

～変える～

研究テーマ：命令型プログラミング言語におけるプログラム可逆化

背景：

目的：平均ゴミ出力量の最適化

可逆性の定義：

可逆プログラムの定義：

状態：

～ここまで～

先週からの進捗状況：

1. 前回の報告で要チェックとなった部分を再び調べた


T3 繰り返し回数が最大n回の繰返し

ゴミ出力量 $\sim \log_2(n+1) \sim$

- ・ 繰返し回数が1回の場合も1ビット必要なので $\sim \log_2(n) \sim$ だと足りない

エントロピー $1/n \sum_{i=1}^n i \cdot (-(1/(i+1))\log_2(1/(i+1)) - (i/(i+1))\log_2(i/(i+1)))$

- ・ 繰返し回数がi回の場合のエントロピー
 - ・ 繰返し1回ごとのエントロピーは $-(1/(i+1))\log_2(1/(i+1)) - (i/(i+1))\log_2(i/(i+1))$
 - ・ i回の繰返しが起こるのでエントロピーにiを掛ける
- ・ 繰返し回数の確率分布は一様分布とする
 - ・ 繰返し回数がi回になる確率は $1/n$
- ・ グラフの形は $\log_2(n+1)$ とだいたい同じになる



```

gnuplotのコード
set samples 101
set xrange [0:100]
log2(x) = log(x)/log(2)
f(n) = (n > 0 ? -n*log2(1/(n+1))/(n+1) - n*n*log2(n/(n+1))/(n+1) + f(n-1) : 0)
itr(n) = f(n)/n
plot itr(x), log2(x+1)

```

T4 関数呼出し（末尾再帰に関して）

ゴミ出力量

- ・ 末尾再帰では、1回の再帰ごとに2分岐と同じ量のゴミが出力される
- ・ n回の再帰が起こるとゴミ出力量はnビットになる

エントロピー

- ・ われわれの手法では繰返しと同じになる
 - ・ 再帰が起こらないのは最後の1回だけ
- ・ $\frac{1}{n} \sum_{i=1}^n i * (-\frac{1}{i+1} \log_2(1/(i+1)) - \frac{i}{i+1} \log_2(i/(i+1)))$
- ・ だいたい $\log_2(n+1)$ になる

線形探索

前提

- ・ 事前に確率の見積もりが可能
- ・ 値は重複しない
- ・ データ数はn個

データが見つかる場合

確率

- ・ m番目で見つかる $1/(n-m+1)$
- ・ m番目で見つからない $(n-m)/(n-m+1)$

エントロピー

- ・ $\sum_{i=1}^m -((n-i)/(n-i+1))\log_2((n-i)/(n-i+1)) - (1/(n-i+1))\log_2(1/(n-i+1))$
 - ・ 第1項 < 第2項 < ... < 第m項
 - ・ ただし, m=nの場合は除く
 - ・ m=n-1の場合, 第m項=1

Perumallaの手法

- ・ データを1回比較するごとに1ビット必要
- ・ m番目で見つかった場合はmビットのゴミ出力量

Perumallaの手法との比較

- ・ Perumallaの手法のゴミ出力量をエントロピーと同じ形に書き直すと
 - ・ $\sum_{i=1}^m 1$
- ・ エントロピーはすべての項が1以下なので, Perumallaの手法よりも常にエントロピーの方が小さい

算術符号を用いた場合, 平均ゴミ出力量はエントロピーに近づく. よって算術符号を用いると平均ゴミ出力を減らすことができる

データが見つからないことがある場合

確率

- ・ m番目で見つかる $1/(100億*n)$
- ・ m番目で見つからない $(100億*n-1)/(100億*n)$
 - ・ mに比べて100億*nが十分に大きいため, mを無視する

見つからない場合の情報量 $-\log_2((100億*n-1)/(100億*n)) \doteq$ ほぼ0

- ・ $(100億*n-1)/(100億*n)$ はほぼ1

見つかる場合の情報量 $-\log_2(1/(100億*n))$

- ・ 巨大な情報量になる

エントロピー $-((100億*n-1)/(100億*n))\log_2((100億*n-1)/(100億*n)) - (1/(100億*n))\log_2(1/(100億*n)) \doteq$ ほぼ0

- ・ $-((100億*n-1)/(100億*n))\log_2((100億*n-1)/(100億*n)) \doteq$ ほぼ0
- ・ $\log_2(100億*n) < 100億*n$
 - ・ $-(1/(100億*n))\log_2(1/(100億*n)) \ll 1$

Perumallaの手法の平均ゴミ出力量 n

- ・ ほとんど見つからないため, 見つかった場合のゴミ出力量を無視する

算術符号を用いた場合, Perumallaの手法と比べて平均ゴミ出力量は下がるが, データが見つかった場合はゴミ出力量が極端に増える

次回までに進めること

- 1.

