

한글 Graphic Image Data의 統計的 特性에 관한 研究 (A Study on the Statistical Characteristics of Hangul Graphic Image Data)

金 在 錫*, 金 在 均**
(Kim, Jae-Seok and Kim, Jae-Kyoon)

要 約

Graphic image data의 効率的인 coding을 위해서, 한글 image와 英文 image의 統計的인 特性들이 测定 比較되었다. 또한 Markov model에 의한 run length의 確率分布와 测定된 run length의 確率分 布가 比較 檢討되었다.

測定된 run length 分布는 negative-power 分布에 近似하며, 이것은 한글 image에서 더욱 뚜렷한 것으로 나타났다.

代表的 네 가지 run length code의 coding 特性가 比較되었는데, 英文 image보다 한글 image의 coding 特性가 더욱 우수한 것으로 밝혀졌다.

Abstract

For efficient coding of graphic image data, the statistical characteristics for both Korean lettered images and English lettered images are measured and compared.

Also, the measured run length distribution is compared with the run length distribution based on Markov model.

It is shown that the measured white run length distribution is more like a negative-power distribution than an exponential distribution. This fact is stronger in the Korean lettered images than in the English lettered images. The performances of four typical run length codes are compared for the same set of graphic data files, and it is shown that the codes perform better in the Korean lettered images than in English lettered images.

1. 序 論

Facsimile로서 傳送되는 書類, 圖面등의 graphic image data는 그 data量이 방대하여 일반적으로 傳送時間이 길다. data量을 減縮하여 이 傳送時

間을 줄이기 위해서는 image data의 統計的 特性이 이해되어야 한다. 英文 image의 경우에는 黑色 pel (picture element)과 白色 pel의 run length 確率分布등 여러 特性들이 测定되어 왔으며 이 資料에 근거하여 効率的인 coding 方法들이 제시되어 왔다.

일자기 연속적인 image data는 first-order Markov source로 假定되어 run length 分布가 exponential 分布를 갖는 것으로 이해되었다.^[1] 그러나 英文 image에 있어서 white run length의 실제 分布는 특히 run length가 긴 경우 exponential 分布

* 正會員, 韓國電子技術研究所
(Korea Institute of Electronics Technology)

** 正會員, 韓國科學院 電氣 및 電子工學科
(Korea Advanced Institute of Science)

接受日字; 1979年 11月 29日

와는 상당한 차이가 있는 것으로 나타났다.

일반적으로 run length分布를 알고 있을 때構成할 수 있는 가장 optimal한 code는 Huffman code이지만構成하기가 비교적 복잡해서, 대체로 조직적인 suboptimal code들을 실제로 많이 사용하고 있다.^[2] 그러나 한글 image에 대해서는 그特性을測定하지 않고 英文 image에 의해 얻어진 결과들이 그대로 이용되었다.^[3]

본 연구에서는英文 image data와 함께 한글 image data의 여러特性들을 测定하여 그結果를 比較検討함으로써, 한글 image data의 効率적인 coding方法에 울바른 資料를 얻고자 한다. 실험에 사용한 image data source로서는 한글 타자문 인쇄文 등 12종, 英語 타자文 인쇄文 14종, 기타 圖面등 4종으로 총 30종의 data source를 選擇하였다. 이들 data source는 CCD scanner로서 digitize되었으며, 그解像度는 水平方向으로 5 pel/mm, 垂直方向으로 3.3 line/mm이 다

각 data file의 run length 確率分布 white pel 的 比率, 평균 run length, pel 당 entropy 등이 测定되었고, image data에 대한 first-order Markov model의妥當性이 檢討되었다. 또한 代表的인 4 종의 code에 대한 simulation結果를 测定比較함으로써 실제 image data에 대해 有用한 code選別의 資料를 제시하였다.

