〈経営研究　第17巻　第1号　平成15年12月〉

# 英書25冊の第43次エントロピー計算

横　井　右　門

## キーワード

エントロピー（平均情報量）　entropy
冗長度　redundancy
記号　symbols
擬似コード　pseudo code

## 1. はじめに

1957年，ソ連のヤグロム兄弟は「情報理論入門」で，まず次のように述べている。(1)「また他の国語についても，同じように計算できる。たとえば，ラテン文字のアルファベットには，全部で26コの文字がある。したがって，ラテン文字のアルファベットで書かれた文章の文字に含まれる最大の情報 $\varepsilon_0$ は，10進単位で log26 ≒ 1.415 である。さらに，いろいろな国語で，それぞれの文字が現われる相対頻度を計算すると，一つの文字に含まれる平均情報量 $\varepsilon_1$ は，英文では1.242（10進）単位，仏文では1.200，独文では1.233になる。これらの値はみな，1.415より小さいことがわかる。国語によって，それぞれの文字の現われる頻度はちがうから，$\varepsilon_1$ の値は少しずつちがっている。」

さらに次のように述べている。(2)

「シャノンは，二つ及び三つの文字のいろいろな組合せの相対頻度の表を作って，英語での $\varepsilon_2$ と $\varepsilon_3$ を計算し，10 進単位で $\varepsilon_2 = 1.075$，$\varepsilon_3 = 0.993$ であることがわかった。（前に述べたように，英語では個個の文字を独立と考えて，それぞれの文字の相対頻度だけを使って計算すれば，一つの文字に含まれる報情（ママ）は $\varepsilon_1 = 1.242$ 単位であった。さらに，英文に現われるいろいろな単語の頻度に関する統計資料を使って，シャノンは近似計算で，$\varepsilon_8$（つまり，すぐ前にある 7 コの文字がわかつたものとして，文章の文字一つあたりに分配される情報）がほぼ，0.6 単位になることを示した。なお文章でいろいろな単語がどのようにつづいて配列されねばならないかという規則（collocation）をしらべたり，多くの単語の組合せを統計的にくわしく計算したりすると，みかけ上，情報ははるかに減るように思われるが，実際には 0.6 より大して減らない。

このように意味がある文章の文字一つあたりに平均的に分配される情報は，アルファベットの文字に含まれている最大情報の半分以下になってしまうことがわかる。（英語では，$\varepsilon_0 = \log 26 \fallingdotseq 1.415$ 単位で，$\varepsilon_8 = 0.6$ 単位である）。ある国語で，意味をもっている文章の一つの文字に平均的に分配される情報とアルファベットの文字に関する最大の情報量との比を 1 から引いたもの（つまり，式では，$1-\frac{\varepsilon_\infty}{\varepsilon_0}=1-\frac{\varepsilon_\infty}{\log n}$）をシャノン流に，その国語の冗長度と名づければ，よく普及しているヨーロッパの言語の冗長度は，50%（或いはそれ以上）である。いいかえれば，通常のどんな文章でも，50%以上の文字は，言語構造そのものによって，いつも必然的に決ってしまう。」

このヤグロムの記述で「単位」で終わっている数値は，常用対数による表現であり，これらを 2 進単位の対数に変換すれば，後述するバーナードのエントロピー計算値にすべて合致してしまう。何故，常用対数にしたのか，バーナードの計算をシャノンの計算としたのか不可解である。

堀は次のように述べている。[(3)]

「何しろ，前にみたように，文字のつながり方の制約は，三つや四つどころでなく，もっともっと長い文字の連鎖まで及ぶことが明らかなのだから。た

ぶん，少なくとも十四か十五の相つづく文字の列のすべての可能なものを数えあげ，それらの頻度分布をしらべてエントロピーを計算しなければ，実際の値に近い値は求まらないだろう。しかしそれは大変な仕事で，まだ誰もやっていない。ある人が英語の中に出てくる相つづく八つの文字の出現頻度をしらべてエントロピーを計算したのが今までの最高記録である。その値は二・三五であったが，実際はこれよりもっともっと小さいだろう。あとは大ざっぱに見当をつけるほかないのだが，まず一・三ぐらいだろうというのが，今のところの定説になっている」

この二・三五というのもバーナードの計算である。ヤグロムにしても，堀にしてもバーナードの計算に頼っている。

そこで改めて相つづく43字までの出現頻度からエントロピーを計算し直すというのが本稿の目的である。

## 2. バーナードのエントロピー計算

南はG.A.Barnardが1955年にStatistical Calculation of Word Entropies for Four European Languages, IRE Trans-IT-1において次のように計算値を発表していると紹介している。(4)

| | 英語 | 仏語 | 独語 | スペイン語 |
|---|---|---|---|---|
| 1次 | 4.124 | 3.98 | 4.10 | 4.015 |
| 2次 | 3.56 | | | |
| 3次 | 3.3 | | | |
| 8次 | 2.35 | | | |

ヤグロムの1.242, 1.200, 1.233を2進単位の対数に換算すると4.126, 3.986, 4.096となり，バーナードの1次エントロピーに極めて近い値になる。ヤグロムがシャノンの計算としている1.076, 0.993は2進単位に換算すると3.574, 3.299になる。20インチ計算尺の視読誤差の範囲に収まる。ヤグロムは$\varepsilon$ 8が0.6単位であるとしているが，2進単位の2.35を10進単位に換算すると

0.707 になるが，小数部第一位で植字の段階で間違えて，0.6 になったと想像することは可能である。

バーナードの計算は藤田も引用している。[5]

南が積極的にバーナードの名前を出している姿勢は高く評価しなければならない。

## 3. エントロピー

計算するのは熱力学のエントロピーではなく，情報理論のエントロピーである。単位はビット数である。熱力学のエントロピーの単位がビット数であるわけがない。

前川によればエントロピーの定義はつぎのとおりである。[6]

「言語が n 個の記号（番号 1 から n で区別する）で表現され，それぞれの出現確率が

P(n) であるとき，つぎの式で定義される。

$$\text{エントロピー}=\sum_{i=1}^{n} P(i)\log_2 P(i)$$

ただし，この値は負になるので，符号を逆転させる。このエントロピーが重要なのは，この値は実は，分析の対象である言語において，1 つの記号を送るのに必要な平均ビット数を表わしているからである。」

シャノンはアルファベットとスペースを使ったから，英語の 1 次エントロピーの計算では 27 個の記号を使ったことになる。英語の 2 次エントロピーを計算するためには $27^2$ すなわち 729 個の記号を使えばよい。英語の 3 次エントロピーを計算するためには $27^3$ すなわち 19,683 個の記号を使うことになる。16 次エントロピーは $27^{16}$ 個の記号を使うことになる。

しかし後述するデータの 2 番目 The Hunt for Red October について言えば

実際に発生した2連字は論理的に可能な729に対し609個である。3連字の論理的可能性は19,683個であるが，実際に発生するのは5,877個である。29パーセントにすぎない。配列を使って計算するのは資源の無駄遣いである。それよりはn次エントロピーを計算するときn字の文字列レコードをsortし(整列させ)たほうが得策である。

## 4. データ

次の25冊である。全て手作業入力でテキスト・データにしてある。

1. イギリス伝承童謡 : Who Killed Cock Robin
2. Tom Clancy: The Hunt for Red October, Harper Collins, 1993
3. Tom Clancy: OP Center, Berkley Novels, 1995
4. Tom Clancy: Without Remorse, Berkley Novels, 1993
5. Frederick Forsyth: The Day of Jackal, Bantam Books, 1993
6. Frederick Forsyth: The Dogs of War, Bantam Books, 1995
7. Frederick Forsyth: The Odessa File, Bantam Books, 1993
8. Frederick Forsyth: The Shepherd, Corgi Books, 1990
9. Jostein Gaarder: Sophie's World, Berkley Books, 1996
10. Akira Kohchi: Why I survived A-Bomb,
    Institute for Historical Review, 1989
11. Anne McCaffrey: The Crystal Singer, Corgi Books, 1991
12. Anne McCaffrey: Crystal Line, Del Rey Books, 1992
13. Robert B. Parker: A Catskill Eagle, Dell, 1985
14. Robert B. Parker: Pastime, Berkley Novel, 1992
15. Robert B. Parker: God Save the Child, Penguin Books, 1997
16. Robert B. Parker: The Godwulf Manuscript, Dell, 1987
17. A. J. Quinnell: Man on Fire, Orion, 1994
18. A. J. Quinnell: In the Name of the Father, Signet, 1987

19. A. J. Quinnell: The Blue Ring, Orion, 1994
20. A. J. Quinnell: Message from Hell, Orion, 1996
21. H. G. Wells: A Short History of the World, Collins, 1953
22. J. K. Rowling: Harry Potter and the Sorcerer's Stone,
Bloomsbury Publishing Plc, 1997
23. C. S. Lewis: Prince Caspian, Collins, 1980
24. Yoshimoto Banana: N.P., Grove Press, 1994
25. Arthur C. Clarke: A Space Odyssey, A ROC Book, 1968

後で必要になるので一番目のデータの全文を次に紹介しておく。

Who killed Cock Robin?
I, said the Sparrow,
With my bow and arrow,
I killed Cock Robin.

Who saw him die?
I, said the Fly,
With my little eye,
I saw him die.

Who caught his blood?
I, said the Fish,
With my little dish,
I caught his blood.

Who'll make the shroud?
I, said the Beetle,
With my thread and needle,

I'll make the shroud.

Who'll dig his grave?
I, said the Owl,
With my pick and shovel,
I'll dig his grave.

Who'll be the parson?
I, said the Rook,
With my little book,
I'll be the parson.

Who'll be the clerk?
I, said the Lark,
If it's not int the dark,
I'll be the clerk.

Who'll carry the link?
I, said the Linnet,
I'll fetch it in a minute,
I'll carry the link.

Who'll be chief mourner?
I, said the Dove,
I mourn for my love,
I'll be chief mourner.

Who'll carry the coffin?

I, said the Kite,
If it's not through the night,
I'll carry the coffin.

Who'll bear the pall?
We, said the Wren,
Both the cock and the hen,
We'll bear the pall.

Who'll sing a psalm?
I, said the Thrush,
As she sat on bush,
I'll sing a psalm.

Who'll toll the bell?
I, said the Bull,
Because I can pull,
I'll toll the bell.

All the birds of the air,
Fell a sighing and a sobbing,
When they heard the bell toll
For poor Cock Robin.

