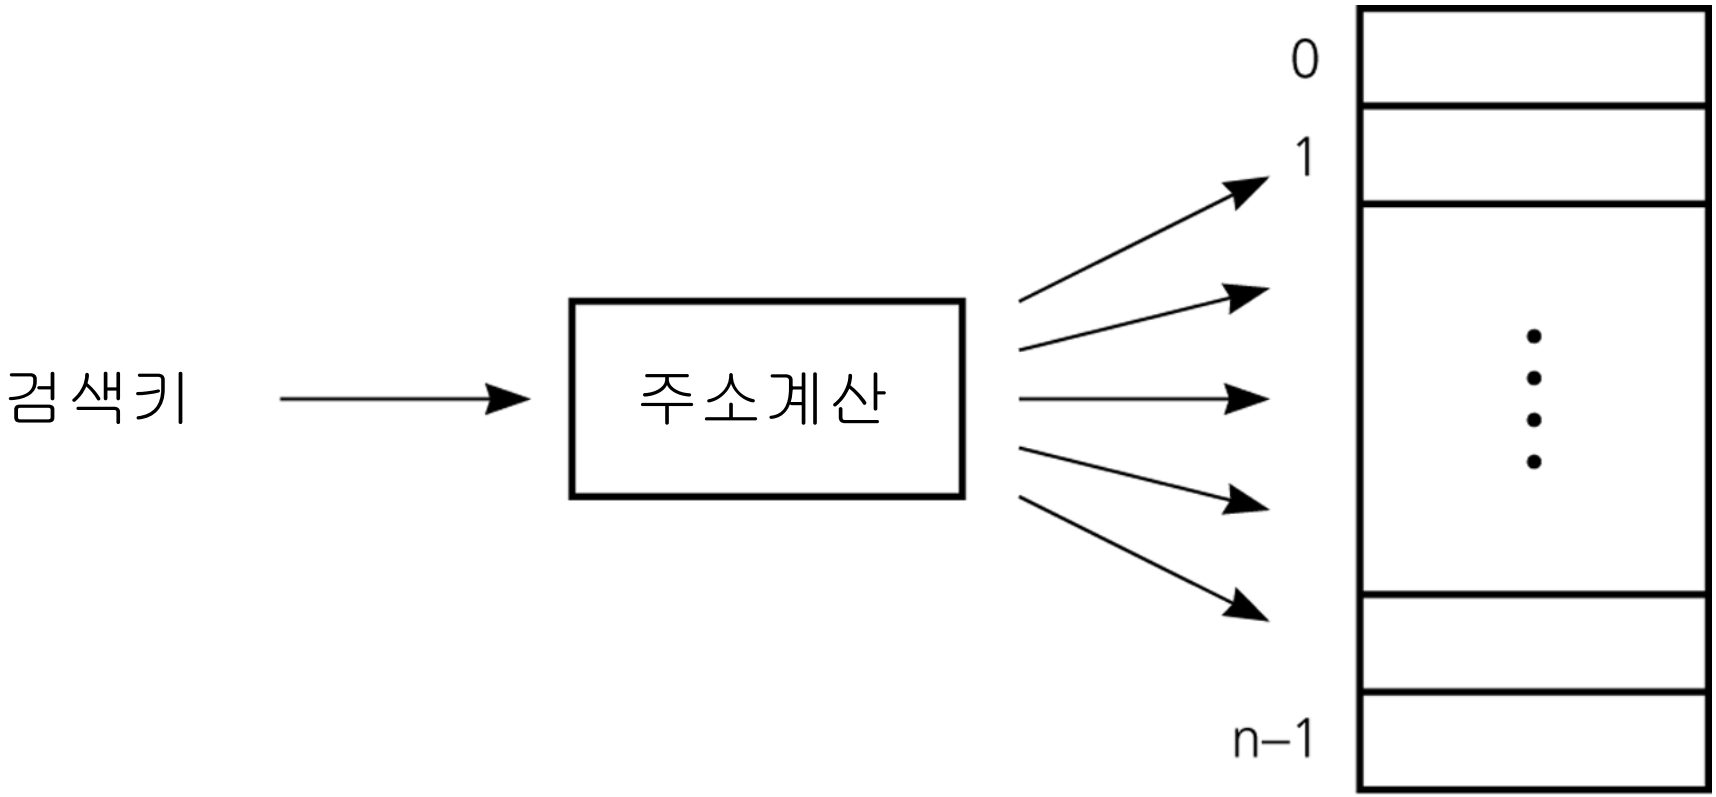

배열 모양의 테이블

크기 13인 Hash Table에 5 개의 원소가 저장된 예

입력: 25, 13, 16, 15, 7

0	13
1	
2	15
3	16
4	
5	
6	
7	7
8	
9	
10	
11	
12	25

Hash function $h(x) = x \bmod 13$

Hash Function

- 입력 원소가 hash table에 고루 저장되어야 한다
- 계산이 간단해야 한다
- 여러가지 방법이 있으나 가장 대표적인 것은 division method와 multiplication method이다

- Division Method
  - $h(x) = x \bmod m$
  - m: table 사이즈. 대개 prime number임.
- Multiplication Method
  - $h(x) = (xA \bmod 1) * m$
  - A: $0 < A < 1$ 인 상수
  - m은 굳이 소수일 필요 없다. 따라서 보통 2^p 으로 잡는다(p는 정수)