2. Markov model

어느 한 画面을 scanning 할 때 한 line 상에서 연속적으로 나타나는 pel 사이에는 統計的인 相關係가 존재하는데,[²⁾] J.Capon은 이 연속적인 image data를 first-order Markov source로 modeling 함으로써 run length의 exponential 確率分布의 特性을 제시하였다.[¹⁾] First-order Markov model이란 한 scan line 상에서 어느 한 pel의 現 狀態는 바로 앞에서 나타난 한 pel의 狀態에만 依存한다고 假定한 것이다.

이 때 각 run length들은 서로 獨立的이라는 假定이
이에 포함되어 있다. 이 model을 假定할 경우에는
image data의 모든 統計的인 情報를 평균 run len-
gth 만의 函數로 표시할 수 있다. [4]

바로 이전의 p_e 가 white 일때 현재 p_e 가 black 일 확률을 $P(b|w)$ 와 같이 표시하면, white run length R_w 가 x 가 될 확률 $P(R_w=x)$ 은 다음과 같이 쓸 수 있다.

$$P(R_w = x) = P(w|w)^{x-1} \cdot P(b|w), \quad x \geq 1 \dots \dots (1)$$

그러므로 white run의 평균 run length가 tran-

sition probability의 逆數로 표시됨을 알 수 있다.^[5]

$$E(R_w) = \sum_{x=1}^{\infty} x \cdot P[R_w = x] = \frac{1}{P(b|w)} \quad \dots \dots \dots (2)$$

(2) 식과 $P(wlw) = 1 - P(blw)$ 의 관계식을 이용하면
 (1) 식의 white run length 分布가 평균 run length
 만의 函數로 표시될 수 있다.

$$P[R_w = x] = [1 - P(b|w)]^{x-1} \cdot P(b|w)$$

$$= [1 - \frac{1}{E(R_w)}]^{x-1} \cdot \frac{1}{E(R_w)} \quad \dots \dots (3)$$

이 식은 run length 가 exponential 하게 감소하는 分布임을 말해 주고 있다.

마찬가지로 pel 당 entropy 값도 평균 run length 만의
함수로 표시할 수 있다.

$$h(R_w) \triangleq \frac{H(R_w)}{E(R_w)} = \frac{1}{E(R_w)} \cdot \left(-\sum_{x=1}^{\infty} P(R_w=x) \cdot \log [P(R_w=x)] \right) = \frac{1}{E(R_w)} \cdot \{ E(R_w) - \log_2 E(R_w) - [E(R_w) - 1] \cdot \log_2 [E(R_w) - 1] \}$$

.....(4)

J. Capon 이 model 을 제시한 이후 有用하게 사용되어 왔으나, 그후 實驗的으로 英文 image의 white run 은 exponential 分布* 보다는 negative power 分布**에 가깝다는 것이 判明되었다.^[2]

$$* P(L) = b \cdot a^{-L} \text{ (단 } a, b \text{ 는 상수)}$$

$$** P(L) = a \cdot \left(\frac{1}{1-b}\right)^b \quad (\text{단 } a, b \text{는 상수})$$

3. 確率測定 及 考察

確率測定에는 30 종의 한글, 英文, 圖面들이 사용되었으나, 다음의 代表의 7종에 대한 测定結果가 표 1로 표시되었다.

- a) 英文 typewritten text
 b) 한글 " "
 c) 英文 printed text
 d) 한글 " "
 e) 英文 handwritten text
 f) 한글 " "
 g) line drawing (圖面) 등

이들 7종의 data source는 그림 1과 같다. 이 data source는 facsimile system의 scanner 부분을 利用하여 digitize 되었다. image sensor 또는 최신 반도체 소자인 CCD가 사용되었는데 그 解像度는 1024

한글 Graphic Image Data 의 統計的 特性에 관한 研究

dundancy가 8% 이내의 값을 갖는다. 이것은 L_N -code 가 first-order Markov source에 대해서 거의 optimal한 特性을 가짐을 말해 준다.