## 5. エントロピー計算

原始テキスト・データからエントロピーの次数に対応した文字列レコード・ファイルと総レコード数のみを記録した1レコード・ファイルを出力する。

文字列レコード・ファイルを整列させる（sort する）。整列済みファイルを 1 レコードづつ読み，同一文字列のレコード数を数え，それを総レコード数で割り，出現相対頻度を求め，エントロピーを計算していく。この 3 ステップからなる。

前川に倣い [7]，擬似コード pseudo coding で説明する。第 40 次エントロピー計算を例にして説明する。

第 1 ステップ

```
#include <stdio.h>
#include <string.h>
void main(void)
{
    変数，配列の定義
    ファイルのオープン処理
    先頭の 1 文字を読む
    次の手続きを 40 回反復する
    {
        大文字ならば小文字にする。
        改行キーだったらスペースにする
        文字配列の適当な要素に順次，文字を書きこむ
        次の 1 文字を読む
    }
    while( ファイルが終わるまで )
    {
        大文字ならば小文字にする
        文字が改行キーだったらスペースにする
        文字配列の 40 番目の要素に文字を入れる
        文字配列の 41 番目の要素に pure binary zero を入れる
```

40 連字の文字列レコードを出力する。

改行キーを出力する（1 レコードの出力が完了する）

文字配列の各要素を一文字ずつ前にずらす

次の一文字を読む

}

統計 1 レコードファイルを出力する

全ファイルをクローズする

}

具体的にプログラム Sigi40.c を次に示す。

```
001:/* Sigi40.c output 40-byte strings */
002:#include <stdio.h>
003:#include <string.h>
004:void main(void)
005:{
006:    int i = 0, stringcnt = 0;
007:    char chara, infile[50], work[50], outfile[50];
008:    FILE * fp0, * fp1, * fp3;
009:    printf("Input-file name: ");
010:    scanf("%s", infile);
011:    printf("Output-file name: ");
012:    scanf("%s", outfile);
013:    fp0 = fopen(infile, "r");
014:    fp1 = fopen(outfile, "w");
015:    fp3 = fopen("filesize.txt", "w");
016:    chara = getc(fp0);
017:    while (i < 39)
018:    {
019:        if(65 <= chara && chara <= 90)
020:        {
021:            chara = chara + 32;
022:        }
023:        if(chara == 0x0a)
024:        {
025:            chara = 32;
026:        }
027:        if((97 <= chara && chara <= 122) || (chara == 32))
028:        {
029:            work[i] = chara;
030:            i = i + 1;
031:        }
032:        chara = getc(fp0);
```

```
033:    }
034:    if(fp0 != NULL)
035:    {
036:        while(chara != EOF)
037:        {
038:            if(65 <= chara && chara <= 90)
039:            {
040:                chara = chara + 32;
041:            }
042:            if(chara == 0x0a)
043:            {
044:                chara = 32;
045:            }
046:            if((97 <= chara && chara <= 122) || (chara == 32))
047:            {
048:                work[39] = chara;
049:                work[40] = '\0';
050:                fputs(work, fp1);
051:                fputc('\n', fp1);
052:                stringcnt = stringcnt + 1;
053:                for(i = 0; i < 39; i++)
054:                {
055:                    work[i] = work[i + 1];
056:                }
057:            }
058:            chara = getc(fp0);
059:        }
060:        fprintf(fp3, "%d\n", stringcnt);
061:    }
062:    fclose(fp0);
063:    fclose(fp1);
064:    printf("%d strings \n", stringcnt);
065:    fclose(fp3);
066:}
```

第2ステップ

文字列レコードファイルを整列させる（sortする）

第3ステップ

```
#include <stdio.h>
#include <string.h>
#include <math.h>
```

```
void main(void)
{
    変数，配列の定義
    ファイルのオープン処理
    if( 入力ファイルがオープンできなければ )
    {
        何もしない
    }
    else
    {
        統計ファイル（1 レコード・ファイル）を読んで
          文字列数を知る
        先頭の文字列を読む
        その文字列を trace に入れる
        while( ファイルが終わるまで )
        {
            if( 文字列が trace に等しければ )
            {
                文字列カウンターを増分する
            }
            else
            {
                文字列カウンターの値を文字列数で割って確率を求める
                確率× log( 確率 ) を entropy に加算する
                文字列を trace に入れる
                文字列カウンターを 1 にする
                unique カウンターを増分する
            }
```

次の文字列レコードを読む

}

}

ファイルをクローズする

entropy を 40 で割る

画面に 40 次エントロピーを表示する

}

次にプログラム Miller40.c を示す

```
001:/* Miller40.c Calculation of 40th order entropy */
002:#include <stdio.h>
003:#include <string.h>
004:#include <math.h>
005:
006:void main(void)
007:{
008:    double entropy = 0, proba = 0;
009:    int totalcnt, stringcnt = 0, uniquecnt = 1;
010:    char  trace[50], infile[50], work[50];
011:    const char * miller;
012:    FILE * fp1, *fp3;
013:    printf("Input-file name: ");
014:    scanf("%s", infile);
015:    fp1 = fopen(infile, "r");
016:    fp3 = fopen("filesize.txt", "r");
017:    if(fp1 == NULL)
018:    {
019:    }
020:    else
021:    {
022:        fscanf(fp3, "%d", &totalcnt);
023:        printf("%7d\n", totalcnt);
024:        miller = fgets(trace, 50, fp1);
025:        strcpy(work, trace);
026:        while(miller != NULL)
027:        {
028:            if(strcmp(trace, work) == 0)
029:            {
030:                stringcnt = stringcnt + 1;
031:            }
032:            else
033:            {
034:                proba = (float)stringcnt / (float)totalcnt;
```

```
035:                entropy = entropy + proba * log(proba) / log(2);
036:                uniquecnt = uniquecnt + 1;
037:                strcpy(trace, work);
038:                stringcnt = 1;
039:            }
040:            miller = fgets(work, 50, fp1);
041:        }
042:        proba = (float)stringcnt / (float)totalcnt;
043:        entropy = entropy + proba * log(proba) / log(2);
044:    }
045:    fclose(fp1);
046:    fclose(fp3);
047:    entropy = entropy / 40.0;
048:    printf("(Miller40.c) ");
049:    printf("%d unique strings\n", uniquecnt);
050:    printf(" 40th order entropy = %8.6f\n", entropy);
051:}
```

このプログラム第47行の除数を変更するだけで何次エントロピーでも計算できる

## 6. 計算結果

| 書　名 | Who Killed Cock Robin | The Hunt for Red October | OP Center | Without Remorse | The Day of Jackal |
|---|---|---|---|---|---|
| file size | 1,289 | 970,567 | 537,312 | 1,462,084 | 771,683 |
| H01 | 3.951722 | 4.080464 | 4.058987 | 4.076145 | 4.063707 |
| H02 | 3.306571 | 3.743244 | 3.710725 | 3.720784 | 3.695529 |
| H03 | 2.618509 | 3.411523 | 3.380817 | 3.379858 | 3.361577 |
| H04 | 2.118716 | 3.092126 | 3.067087 | 3.069802 | 3.053169 |
| H05 | 1.769667 | 2.794259 | 2.794259 | 2.811472 | 2.784862 |
| H06 | 1.523971 | 2.587464 | 2.554308 | 2.593109 | 2.551317 |
| H07 | 1.333189 | 2.380843 | 2.339259 | 2.400077 | 2.344505 |
| H08 | 1.184097 | 2.194507 | 2.145373 | 2.224664 | 2.158803 |
| H09 | 1.066903 | 2.024234 | 1.969411 | 2.062322 | 1.990291 |
| H10 | 0.970298 | 1.869798 | 1.811584 | 1.912473 | 1.838261 |
| H11 | 0.890077 | 1.730608 | 1.671115 | 1.775313 | 1.710752 |
| H12 | 0.822563 | 1.605729 | 1.546549 | 1.650486 | 1.579231 |
| H13 | 0.764931 | 1.494324 | 1.436555 | 1.537954 | 1.469920 |
| H14 | 0.713608 | 1.395297 | 1.339477 | 1.437128 | 1.372680 |
| H15 | 0.668253 | 1.307220 | 1.253662 | 1.346904 | 1.286127 |
| H16 | 0.628347 | 1.228752 | 1.177527 | 1.266215 | 1.208916 |
| H17 | 0.592928 | 1.158621 | 1.109682 | 1.193932 | 1.139917 |
| H18 | 0.561011 | 1.095684 | 1.048941 | 1.128974 | 1.078012 |
| H19 | 0.532077 | 1.038983 | 0.994326 | 1.070424 | 1.022239 |
| H20 | 0.505767 | 0.987696 | 0.945012 | 1.017461 | 0.971793 |
| H21 | 0.481793 | 0.941116 | 0.900278 | 0.969337 | 0.925976 |
| H22 | 0.459834 | 0.898650 | 0.859537 | 0.925555 | 0.884204 |
| H23 | 0.439785 | 0.859796 | 0.822296 | 0.885472 | 0.845988 |
| H24 | 0.421406 | 0.824123 | 0.788129 | 0.848683 | 0.810899 |
| H25 | 0.404498 | 0.791267 | 0.756676 | 0.814806 | 0.778574 |
| H26 | 0.388900 | 0.760912 | 0.727625 | 0.783514 | 0.748709 |
| H27 | 0.374438 | 0.732787 | 0.700717 | 0.764528 | 0.721035 |
| H28 | 0.360972 | 0.706658 | 0.675722 | 0.727603 | 0.695324 |
| H29 | 0.348625 | 0.682323 | 0.652446 | 0.702530 | 0.671377 |
| H30 | 0.336864 | 0.659603 | 0.630717 | 0.679124 | 0.649019 |
| H31 | 0.325955 | 0.638345 | 0.610387 | 0.657226 | 0.628100 |
| H32 | 0.315728 | 0.618411 | 0.591324 | 0.636694 | 0.608485 |
| H33 | 0.306120 | 0.599682 | 0.573416 | 0.617405 | 0.590056 |
| H34 | 0.297078 | 0.582053 | 0.556560 | 0.599251 | 0.572709 |
| H35 | 0.288553 | 0.565430 | 0.540666 | 0.582132 | 0.556351 |
| H36 | 0.280501 | 0.549730 | 0.525653 | 0.565965 | 0.450901 |
| H37 | 0.272884 | 0.534877 | 0.511452 | 0.550671 | 0.526285 |
| H38 | 0.265668 | 0.520805 | 0.497996 | 0.536181 | 0.512438 |
| H39 | 0.258823 | 0.507454 | 0.485231 | 0.522435 | 0.499300 |
| H40 | 0.252319 | 0.494770 | 0.473104 | 0.509375 | 0.486810 |
| H41 | 0.246133 | 0.482705 | 0.461568 | 0.496952 | 0.474946 |
| H42 | 0.240241 | 0.471213 | 0.450580 | 0.485120 | 0.468638 |
| H43 | 0.236623 | 0.460256 | 0.440104 | 0.473839 | 0.452857 |