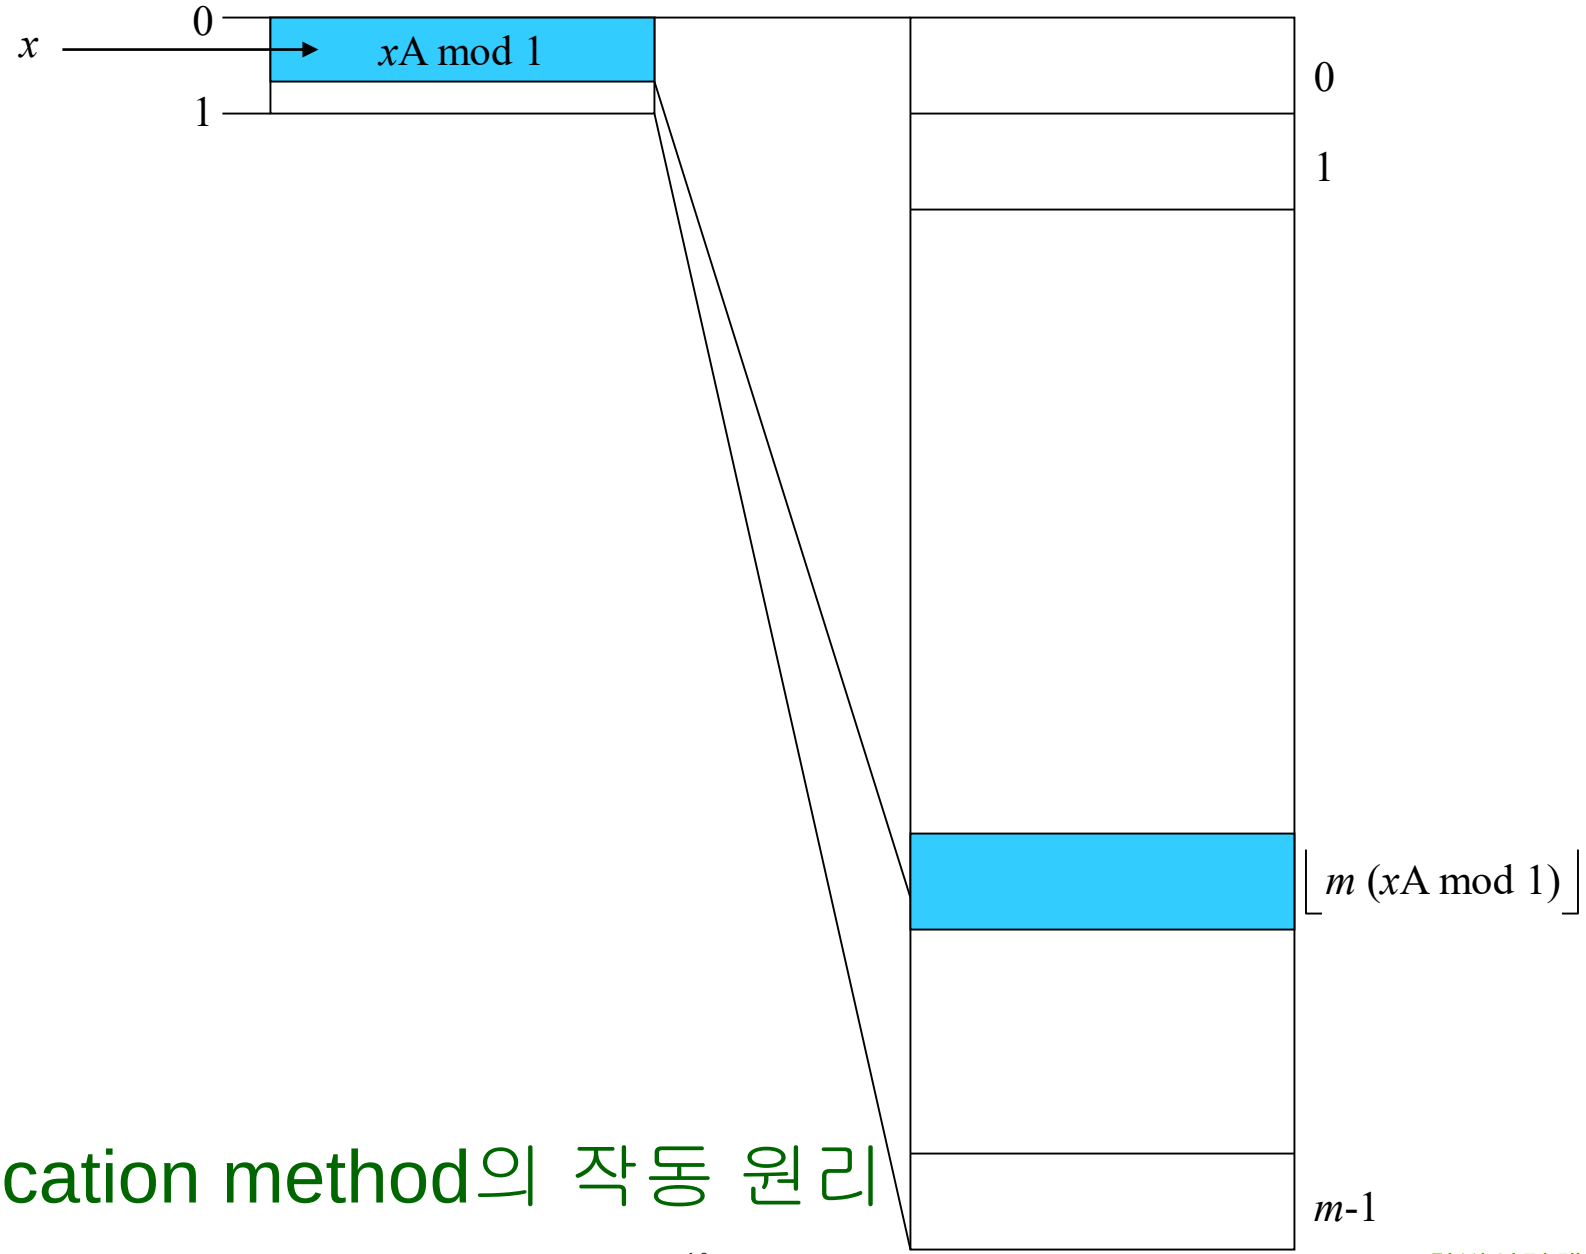

Multiplication method의 작동 원리

Collision

- Hash table의 한 주소를 놓고 두 개 이상의 원소가 자리를 다투는 것
  - Hashing을 해서 삽입하려 하니 이미 다른 원소가 자리를 차지하고 있는 상황
- Collision resolution 방법은 크게 두 가지가 있다
  - Chaining
  - Open Addressing

Collision의 예

입력: 25, 13, 16, 15, 7

0	13
1	
2	15
3	16
4	
5	
6	
7	7
8	
9	
10	
11	
12	25

$h(29) = 29 \bmod 13 = 3$

29를 삽입하려 하자 이미
다른 원소가 차지하고 있다!

Hash function $h(x) = x \bmod 13$

Collision Resolution

- Chaining
  - 같은 주소로 hashing되는 원소를 모두 하나의 linked list로 관리한다
  - 추가적인 linked list 필요
- Open addressing
  - Collision이 일어나더라도 어떻게든 주어진 테이블 공간에서 해결한다
  - 추가적인 공간이 필요하지 않다