그런데 Hasler code(H_N -code)에 대한 실제 image data의 redundancy 값이 英文의 경우 平均 33%, 한글의 경우 平均 31%가 되는 것으로 나타났다.

표 1. 측정된 image data의 특성

Table 1. Characteristics for some typical image data.

File No.	Number of runs		Probability (%)		Mean run length		entropy/pel (bit/pel)		Remarks
	N_w	N_B	$P(w)$	$p(B)$	$E(w)$	$E(B)$	$h(w)$	$h(B)$	
1	7,657	7,019	0.937	0.063	43.80	3.21	0.0945	0.8683	English typewritten
2	4,541	3,899	0.956	0.044	75.36	4.03	0.0625	0.7477	Korean "
3	11,031	10,408	0.910	0.090	29.52	3.09	0.1469	0.8817	English printing
4	8,012	7,321	0.927	0.073	41.42	3.56	0.1187	0.8203	Korean "
5	4,941	4,261	0.961	0.039	69.61	3.27	0.0773	0.8189	English handwritten
6	6,957	6,279	0.946	0.054	48.64	3.10	0.1034	0.8624	Korean "
7	4,564	3,881	0.967	0.033	75.82	3.05	0.0738	0.8510	line drawing

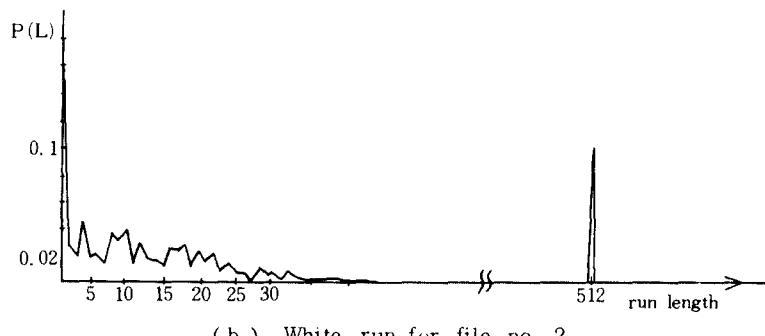
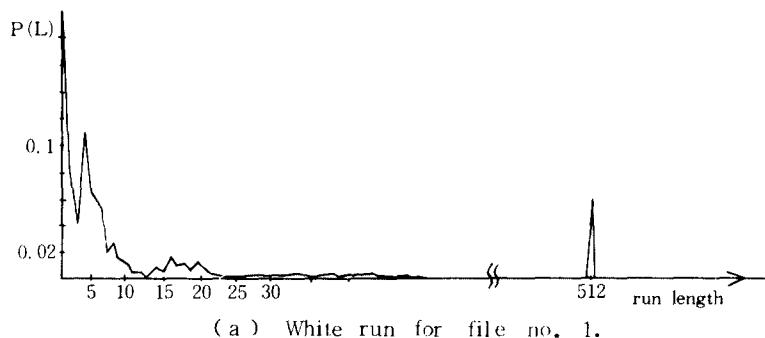


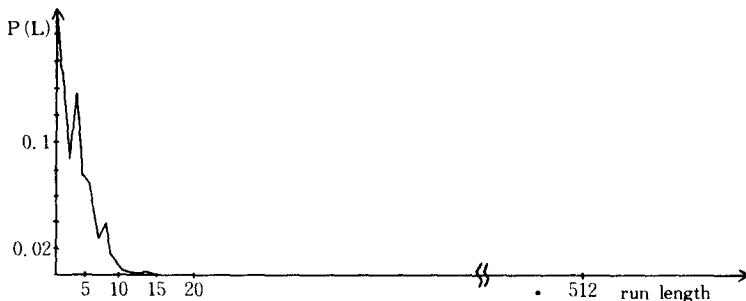
그림 2. White run length의 확률분포도

Fig. 2. Probability distribution of white run length.