| 書　名 | The Dogs of War | The Odessa File | The Shepherd | Sophie's World | Why I survived A-Bombs |
|---|---|---|---|---|---|
| file size | 810,586 | 596,877 | 64,003 | 964,734 | 371,522 |
| H01 | 4.068114 | 4.063637 | 4.077524 | 4.054536 | 4.105486 |
| H02 | 3.704562 | 3.705517 | 3.714431 | 3.700202 | 3.752481 |
| H03 | 3.374857 | 3.369982 | 3.341634 | 3.362045 | 3.436056 |
| H04 | 3.063209 | 3.055386 | 2.974577 | 3.045866 | 3.123731 |
| H05 | 2.793966 | 2.782213 | 2.643293 | 2.776917 | 2.836641 |
| H06 | 2.561120 | 2.554118 | 2.352480 | 2.546776 | 2.576470 |
| H07 | 2.354661 | 2.332727 | 2.103107 | 2.344339 | 2.341912 |
| H08 | 2.168820 | 2.142822 | 1.889770 | 2.162480 | 2.132168 |
| H09 | 1.999820 | 1.970830 | 1.708196 | 1.997151 | 1.945393 |
| H10 | 1.847139 | 1.816338 | 1.554171 | 1.847501 | 1.781172 |
| H11 | 1.710030 | 1.678350 | 1.422606 | 1.712793 | 1.637667 |
| H12 | 1.586969 | 1.555304 | 1.309746 | 1.591830 | 1.512284 |
| H13 | 1.477710 | 1.446053 | 1.212490 | 1.483636 | 1.402503 |
| H14 | 1.379265 | 1.349292 | 1.128153 | 1.387000 | 1.306310 |
| H15 | 1.292158 | 1.263434 | 1.054395 | 1.300752 | 1.221707 |
| H16 | 1.214455 | 1.187052 | 0.989399 | 1.223658 | 1.146975 |
| H17 | 1.144988 | 1.118882 | 0.931779 | 1.154542 | 1.080553 |
| H18 | 1.082655 | 1.057814 | 0.880417 | 1.092377 | 1.021236 |
| H19 | 1.026520 | 1.002866 | 0.834372 | 1.036254 | 0.967982 |
| H20 | 0.975753 | 0.953210 | 0.793413 | 0.985426 | 0.919940 |
| H21 | 0.929659 | 0.908151 | 0.755257 | 0.939213 | 0.876376 |
| H22 | 0.887654 | 0.867103 | 0.721016 | 0.897035 | 0.836707 |
| H23 | 0.849232 | 0.829560 | 0.689735 | 0.858409 | 0.800444 |
| H24 | 0.813962 | 0.795106 | 0.661045 | 0.822920 | 0.767172 |
| H25 | 0.781482 | 0.763378 | 0.634638 | 0.790211 | 0.736542 |
| H26 | 0.751480 | 0.734074 | 0.610251 | 0.759972 | 0.708258 |
| H27 | 0.723685 | 0.706927 | 0.587662 | 0.731943 | 0.682057 |
| H28 | 0.697864 | 0.681708 | 0.566680 | 0.705893 | 0.657719 |
| H29 | 0.673818 | 0.658222 | 0.547146 | 0.681623 | 0.635054 |
| H30 | 0.651370 | 0.636298 | 0.528913 | 0.658959 | 0.613899 |
| H31 | 0.630368 | 0.615784 | 0.511854 | 0.637749 | 0.594105 |
| H32 | 0.610677 | 0.596550 | 0.495860 | 0.617857 | 0.575547 |
| H33 | 0.592177 | 0.578480 | 0.480834 | 0.599165 | 0.558111 |
| H34 | 0.574763 | 0.561472 | 0.466692 | 0.581569 | 0.541700 |
| H35 | 0.558345 | 0.545436 | 0.453358 | 0.564975 | 0.526225 |
| H36 | 0.542837 | 0.530289 | 0.440765 | 0.549300 | 0.511610 |
| H37 | 0.528168 | 0.515960 | 0.428853 | 0.534471 | 0.497785 |
| H38 | 0.514270 | 0.502384 | 0.417568 | 0.520421 | 0.484686 |
| H39 | 0.501085 | 0.489505 | 0.406861 | 0.507090 | 0.472260 |
| H40 | 0.488559 | 0.477268 | 0.396690 | 0.494424 | 0.460454 |
| H41 | 0.476644 | 0.465629 | 0.387014 | 0.482376 | 0.449224 |
| H42 | 0.465296 | 0.454544 | 0.377800 | 0.470900 | 0.438530 |
| H43 | 0.454475 | 0.443974 | 0.369014 | 0.459957 | 0.428332 |

英書 25 冊の第 43 次エントロピー計算

| 書　名 | The Crystal Singer | Crystal Line | A Catskill Eagle | Pastime | God Save the Child |
|---|---|---|---|---|---|
| file size | 304,275 | 511,075 | 404,989 | 287,287 | 298,069 |
| H01 | 4.090534 | 4.071662 | 4.028679 | 4.036607 | 4.053653 |
| H02 | 3.725994 | 3.715240 | 3.674846 | 3.682574 | 3.700939 |
| H03 | 3.385547 | 3.372888 | 3.319868 | 3.321185 | 3.348583 |
| H04 | 3.066058 | 3.053926 | 2.999099 | 2.993473 | 3.023943 |
| H05 | 2.792212 | 2.781191 | 2.726949 | 2.713752 | 2.742900 |
| H06 | 2.555564 | 2.542879 | 2.485689 | 2.467347 | 2.492648 |
| H07 | 2.345113 | 2.330058 | 2.271828 | 2.249011 | 2.269617 |
| H08 | 2.155192 | 2.137730 | 2.080731 | 2.054667 | 2.071097 |
| H09 | 1.982324 | 1.962598 | 1.909356 | 1.880796 | 1.893797 |
| H10 | 1.826648 | 1.805301 | 1.757230 | 1.727035 | 1.737220 |
| H11 | 1.687490 | 1.665400 | 1.622684 | 1.591465 | 1.599622 |
| H12 | 1.563423 | 1.541292 | 1.503675 | 1.472227 | 1.478810 |
| H13 | 1.453470 | 1.431649 | 1.398474 | 1.367312 | 1.372829 |
| H14 | 1.356229 | 1.334961 | 1.305367 | 1.274891 | 1.279663 |
| H15 | 1.270137 | 1.249479 | 1.222718 | 1.193232 | 1.192516 |
| H16 | 1.193644 | 1.171389 | 1.149107 | 1.120759 | 1.124714 |
| H17 | 1.125346 | 1.106084 | 1.083324 | 1.056129 | 1.059000 |
| H18 | 1.064086 | 1.045547 | 1.024341 | 0.998278 | 1.001922 |
| H19 | 1.008912 | 0.991111 | 0.971236 | 0.946257 | 0.949776 |
| H20 | 0.959006 | 0.941931 | 0.923222 | 0.899282 | 0.901677 |
| H21 | 0.913687 | 0.897310 | 0.879641 | 0.856671 | 0.859963 |
| H22 | 0.872385 | 0.856667 | 0.839925 | 0.817870 | 0.821061 |
| H23 | 0.834616 | 0.819512 | 0.803596 | 0.782404 | 0.785489 |
| H24 | 0.799941 | 0.785426 | 0.770245 | 0.749872 | 0.752845 |
| H25 | 0.768014 | 0.754048 | 0.739527 | 0.719925 | 0.722787 |
| H26 | 0.738522 | 0.725070 | 0.711150 | 0.692269 | 0.695024 |
| H27 | 0.711202 | 0.698233 | 0.684858 | 0.666652 | 0.669308 |
| H28 | 0.685828 | 0.673309 | 0.660432 | 0.642862 | 0.645423 |
| H29 | 0.662198 | 0.650100 | 0.637684 | 0.620708 | 0.623184 |
| H30 | 0.640140 | 0.628437 | 0.616446 | 0.600027 | 0.602424 |
| H31 | 0.619501 | 0.608169 | 0.596572 | 0.580800 | 0.583001 |
| H32 | 0.600150 | 0.589168 | 0.577939 | 0.562539 | 0.564791 |
| H33 | 0.581971 | 0.571318 | 0.560433 | 0.545497 | 0.547683 |
| H34 | 0.564859 | 0.554517 | 0.543955 | 0.529456 | 0.531579 |
| H35 | 0.548724 | 0.538675 | 0.528418 | 0.514331 | 0.516395 |
| H36 | 0.533484 | 0.523713 | 0.513743 | 0.500045 | 0.502053 |
| H37 | 0.519067 | 0.509560 | 0.499861 | 0.486531 | 0.488487 |
| H38 | 0.505409 | 0.496152 | 0.486709 | 0.473728 | 0.475634 |
| H39 | 0.492451 | 0.483431 | 0.474230 | 0.461581 | 0.463440 |
| H40 | 0.480141 | 0.471346 | 0.462338 | 0.450041 | 0.451855 |
| H41 | 0.468431 | 0.459850 | 0.451099 | 0.439065 | 0.440834 |
| H42 | 0.457278 | 0.448902 | 0.440359 | 0.428611 | 0.430339 |
| H43 | 0.446644 | 0.438463 | 0.430119 | 0.418643 | 0.420332 |