Chaining을 이용한 Collision Resolution의 예

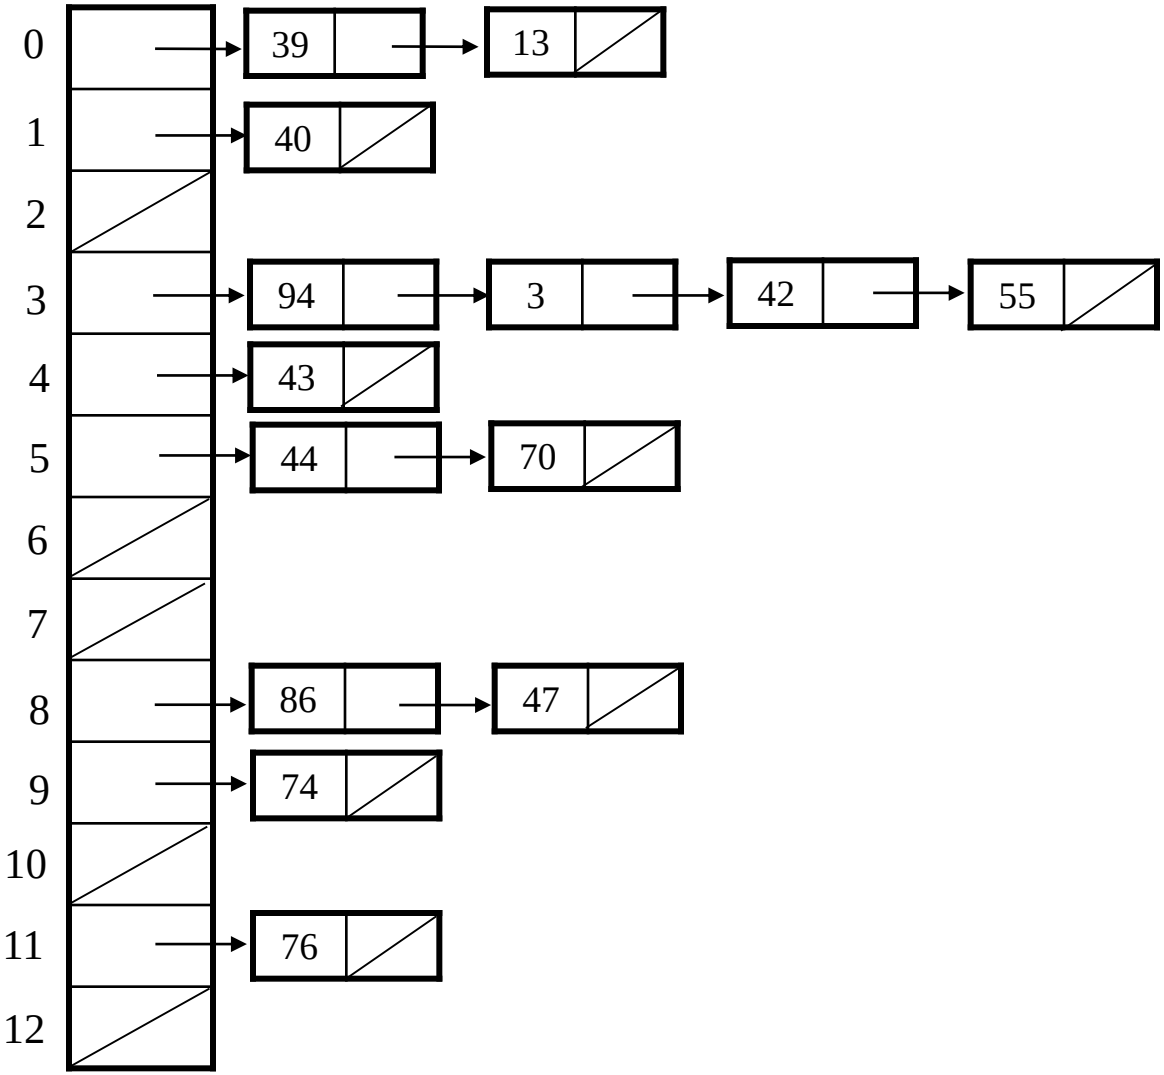

Open Addressing

- 빈 자리가 생길 때까지 해시값을 계속 만들어낸다
  - $h_0(x), h_1(x), h_2(x), h_3(x), \ldots$
- 중요한 세가지 방법
  - Linear probing
  - Quadratic probing
  - Double hashing