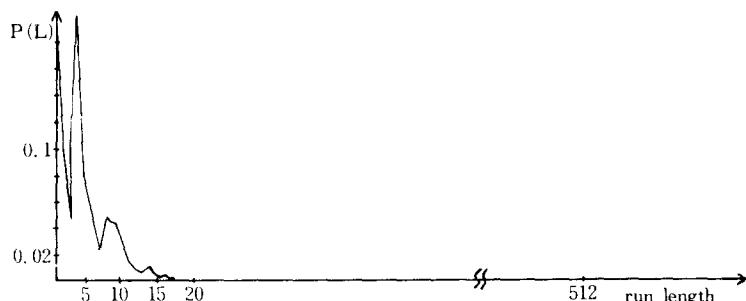
그러나 실제 image data의 white run은 L_N -code에 대한 그 redundancy 값이 英文의 경우 70~115%, 한글의 경우 73~106%나 되어, white run에 대해서는 한글과 英文 image 모두가 Markov model의 適用이 適合하지 않음을 보여 주고 있다.

이것은 한글과 英文 image의 white run length 分布가 그 分布의 모습은 서로 다르지만 exponential 分布보다는 negative-power 分布에 더 가깝다는 것을 말해 주고 있다.

그러나 black run의 경우에는 그 redundancy 값이



(a) Black run for file no. 1.



(b) Black run for file no. 2.

그림 3. Black run length의 확률분포도

Fig. 3. Probability distribution of black run length.

표 2. Laemmle code에 대한 redundancy 값

Table 2. Redundancy values for Laemmle code.

file No.	White run		Black run		Remarks
	Markov source	meas- ured image	Mar- kov source	meas- ured image	
1	7.6(%)	115(%)	3.3(%)	10.2(%)	English typewritten
2	7.8	105	6.5	18.7	Korean "
3	7.5	83	3.2	10.7	English printing
4	7.9	73	4.4	13.3	Korean "
5	8.2	70	3.5	19.2	English handwritten
6	6.9	74	3.2	13.6	Korean "
7	7.9	57	3.2	16.7	line drawing

英文의 경우 10.2 ~ 19.2 %, 한글의 경우 13.3 ~ 18.7 %의 값을 갖기 때문에, black run에 대해서는 Markov model의 적용이 매우妥當함을 보여 주고 있다. 이것은 한글과英文 image의 black run이 exponential 分布에 近似한 分布를 가짐을 말해 준다.

그러나 실제로는 white와 black run을 区分하지 않고, white run에 optimal 한 code로 같이 coding 하여 사용하는 경우가 많다. 이럴 때에는 white run의 特性이 크게 작용함으로, image data를 Markov model로 假定하는 것은 한글과 英文 image 모두에게 있어서 適合하지 않다고 하겠다.

4. Run length code의 特性比較

본 章에서는 앞 章에서 测定된 image data의 여러 特性들을 사용하여, 代表의 네 가지 기존 run length code의 coding 特性를 比較하였다.

選擇된 네 가지 code는 modified-white block skipping cod.^[6] (M-WBS code), linear code의 일 종인 Laemmle code (L_N -code), logarithmic code의 일 종인 Hasler code (H_N -code), 그리고 Truncated-Huffman code^[7]이다.

각 image data를 選擇된 네 가지 code로 coding했을 경우, 우리가 얻을 수 있는 최소의 bit rate Q_{\min} . 과 그때의 optimum coding block size N_{opt} . 을 computer simulation으로 测定한結果가 표 3과 같다. 여기서 N_{opt} .은 block run과 white run에 同

표 3. 네 가지 code에 대한 minimum bit rate (Q_{\min})와 optimum block size(N_{opt}).
Table 3. Minimum bit rate and optimum block size for 4 different codes.