| 書　名 | The Godwulf Manuscript | Man on Fire | In the Name of the Father | The Blue Ring | Message from Hell |
|---|---|---|---|---|---|
| file size | 304,275 | 547,589 | 638,157 | 622,674 | 298,069 |
| H01 | 4.054947 | 4.063091 | 4.073119 | 4.060667 | 4.059951 |
| H02 | 3.700538 | 3.704640 | 3.713228 | 3.701047 | 3.697347 |
| H03 | 3.346448 | 3.361731 | 3.375556 | 3.356503 | 3.347897 |
| H04 | 3.021676 | 3.045617 | 3.059764 | 3.035953 | 3.022360 |
| H05 | 2.741941 | 2.772321 | 2.786789 | 2.760488 | 2.743293 |
| H06 | 2.494004 | 2.534545 | 2.549188 | 2.522708 | 2.501684 |
| H07 | 2.272396 | 2.324328 | 2.338639 | 2.314341 | 2.289669 |
| H08 | 2.076223 | 2.135529 | 2.149486 | 2.128117 | 2.100531 |
| H09 | 1.899216 | 1.963959 | 1.977912 | 1.959533 | 1.930142 |
| H10 | 1.742477 | 1.809604 | 1.823345 | 1.808246 | 1.778225 |
| H11 | 1.604327 | 1.671622 | 1.684871 | 1.672941 | 1.643068 |
| H12 | 1.482858 | 1.548532 | 1.561571 | 1.552115 | 1.522970 |
| H13 | 1.376322 | 1.439195 | 1.452132 | 1.444519 | 1.416383 |
| H14 | 1.282688 | 1.342355 | 1.355186 | 1.349028 | 1.322076 |
| H15 | 1.200156 | 1.256520 | 1.269155 | 1.264136 | 1.238465 |
| H16 | 1.127064 | 1.180233 | 1.192583 | 1.188474 | 1.164032 |
| H17 | 1.062024 | 1.112232 | 1.124214 | 1.120798 | 1.097520 |
| H18 | 1.003849 | 1.051356 | 1.062925 | 1.060066 | 1.037871 |
| H19 | 0.951544 | 0.996595 | 1.007768 | 1.005328 | 0.984138 |
| H20 | 0.904327 | 0.947138 | 0.957918 | 0.955778 | 0.935524 |
| H21 | 0.861515 | 0.902277 | 0.912663 | 0.910772 | 0.891379 |
| H22 | 0.822535 | 0.861424 | 0.871417 | 0.869733 | 0.851142 |
| H23 | 0.786903 | 0.824077 | 0.833694 | 0.832167 | 0.814329 |
| H24 | 0.754213 | 0.789816 | 0.799071 | 0.797667 | 0.780537 |
| H25 | 0.724116 | 0.758280 | 0.767192 | 0.765884 | 0.749417 |
| H26 | 0.696311 | 0.729156 | 0.737742 | 0.720665 | 0.720665 |
| H27 | 0.670554 | 0.702179 | 0.710459 | 0.709294 | 0.694023 |
| H28 | 0.646630 | 0.677122 | 0.685117 | 0.684003 | 0.669272 |
| H29 | 0.624350 | 0.653788 | 0.661515 | 0.660446 | 0.646220 |
| H30 | 0.603551 | 0.632006 | 0.639480 | 0.638452 | 0.624698 |
| H31 | 0.584092 | 0.611627 | 0.618864 | 0.617873 | 0.604561 |
| H32 | 0.565847 | 0.592520 | 0.599534 | 0.598577 | 0.585679 |
| H33 | 0.548707 | 0.574570 | 0.581373 | 0.580488 | 0.567939 |
| H34 | 0.532573 | 0.557674 | 0.564279 | 0.563383 | 0.551242 |
| H35 | 0.517361 | 0.541743 | 0.548161 | 0.547293 | 0.535497 |
| H36 | 0.502992 | 0.526697 | 0.532937 | 0.532095 | 0.520627 |
| H37 | 0.489400 | 0.512463 | 0.518536 | 0.517717 | 0.506558 |
| H38 | 0.476522 | 0.498978 | 0.504892 | 0.504095 | 0.493230 |
| H39 | 0.463440 | 0.486185 | 0.491947 | 0.494117 | 0.480585 |
| H40 | 0.452697 | 0.474031 | 0.479650 | 0.478893 | 0.468572 |
| H41 | 0.441656 | 0.462470 | 0.467952 | 0.467213 | 0.457144 |
| H42 | 0.431141 | 0.451459 | 0.456811 | 0.456090 | 0.446260 |
| H43 | 0.421114 | 0.440960 | 0.440960 | 0.445483 | 0.435882 |

英書25冊の第43次エントロピー計算

| 書　名 | A Short History of the World | Harry Potter and the Sorcerer's | Prince Caspian | N.P. | A Space Odyssey |
|---|---|---|---|---|---|
| file size | 712,476 | 441,674 | 252,542 | 162,125 | 368,733 |
| H01 | 4.084961 | 4.086546 | 4.046785 | 4.019926 | 4.069920 |
| H02 | 3.711772 | 3.718182 | 3.674851 | 3.665617 | 3.709878 |
| H03 | 3.380499 | 3.353834 | 3.293484 | 3.294808 | 3.380259 |
| H04 | 3.060751 | 3.022613 | 2.964378 | 2.956081 | 3.059985 |
| H05 | 2.776146 | 2.745592 | 2.685717 | 2.671201 | 2.777302 |
| H06 | 2.533825 | 2.504658 | 2.443111 | 2.425580 | 2.527429 |
| H07 | 2.324854 | 2.290954 | 2.229662 | 2.210769 | 2.305317 |
| H08 | 2.140635 | 2.099598 | 2.038848 | 2.019516 | 2.107084 |
| H09 | 1.974377 | 1.927711 | 1.866635 | 1.848176 | 1.929109 |
| H10 | 1.824370 | 1.774556 | 1.713531 | 1.696221 | 1.771135 |
| H11 | 1.689697 | 1.638504 | 1.578713 | 1.562008 | 1.631776 |
| H12 | 1.569066 | 1.518047 | 1.460077 | 1.443610 | 1.509064 |
| H13 | 1.461264 | 1.411544 | 1.355666 | 1.339723 | 1.401036 |
| H14 | 1.365063 | 1.317247 | 1.263784 | 1.248390 | 1.305797 |
| H15 | 1.279253 | 1.233618 | 1.182656 | 1.167882 | 1.221635 |
| H16 | 1.202698 | 1.159268 | 1.110772 | 1.096569 | 1.147051 |
| H17 | 1.134131 | 1.092872 | 1.046673 | 1.033160 | 1.080666 |
| H18 | 1.072568 | 1.033373 | 0.989314 | 0.976471 | 1.021322 |
| H19 | 1.017101 | 0.979813 | 0.937750 | 0.925527 | 0.968030 |
| H20 | 0.966938 | 0.931399 | 0.891183 | 0.879560 | 0.919934 |
| H21 | 0.921346 | 0.887468 | 0.848961 | 0.837897 | 0.876331 |
| H22 | 0.879815 | 0.847430 | 0.810519 | 0.799963 | 0.836644 |
| H23 | 0.841803 | 0.810811 | 0.775379 | 0.765289 | 0.800359 |
| H24 | 0.806900 | 0.777188 | 0.743146 | 0.733477 | 0.767071 |
| H25 | 0.774748 | 0.746210 | 0.713466 | 0.704191 | 0.736432 |
| H26 | 0.745039 | 0.717583 | 0.686054 | 0.677142 | 0.708137 |
| H27 | 0.717508 | 0.691058 | 0.660664 | 0.652088 | 0.681931 |
| H28 | 0.691929 | 0.666417 | 0.637083 | 0.628817 | 0.657592 |
| H29 | 0.668102 | 0.643466 | 0.615126 | 0.607146 | 0.634930 |
| H30 | 0.645824 | 0.622039 | 0.594631 | 0.586916 | 0.613776 |
| H31 | 0.625038 | 0.601990 | 0.575456 | 0.567990 | 0.593984 |
| H32 | 0.605518 | 0.583191 | 0.557478 | 0.550245 | 0.575428 |
| H33 | 0.587179 | 0.565529 | 0.540589 | 0.533575 | 0.557996 |
| H34 | 0.569915 | 0.548904 | 0.524693 | 0.517884 | 0.541588 |
| H35 | 0.553638 | 0.533227 | 0.509704 | 0.503089 | 0.526117 |
| H36 | 0.538264 | 0.518419 | 0.495547 | 0.489116 | 0.511506 |
| H37 | 0.523720 | 0.504412 | 0.482156 | 0.475898 | 0.497684 |
| H38 | 0.509941 | 0.491141 | 0.469469 | 0.463375 | 0.484590 |
| H39 | 0.496868 | 0.478551 | 0.457432 | 0.451495 | 0.472167 |
| H40 | 0.484448 | 0.466589 | 0.445997 | 0.440209 | 0.460364 |
| H41 | 0.472634 | 0.455211 | 0.435120 | 0.429473 | 0.449138 |
| H42 | 0.461383 | 0.444374 | 0.424760 | 0.419248 | 0.438445 |
| H43 | 0.450654 | 0.434041 | 0.414883 | 0.409499 | 0.428250 |

# 7. グラフ

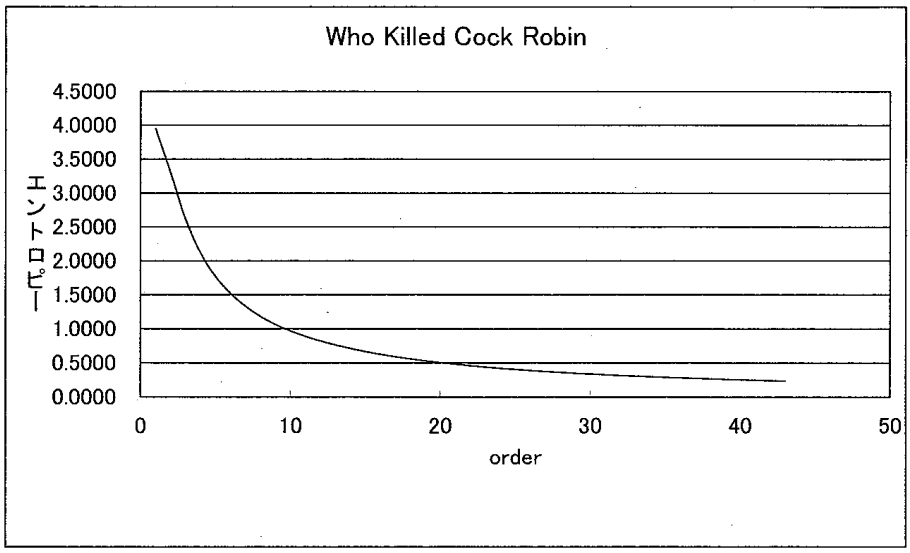
Who Killed Cock Robin
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

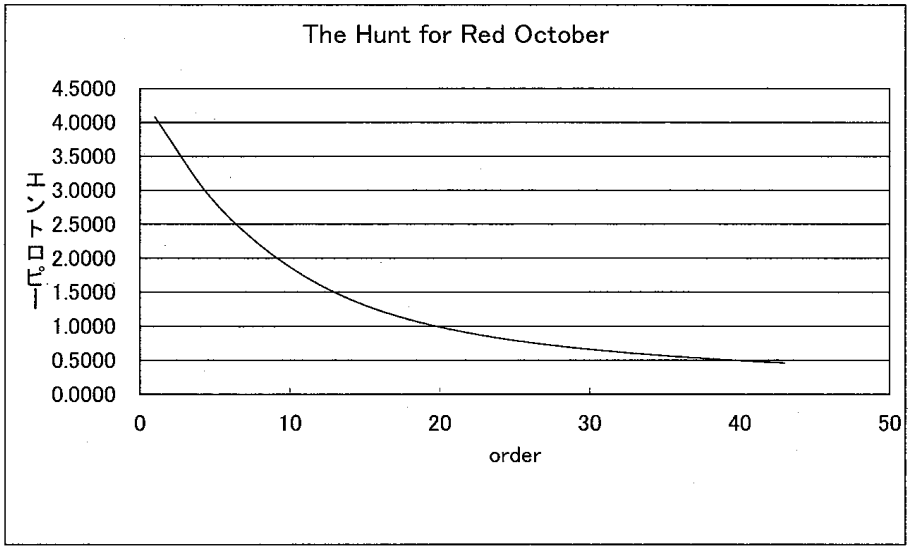
The Hunt for Red October
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