Linear Probing

$h_i(x) = (h(x) + i) \bmod m$

예: 입력 순서 25, 13, 16, 15, 7, 28, 31, 20, 1, 38

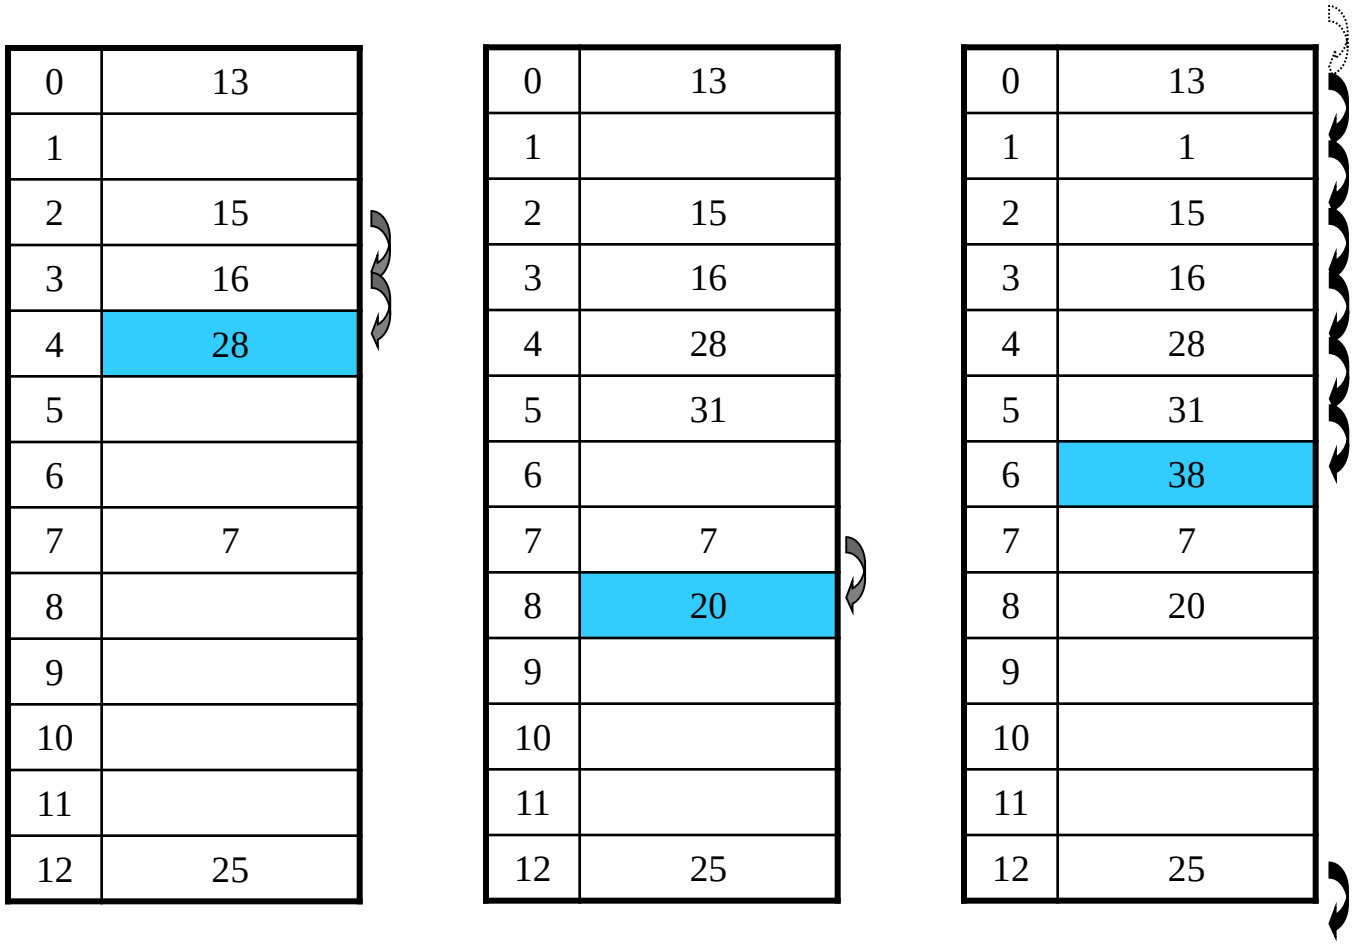

$h_i(x) = (h(x) + i) \bmod 13$

Linear Probing은 Primary Clustering에 취약하다

Primary clustering: 특정 영역에 원소가 몰리는 현상

0	
1	
2	15
3	16
4	28
5	31
6	44
7	
8	
9	
10	
11	37
12	

Primary clustering의 예

Quadratic Probing

$$h_i(x) = (h(x) + c_1 i^2 + c_2 i) \bmod m$$

예: 입력 순서 15, 18, 43, 37, 45, 30

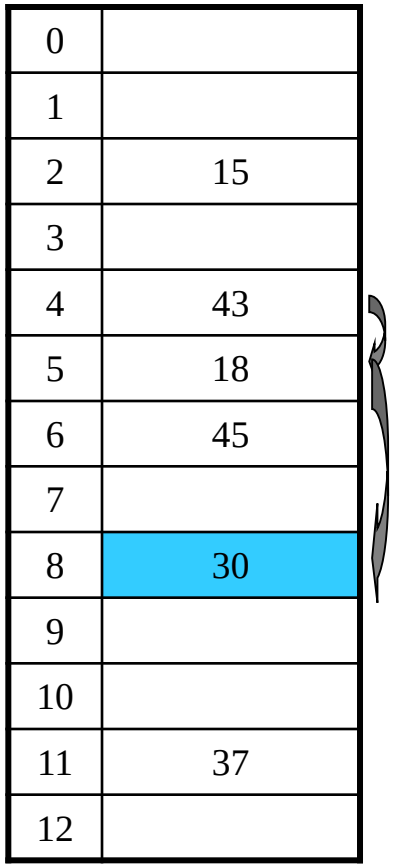

0	
1	
2	15
3	
4	43
5	18
6	45
7	
8	30
9	
10	
11	37
12	

$$h_i(x) = (h(x) + i^2) \bmod 13$$

Quadratic Probing은 Secondary Clustering에 취약하다

Secondary clustering: 여러 개의 원소가 동일한 초기 해시 함수값을 갖는 현상

0	
1	
2	15
3	28
4	
5	54
6	41
7	
8	21
9	
10	
11	67
12	

← Secondary clustering의 예

Double Hashing

$h_i(x) = (h(x) + i\,f(x)) \bmod m$