file No.	experimental entropy	modified WBS code		L_N -code		H_N -code		Truncated Huffman code
		entropy	Q_{\min}	N_{opt}	Q_{\min}	N_{opt}	Q_{\min}	
1	0.1433	0.233	5	0.321	6	0.172	1	0.1698
2	0.0925	0.164	6	0.209	7	0.123	1	0.1104
3	0.2130	0.338	5	0.415	5	0.241	1	0.2294
4	0.1697	0.303	6	0.321	6	0.198	1	0.1852
5	0.1062	0.212	8	0.218	7	0.134	1	0.1264
6	0.1447	0.261	7	0.289	6	0.174	1	0.1634
7	0.0995	0.239	9	0.193	7	0.133	1	0.1288

一한 code를 適用한 경우의 optimum block size이다.

표 3에 보면 한글과 英文 image 모두에서 Truncated-Huffman code가 가장 우수하고, 그 다음이 H_N -code(그중 H_1 -code), M-WBS code, L_N -code(그 중 L_6 -code) 順으로 bit rate가 증가하고 있다. 그러나 all-white line이 별로 없는 line drawing image에 대해서는 M-WBS code보다 L_N -code가 더 좋은特性을 나타내고 있다.

또한 한글과 英文 file에 관계없이 H_N -code와 L_N -code의 평균 optimum block size는 각각 1과 6임을 알 수 있다.

표 3의 각 code로 부터 얻을 수 있는 data 壓縮比의 平均值을 정리하면 표 4와 같다.

표 4. 각 code의 reduction factor의 평균치
Table 4. Average values of reduction factor in 4 different codes.

File	M WBS code	L_6 -code	H_1 -code	Truncated Huffman code
English	3.92	3.18	5.40	5.70
Korean	4.43	3.70	6.03	6.52
Line drawing	3.23	3.81	5.54	5.67

표 4로부터 H_1 -code가 Truncated-Huffman code에 매우 가까운 우수한 壓縮比를 가지며, 같은 code에 있어서도 英文 image 보다 한글 image에서 조금

더 큰 壓縮比를 얻을 수 있음을 알 수 있다.

특히 file #1(英文 image)과 file #2(한글 image)에서 block size의變化에 따른 각 code의 bit rate變化는 그림 4, 그림 5와 같다. 이 그림에서 보

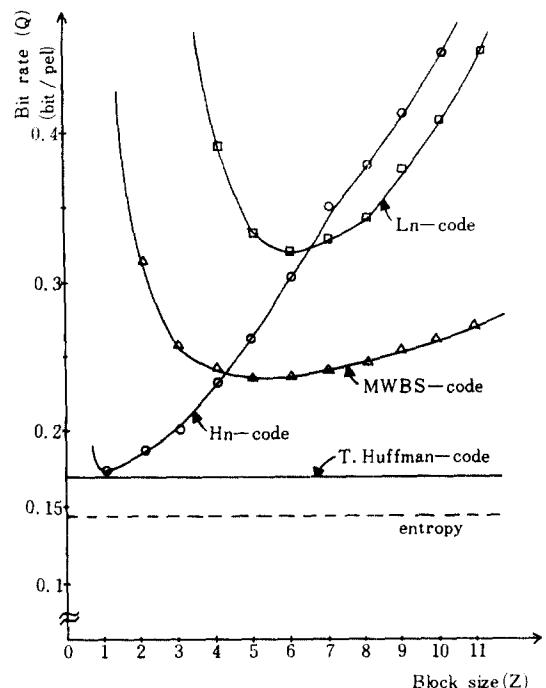


그림 4. 영문 image에 대해 block size에 따른 bit rate 변화

Fig. 4. Bit rate variation by the block size for English typewritten text.

면 한글 image 가 英文 image에 비해 block size의 變化에 덜 민감한 특징을 찾고 있음을 알 수 있다.

각 code의 効率性을 알아보기 위해, optimum block size 때 각 code의 redundancy를 평균한結果, Truncated-Huffman code가 0.2, H_1 -code는 0.3, M-WBS code는 0.8, 그리고 L_6 -code는 0.8 정도인 것으로 나타났다.