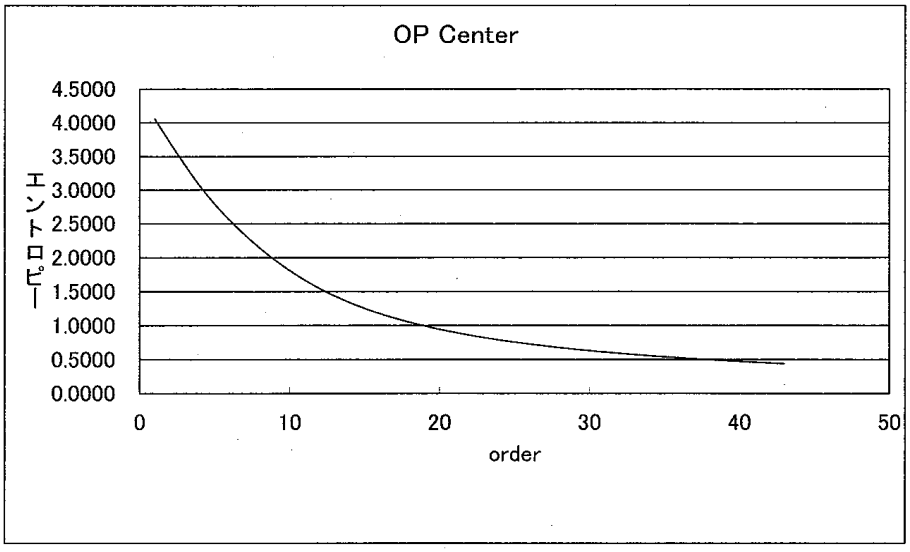
OP Center
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

英書25冊の第43次エントロピー計算

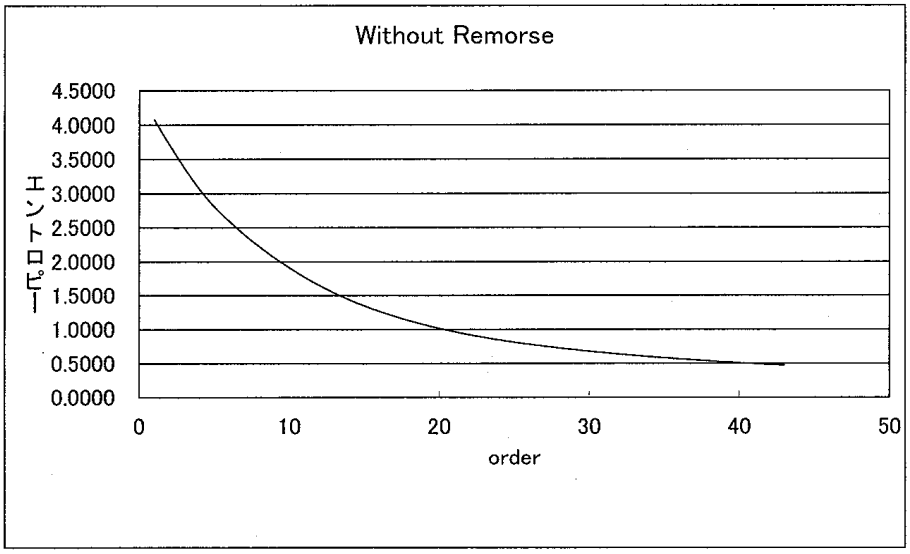


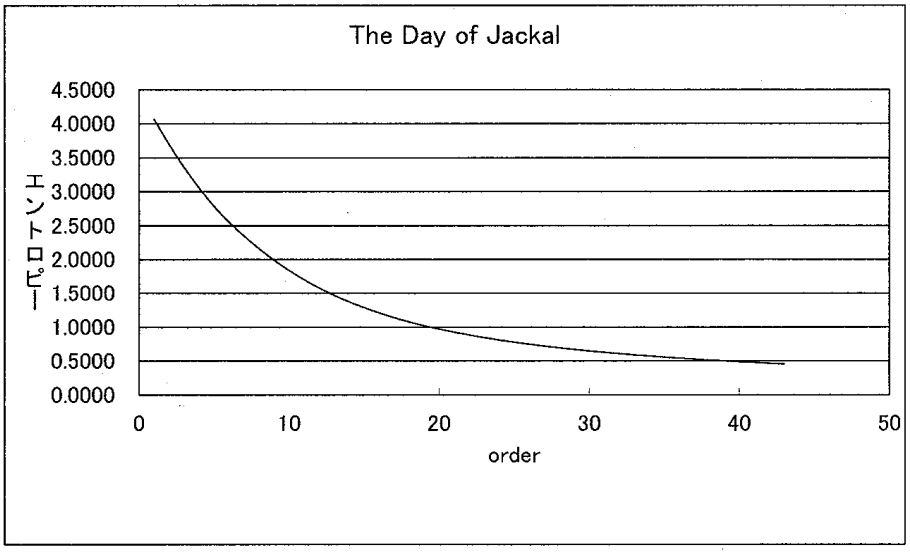


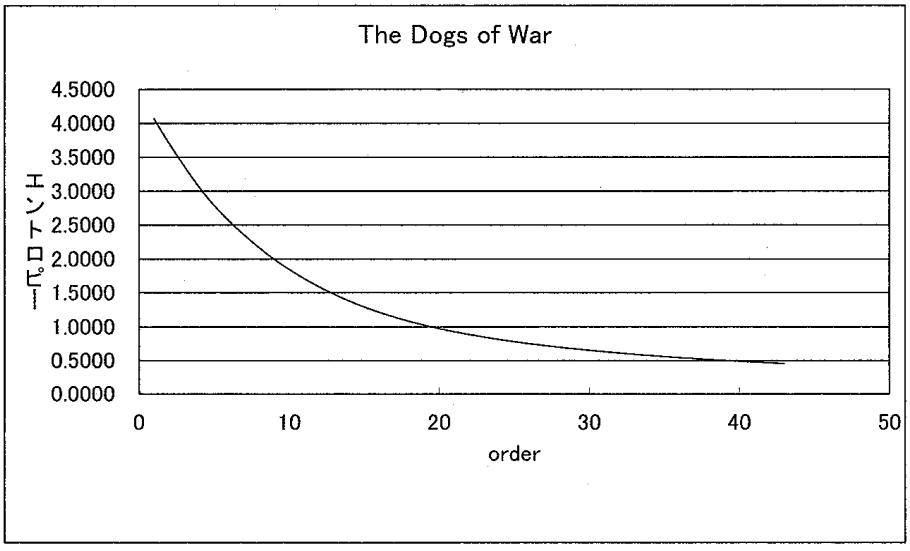

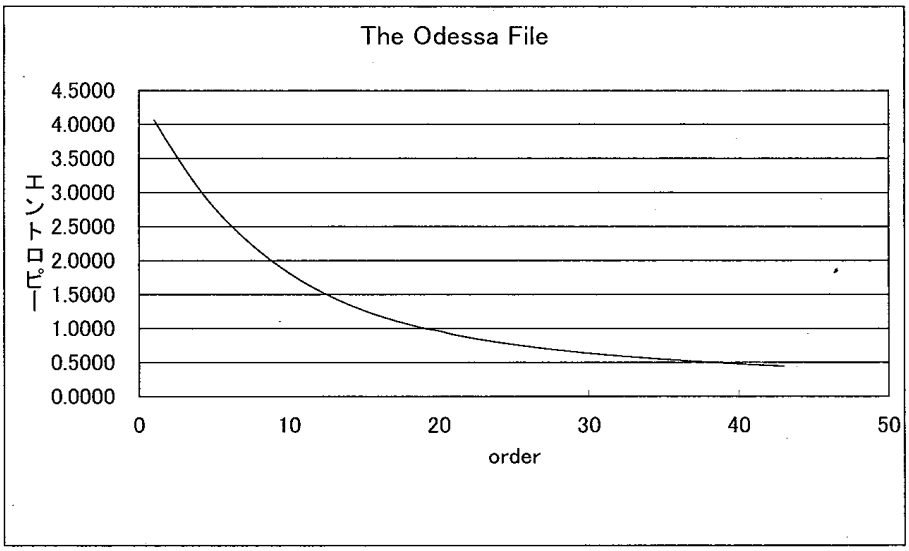
The Odessa File
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

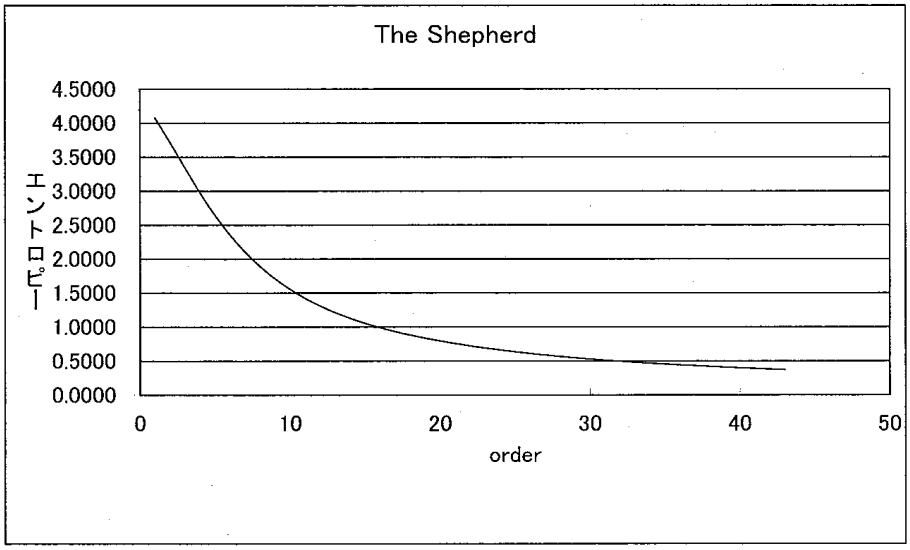
The Shepherd
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