예: 입력 순서 15, 19, 28, 41, 67

0	
1	
2	15
3	
4	67
5	
6	19
7	
8	
9	28
10	
11	41
12	

$h_0(15) = h_0(28) = h_0(41) = h_0(67) = 2$

$h_1(67) = 3$

$h_1(28) = 8$

$h_1(41) = 10$

$h(x) = x \bmod 13$

$f(x) = (x \bmod 11) + 1$

$h_i(x) = (h(x)+if(x)) \bmod 13$

삭제시 조심할 것

0	13
1	1
2	15
3	16
4	28
5	31
6	38
7	7
8	20
9	
10	
11	
12	25

(a) 원소 1 삭제

0	13
1	
2	15
3	16
4	28
5	31
6	38
7	7
8	20
9	
10	
11	
12	25

(b) 38 검색, 문제발생

0	13
1	DELETED
2	15
3	16
4	28
5	31
6	38
7	7
8	20
9	
10	
11	
12	25

(c) 표식을 해두면 문제없다

Hash Table에서의 검색 시간

- Load factor α
  - Hash table 전체에서 얼마나 원소가 차 있는지를 나타내는 수치
  - Hash table에 n 개의 원소가 저장되어 있다면 $\alpha = n/m$ 이다
- Hash table에서의 검색 효율은 load factor와 밀접한 관련이 있다

Chaning에서의 검색 시간

- 정리 1
  - Chaining을 이용하는 hashing에서 load factor가 α일 때, 실패하는 검색에서 probe 횟수의 기대치는 α이다

- 정리 2