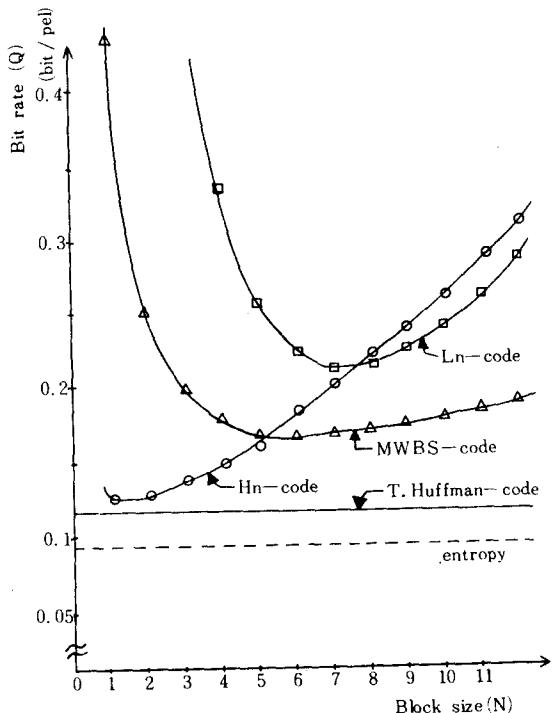


그림 5. 한글 image에 대해 block size에 따른 bit rate 변화

Fig. 5. Bit rate variation by the block size for Korean typewritten text.

5. 結論

한글과 英文 image data의 統計的 特性들이 測定比較되었다. run length의 確率分布는 대체로 비슷하지만, white run에서는 한글 image가 英文 image보다 negative-power distribution의 性向이 좀 더 강함을 알 수 있었다. 그러나 한글과 英文 image 모두 그

run length distribution가 Markov model에 의한 exponential distribution과는 상당한 차이가 있음이 확인되었다.

네 가지 run length code에 대한 여러가지 coding特性을 比較한結果, 같은 code로서도 英文 image에서 보다 한글 image에서 data 壓縮比가 더욱 크며, code block size에 덜 민감한 사실을 볼 수 있었다. 이런 사실들은 英文 image의 特性을 調査研究하여 얻어진 여러 coding 方法들이, 한글 image에 대해서는 오히려 더 効率의 임을 말해 주고 있다. 그러므로 英文 image에 의해 얻어진結果들이 한글 image에 그대로 사용되어도 무방하다고 할 수 있다. 그러나 한글 image가 갖는 特性을 최대한 살리기 위해서는 한글 image에 적합한 coding method이 새로이研究開發되어야 할 것이다.

比較된 code 중에서는 Truncated-Huffman code와 Hasler code(H_1 -code)의 성능이 우수했다.

参考文獻

1. J. Capon "A probabilistic model for run length coding of pictures", IRE Trans. vol. IT-5, pp. 157~163, Dec. 1959.
2. H. Meyr, H. G. Rosdolsky and T. S. Huang "Optimum run length codes", IEEE Trans., vol. Com-22, No. 6, pp. 826~835, June 1974.
3. 한국과학원, "전화 통신망을 이용한 FAX system의 研究開發", July 1978.
4. T. S. Huang "Coding of two-tone images", IEEE Trans. vol Com-25, No. 11, pp. 1406~1424, Nov. 1977.
5. Kie-Bum Eom "A study on run length codes -comparison and implementation", M.S. thesis, KAIS, Feb. 1978.
6. T. S. Huang and Shahid Hussain "Facsimile coding by skipping white", IEEE Trans. vol. Com-23, No. 12, pp. 1452~1460, Dec. 1975.
7. H. G. Musmann and Dieter Preuss "Comparison of redundancy reducing codes for facsimile transmission of documents", IEEE Trans. vol. Com-25, No. 11, pp. 1425~1433, Nov. 1977.