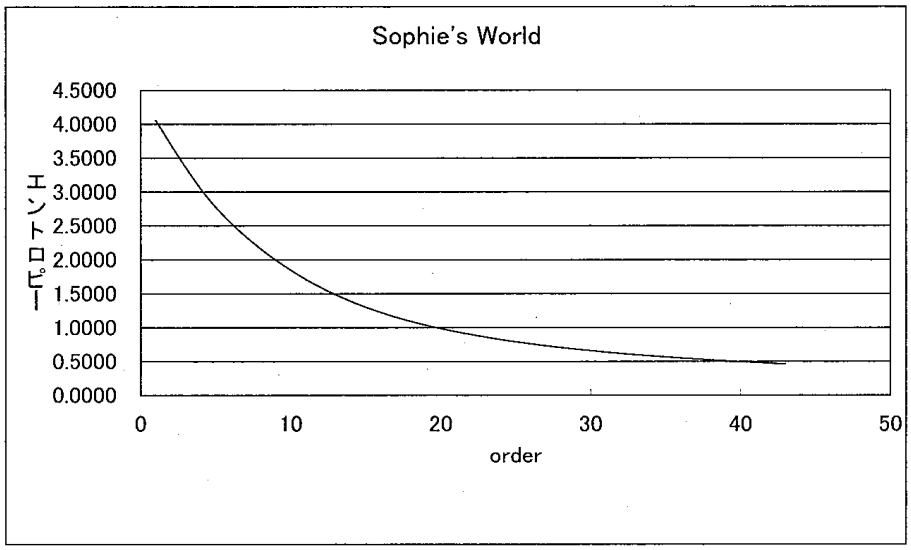
Sophie's World
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

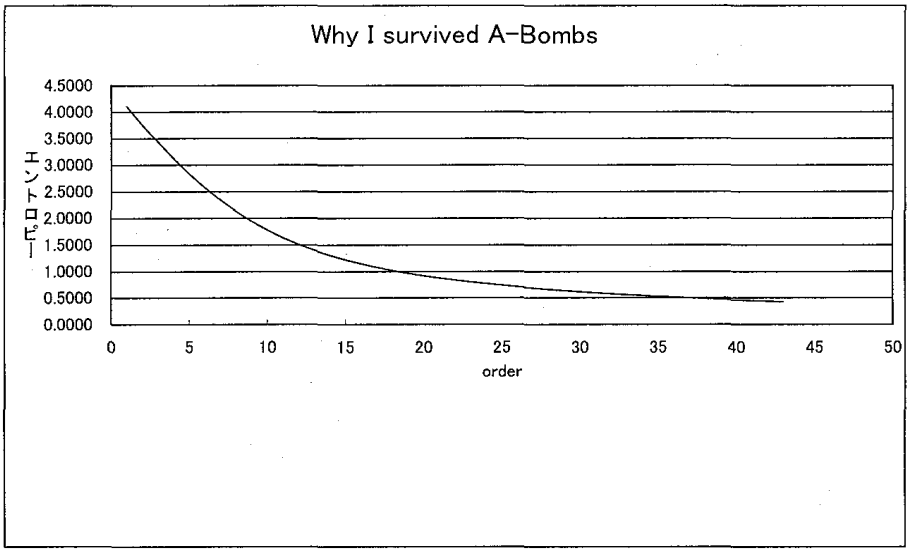
Why I survived A-Bombs
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
5
10
15
20
25
30
35
40
45
50
order

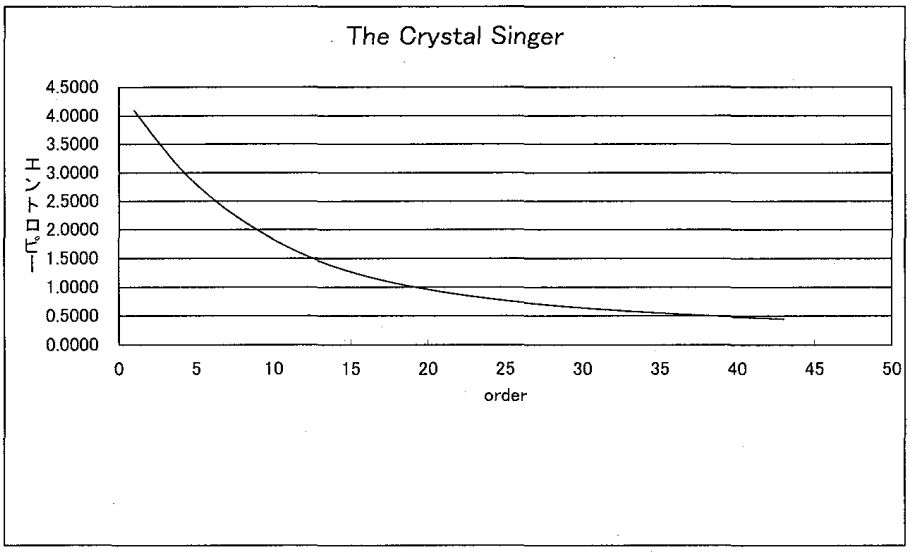
The Crystal Singer
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
5
10
15
20
25
30
35
40
45
50
order

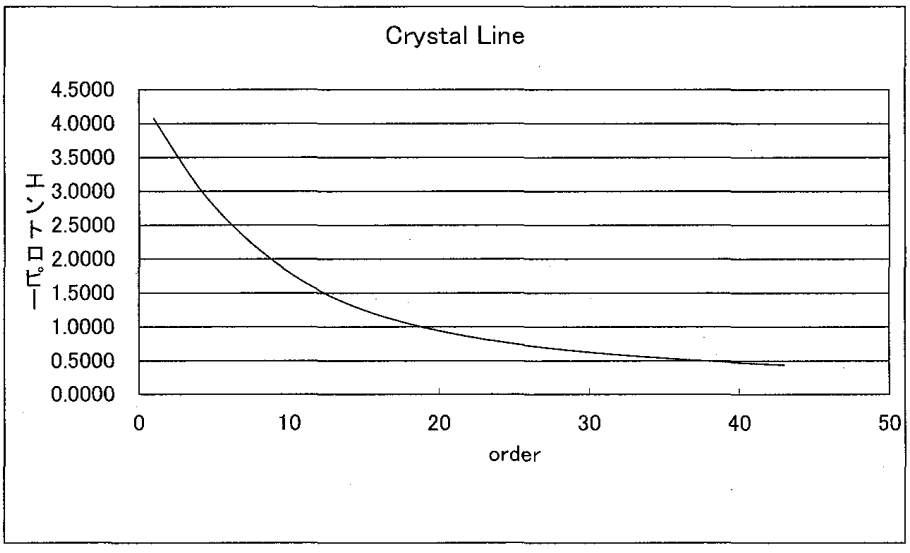
Crystal Line
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

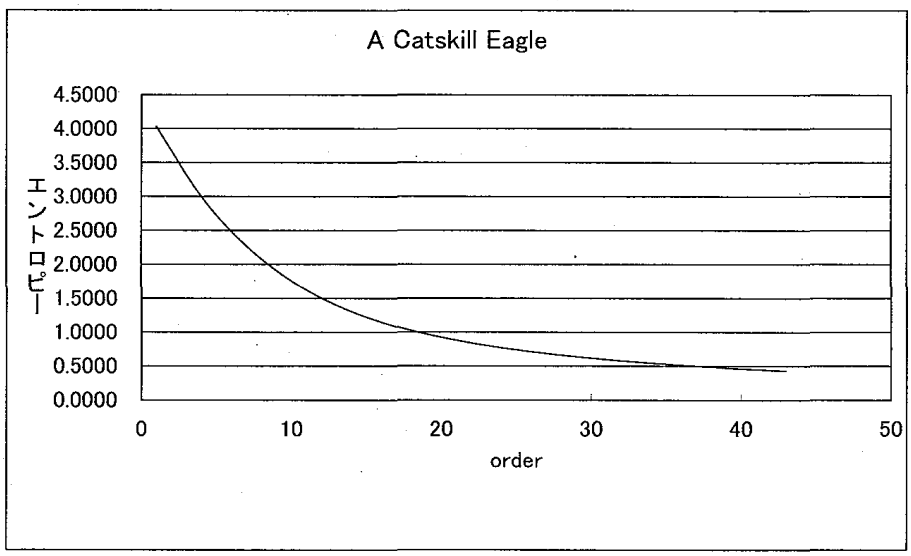
A Catskill Eagle
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

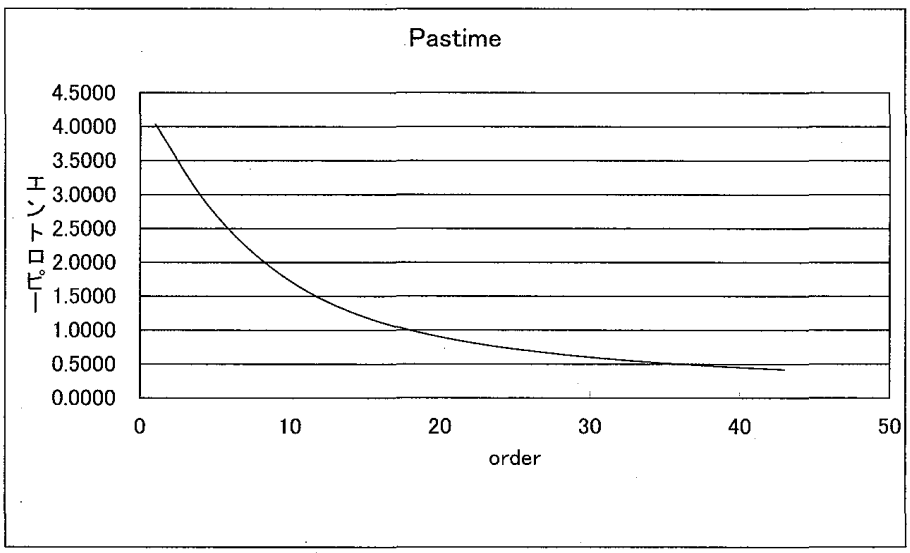
Pastime
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

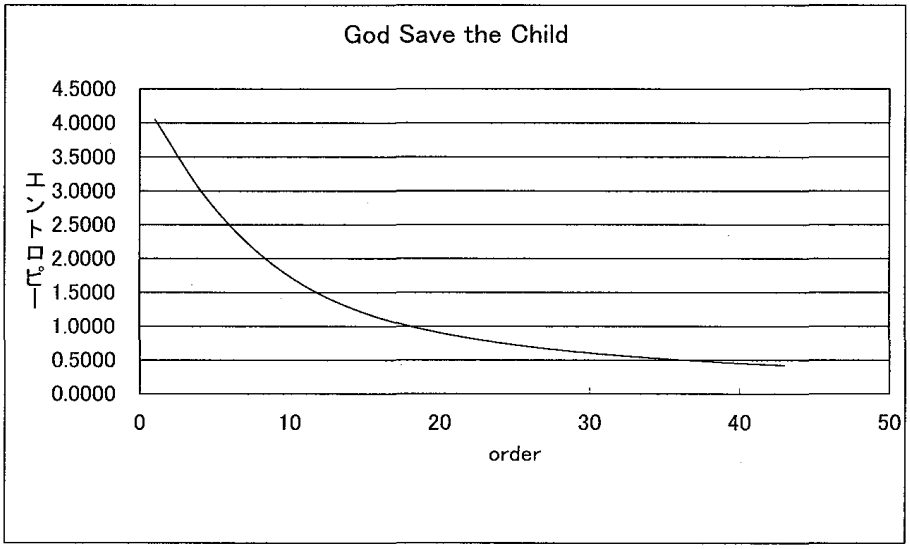
God Save the Child
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

