

알고리즘 5장 - 데이터 압축 알고리즘

멀티미디어공학과
조 미 경 교수

RLE(Run-Length Encoding)

- 동일 문자가 연속적으로 나타나면 이를 반복 개수를 줄여서 표현하는 방법

aaaaaefbbbbbbbcdefg



&5aef&6bcdefg

- 반복 개수가 3이상일 때 효과적
- 일반 문서에서 셋 이상 반복되는 문자가 희박
- 화상(image)데이터 압축에는 효과적

Huffman 코딩

- 문자가 텍스트에 나오는 빈도에 따라 다른 길이의 부호를 부여
 - 많이 나타나는 문자에 짧은 부호를 부여하고 드물게 나타나는 문자에는 긴 부호를 부여하여 전체 메시지의 길이를 줄이려는 방법
- 알파벳 Σ 의 각 문자에 대응하는 부호를 코드워드(codeword)라 함

[예제] 'abracadabra'의 코딩 예.

✚ 영문 알파벳 26자. 5비트로 인코딩 → 55비트 필요.

✚ 빈도수

— a => 5번, b => 2번, c와d => 1번, r => 2번

— 코드

a = '0', b = '1', r = '00', c = '01', d = '10'

010000101001000 → 15비트

→ 디코딩 불가

✚ 빈도에 따라 단순히 코드워드를 생성할 때의 문제점

Huffman 코딩





- 모호함이 없는 디코딩 가능하기 위해서는 어떠한 코드워드도 다른 코드워드의 접두부와 일치하지 않아야 함
- 접두부 코드(prefix code)
 - 어떠한 코드워드도 다른 코드워드의 접두부와 일치하지 않는 코드
 - 인코딩된 메시지의 길이가 가장 짧은 최적 코드
- 접두부 불일치 코드(prefix-free code)

허프만 코드

- ✚ 접두부 코드임
- ✚ 허프만 나무를 상향식으로 만들어 코드 부여 함
 - 이진나무
 - 알파벳의 각 문자는 앞에 나타남
 - 노드는 빈도수로 레이블. 좌우의 두 간선은 각각 0과 1로 레이블한다.
 - 레이블이 작은 노드들을 합쳐 부모 노드를 만들어 나가는데 이때 부모 노드는 자식 노드 레이블의 합으로 레이블됨.


허프만 나무

'abracadabra'



허프만 나무

'abracadabra'



허프만 나무는 유일하지 않음

010010101110011101001010

허프만 코드

- 빈도수(또는 확률)를 알아야 코드를 구할 수 있음
 - 모르면 텍스트를 두 번 읽어야 함
- 디코딩은 허프만 나무 구조와 알파벳에 관한 정보가 있어야 가능
 - 최대 $2^{|\Sigma|}-1$ 개 노드
 - 원래 k 비트 코드였다면, 약 $2^{|\Sigma|}+k^{|\Sigma|}$ 비트 정보가 헤더에 공급되어야 함

허프만 나무

- 전이진나무(full binary tree)
- 나무 T 의 비용 $D(T)$

$$D(T) = \sum_{i=1}^n f_i d_T(c_i)$$

$d_T(l)$: 나무 T 에서 잎 l 의 깊이

- 허프만 나무 T 는 $D(T)$ 가 최소인 나무.

허프만 나무 알고리즘

```
Huffman(C, F, n) /* Huffman tree의 생성 */
{
    //입력 : n:알파벳의 크기, C[1..n]:알파벳, F[1..n]:문자 의 빈도
    //출력 : 허프만 나무

    빈도 F[]에 따라 우선순위 큐 Q 생성;
    // 큐의 각 원소는 문자와 빈도의 쌍으로 구성
    for (i=1; i<n ; i+) {
        Q에서 최소값을 삭제하여 이를 u로 함;
        Q에서 최소값을 삭제하여 이를 v로 함;
        새 노드 x를 생성하여 u와 v를 각각 x의 왼쪽, 오른쪽 자식으로 함;
        노드 x의 빈도를 u와 v의 빈도의 합으로 함;
    }
}
```

허프만 나무 알고리즘 정확성

[보조정리] 최적 코드에서 $f_i < f_j$ 이면 $|c_i| \geq |c_j|$ 이다.

[보조정리] 빈도가 가장 낮은 두 코드워드는 마지막 비트는 다르지만 같은 길이가 되도록 하는 최적 접두부 코드가 존재한다.

[보조정리] 알파벳 $S = \{a_1, a_2, \dots, a_n\}$ 와 각 a_i 에 대응하는 빈도 f_{a_i} 에 대한 최적 접두부 코드를 나타낸 전 이진 나무를 T 라고 하자. T 의 잎이면서 동기로 나타나는 두 노드 u, v 의 문자가 x, y 라고 하자. z 를 u 와 v 의 부모 노드 w 의 문자라고 하고, $f_z = f_x + f_y$ 라고 하면, $T' = T - \{u, v\}$ 는 알파벳 $S' = (S - \{x, y\}) \cup \{z\}$ 에 대한 최적 접두부 코드를 나타내는 나무이다.

동적 허프만 코딩

- adaptive Huffman coding 이라고도 한다
- 문자의 빈도수를 만들어나가면서 코딩을 하는 방법. 텍스트를 한 번만 읽으면 된다
- 빈 나무에서 시작해서 텍스트의 문자를 하나씩 읽어 들이면서 Huffman 나무를 만듦과 동시에 인코딩/디코딩을 행한다

동적 허프만 인코딩

✚ '\$'를 텍스트에 나타나지 않는 문자라고 가정. '\$'의 빈도는 0.

Adaptive_Huffman(Text) {

// 입력 : Text - 텍스트

// 출력 : 압축된 기호, 처리 과정에서 허프만 나무 T를 만듦

빈도는 0이고 이름은 \$인 한 노드로 구성된 초기 나무 T를 생성;

while (Text의 끝이 아님) {

 x = Text의 다음 문자;

 if (x가 T에 이미 있던 문자) {

 T에서 x에 부여된 코드워드 출력;

 x의 빈도를 하나 증가;

 }

 else {

 \$의 현재 코드워드와 x의 기호 출력;

 x를 빈도 1로 하여 T에 삽입;

 }


 ADJUST(T);

}

}

동적 인코딩 과정


[예제] 텍스트가 'abcdabedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?




(a) 초기 상태

동적 인코딩 과정

[예제] 텍스트가 'abcdabedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?





(a) 초기 상태




(b) a 입력. 출력 : 00001

동적 인코딩 과정


[예제] 텍스트가 'a**b**cdabedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?




[예제] 텍스트가 'ab**c**dabedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?




(c) b 입력. 출력 : 000010



(d) c 입력. 출력 : 0000011






[예제] 텍스트가 'abcdabedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?




(e) d 입력. 출력 : 10000100

[예제] 텍스트가 'abcd**a**bedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?





(f) a 입력. 출력 : 10

[예제] 텍스트가 'abcdabedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?




(g) b 입력. 출력 : 10

[예제] 텍스트가 'abcdabedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?




(h) e 삽입. 출력 : 00000101

[예제] 텍스트가 'abcdabedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?




(i) d 입력. 출력 : 011

[예제] 텍스트가 'abcdabedbad'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?




(j) b 입력. 출력 : 10

[예제] 텍스트가 'abcdabedb**a**d'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?



(k) a 입력. 출력: 10

[예제] 텍스트가 'abcdabedba**d**'라고 하자. a, b, c, d, e의 원래 코드는 각각 5비트 코드로서 00001, 00010, 00011, 00100, 00101라고 하자. 동적 인코딩 과정?



(I) d 입력. 출력 : 00