  - Chaining을 이용하는 hashing에서 load factor가 α일 때, 성공하는 검색에서 probe 횟수의 기대치는 $1 + \alpha/2 + \alpha/2n$ 이다

Open Addressing에서의 검색 시간

- Assumption (uniform hashing)
  - Probe 순서 $h_0(x), h_1(x), \ldots, h_{m-1}(x)$가 0부터 m-1 사이의 수로 이루어진 permutation을 이루고, 모든 permutation은 같은 확률로 일어난다
- 정리 3
  - Load factor $\alpha=n/m$ 인 open addressing hashing에서 실패하는 검색에서 probe 횟수의 기대치는 최대 $1/(1-\alpha)$이다
- 정리 4
  - Load factor $\alpha=n/m$ 인 open addressing hashing에서 성공하는 검색에서 probe 횟수의 기대치는 최대 $(1/\alpha)\log(1/(1-\alpha))$ 이다

Load Factor가 우려스럽게 높아지면

- Load factor가 높아지면 일반적으로 hash table의 효율이 떨어진다
- 일반적으로, threshold을 미리 설정해 놓고 load factor가 이에 이르면
  - Hash table의 크기를 두 배로 늘인 다음 hash table에 저장되어 있는 모든 원소를 다시 hashing하여 저장한다

생각해 볼 것

- Load factor가 아주 낮으면 각 조사 방법들이 차이가 많이 나는가?
- 성공적인 검색과 삽입의 관계는?
  - [정리 4]의 증명과도 관계 있음

Thank you