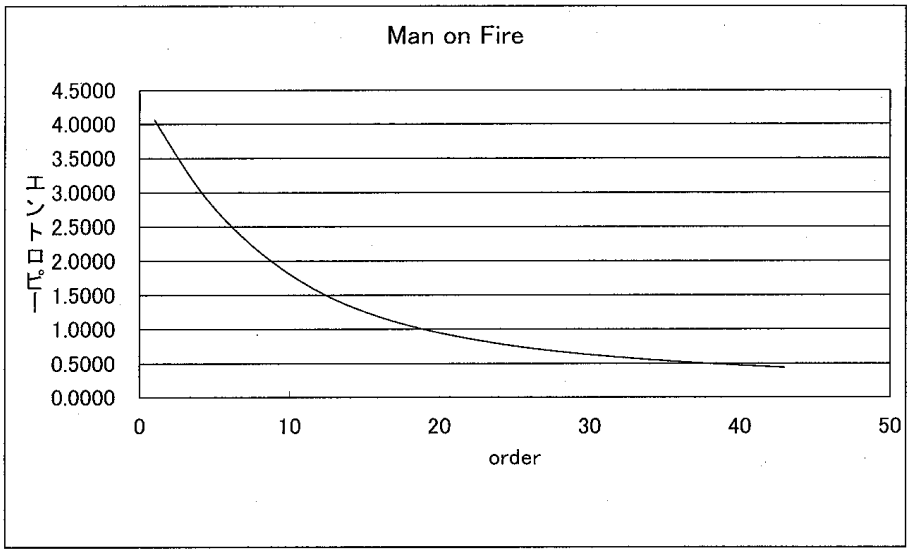
Man on Fire
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
エントロピー
0
10
20
30
40
50
order

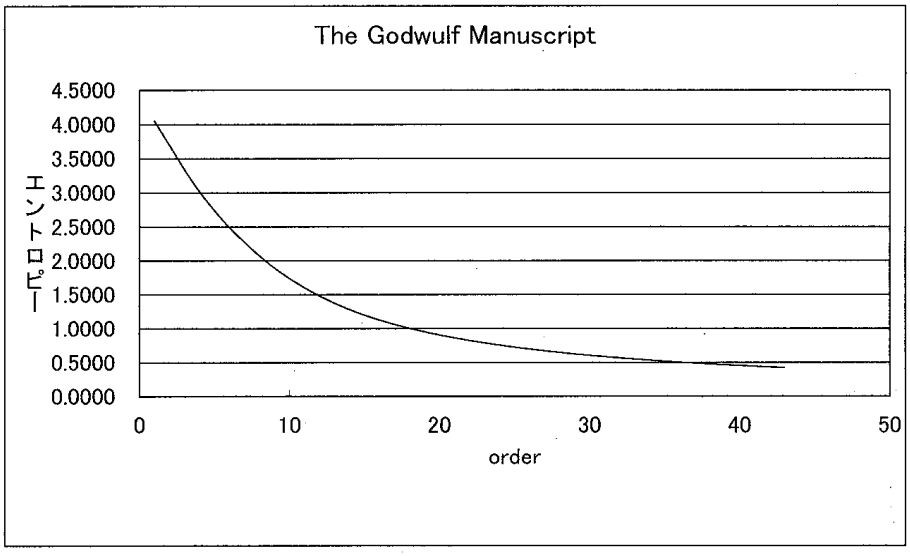
The Godwulf Manuscript
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
エントロピー
0
10
20
30
40
50
order

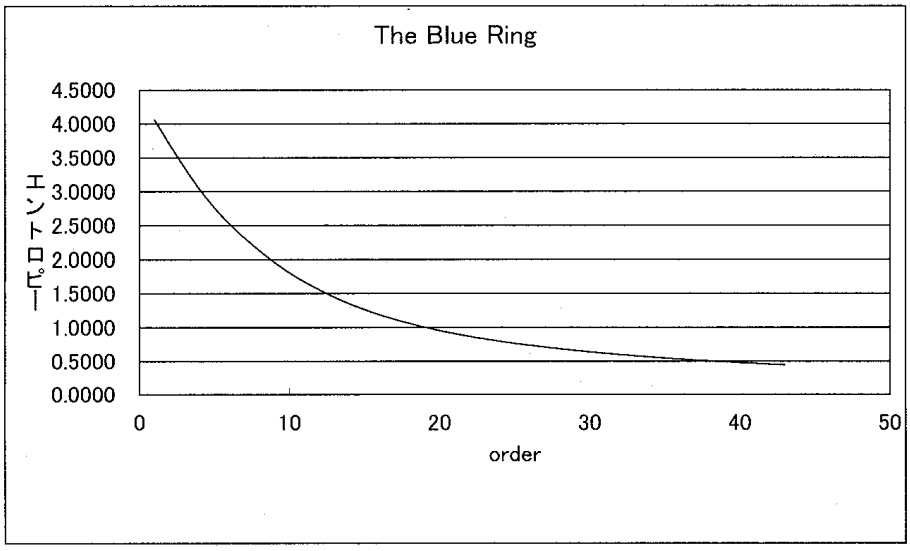
The Blue Ring
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
エントロピー
0
10
20
30
40
50
order

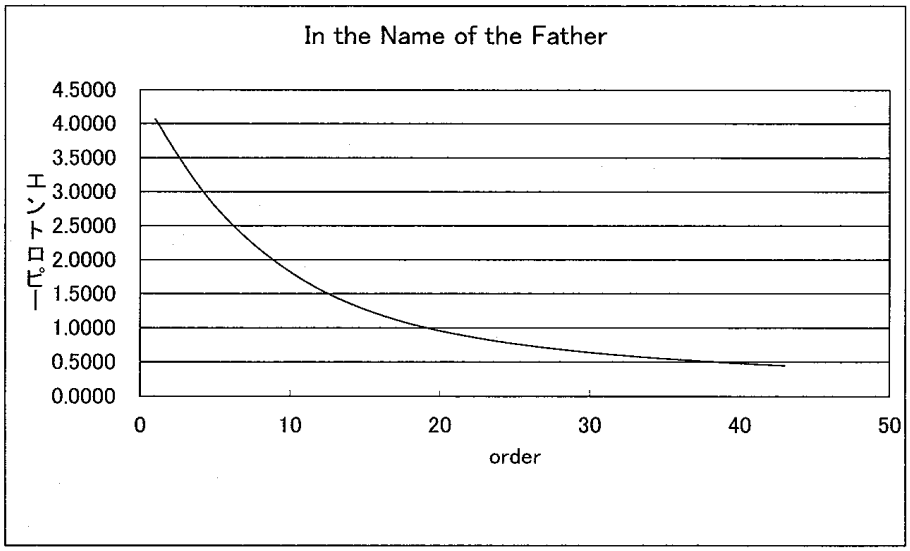
In the Name of the Father
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

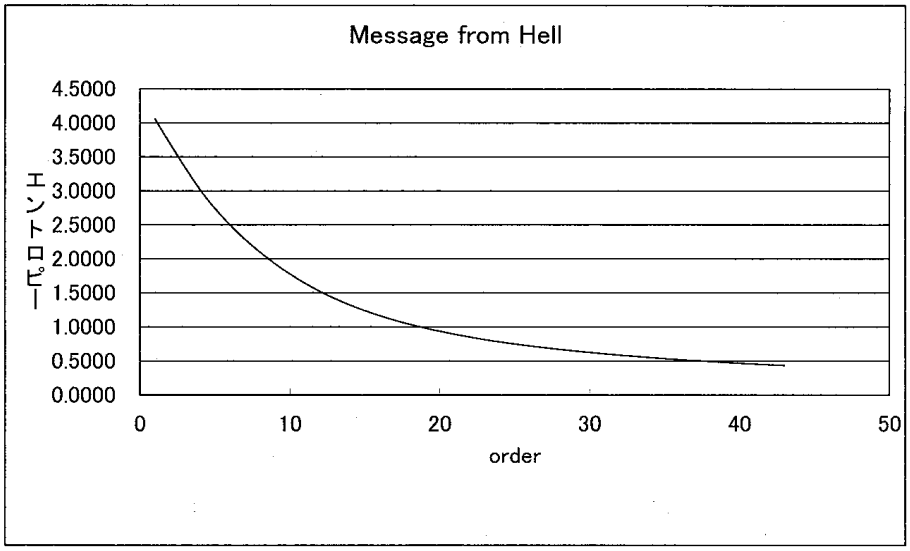
Message from Hell
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

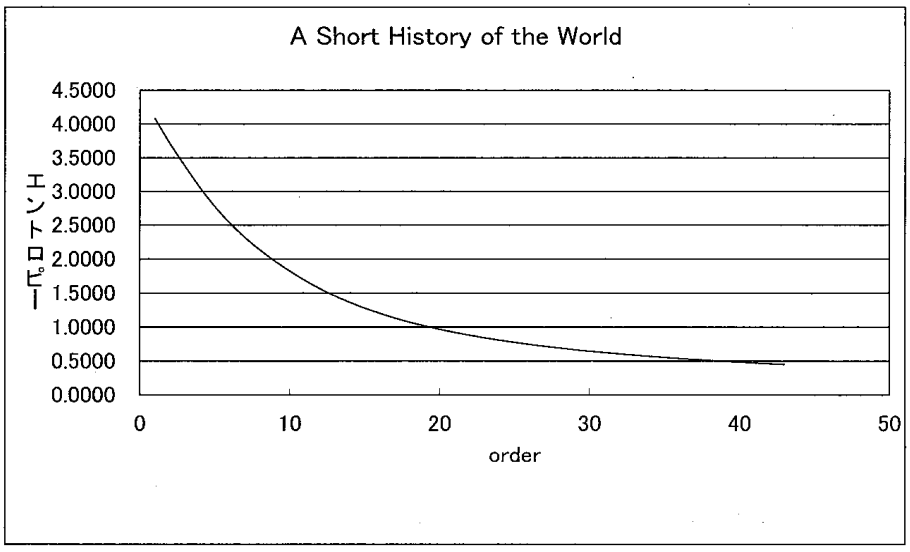
A Short History of the World
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

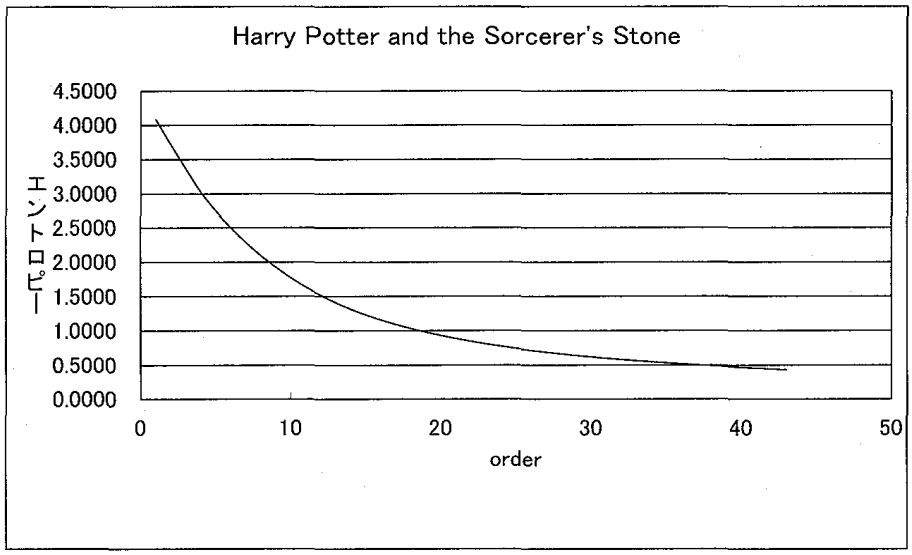
Harry Potter and the Sorcerer's Stone
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

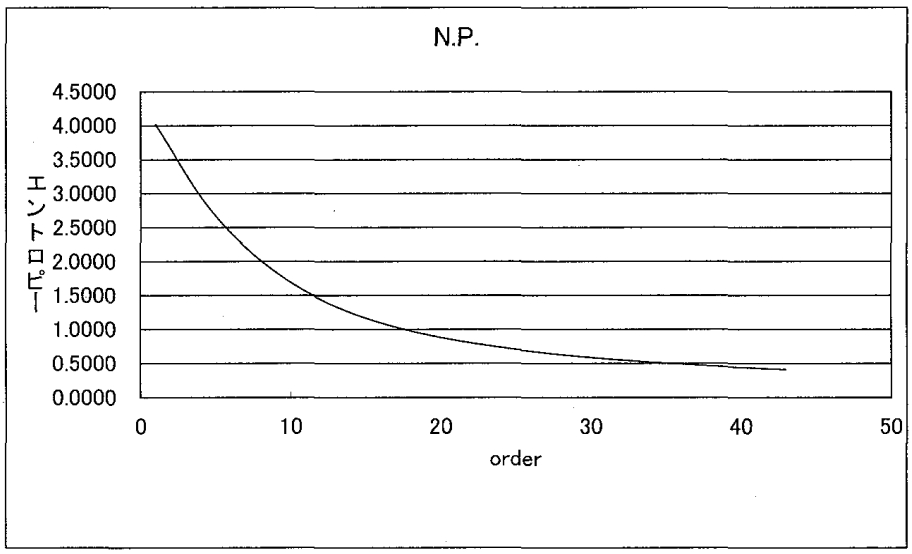
N.P.
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

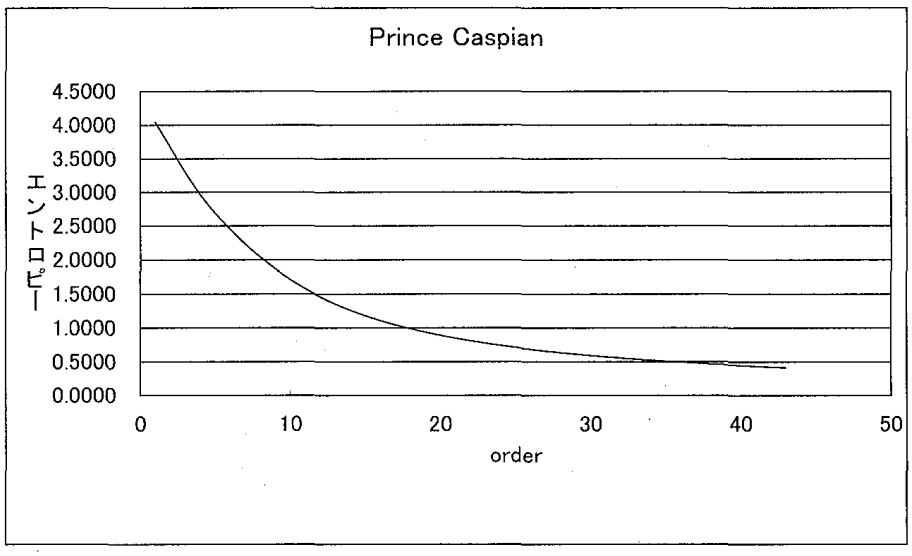
Prince Caspian
エントロピー
4.5000
4.0000
3.5000
3.0000
2.5000
2.0000
1.5000
1.0000
0.5000
0.0000
0
10
20
30
40
50
order

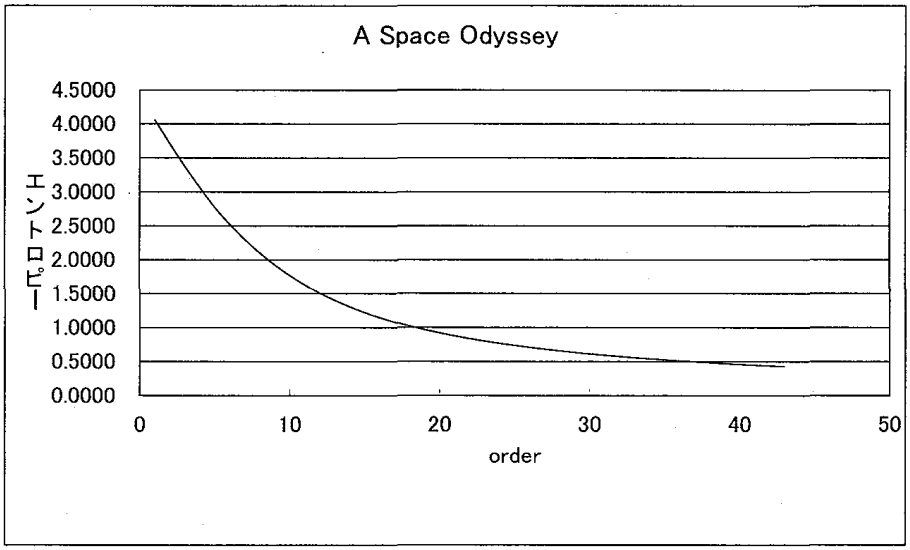


## 8. sort 時間の興味ある現象

三番目のデータである Tom Clancy の Without Remorse は 1.46 メガバイトの大きさである。本報告が処理した最大のファイルである 1 次エントロピーを計算するためには 1 文字プラス改行キーのレコードを作ると改行キーは 16 進で 0d0a という 2 バイトであるため，3 バイトのレコードが出来上がる。0d はカーソルを最左端に移動させることであり，0a は改行することである。今回はアルファベットとスペースだけ選んだがそれでも 4 メガバイトのファイルになってしまう。Windows2000 の sort を実行したら 2 時間 17 分掛かってしまった。ところが 2 次エントロピーのための sort は 11 分，3 次エントロピーのための sort は 2 分，4 次以上の sort はすべて一分未満であった。経験からファイルか大きくなれば sort 時間も増大すると認識していたため，かなりの違和感を覚えた。

ところが同じ sort を Windows xp で実行すると，今度は逆で，1 次エントロピーのための sort に 3 秒，2 次で 6 秒，と増大し，40 次近くになっても 18 秒から 20 秒の間に飽和するような現象が観察された。ただ，ここから今

回は43次エントロピーの計算で終わらせたが，作業時間さえあれば，100次エントロピーぐらいまでは計算可能のように推測できる。Windows xpによるsort時間の変化をグラフとして次に示す。

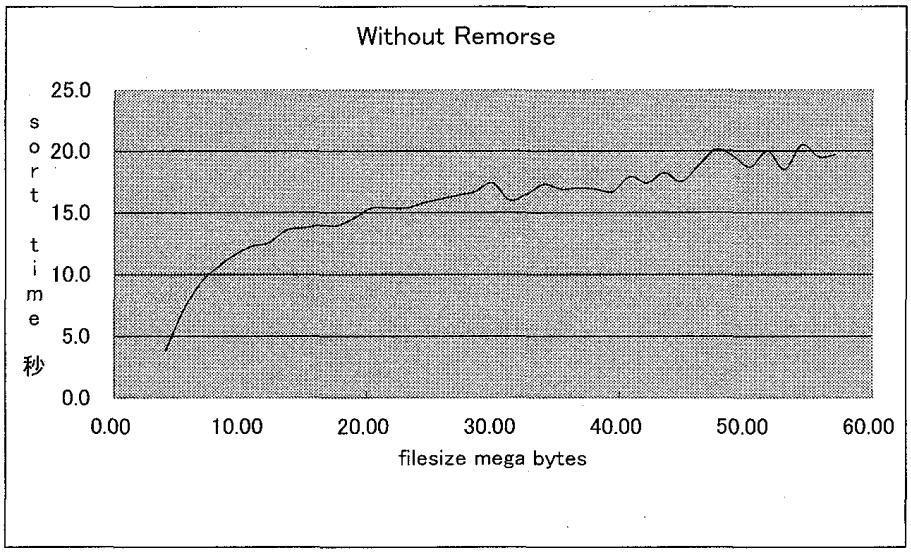


## 7. 結論

①1次エントロピーはファイル・サイズに関係なく4.02から4.11までの範囲である。Who killed Cock Robinだけが4.0未満なのはアルファベット27文字のうちj，q，x，yの4文字がないからである。$p \times \log_2 p$の数が少なくなるからである。

②エントロピーの次数が大きくなるにつれてエントロピーは小さくなるが，その減少の早さはファイルが小さければ早く，大きければ遅い。ファイルが小さければuniqueな文字列が少なく，大きければ多い。すなわち小さければ$p \times \log_2 p$の数が少なく，大きければ，$p \times \log_2 p$の数が多いからである。

③一番大きいWithout Remorseで43次エントロピーは0.473839である。冗長度は89.55%である。ヤグロム，堀等の予想をはるかに越えている。

## 参考文献

(1) アー・エム・ヤグロム，イー・エム・ヤグロム（井関清志・西田俊夫訳）：情報理論入門，みすず書房（1958）p121
(2) アー・エム・ヤグロム，イー・エム・ヤグロム（井関清志・西田俊夫訳）：情報理論入門，みすず書房（1958）p124
(3) 堀　淳一：エントロピーとは何か，講談社　（1992）p194
(4) 南　敏：情報理論，産業図書（1996）p55
(5) 藤田広一：情報理論，昭晃堂（1996），p24
(6) 前川　守：文章を科学する，岩波書店（1995）p13
(7) 前川　守：文章を科学する，岩波書店（1995）p84
(8) 前川　守：文章を科学する，岩波書店（1995）p48