

Sparse Regression Codes

Сенин Игорь

Московский Физико-Технический Институт

senin.ia@phystech.edu


7 мая 2024 г.

Теорема Шеннона-Хартли для AWGN канала

\mathcal{C} - точная верхняя грань всех достижимых R .

Цель - придумать код с быстрыми алгоритмами кодирования и декодирования, который (асимптотически) достигал бы пропускной способности гауссовского канала $\frac{1}{2} \log(1 + snr)$.

В SPARC'ах кодовые слова - векторы длины n вида $A\beta$, где A - матрица плана $n \times ML$, β - разреженный вектор длины ML . A и β разбиты на L секций длины M , причём в каждой из L секций β ровно одна ненулевая координата c_l .



Параметры M, L , элементы A , c_1, \dots, c_L фиксируются и считаются известными.

- Элементы матрицы A выбираются i.i.d. $\mathcal{N}(0, \frac{1}{n})$.
- L выбирается $\Theta(n/\log n)$.
- $M = L^a$ для некоторой константы $a > 0$.

Благодаря такому выбору M и L размер матрицы A растёт полиномиально с n .

Общее число кодовых слов - M^L .

$$M^L = 2^{Rn} \Leftrightarrow L \log M = Rn$$

- Сжатие с потерями
- Применение SPARC к Lossy compression
- Конечный алфавит источника
- Successive и AMP энкодеры

Определения

Искажение (distortion) - функция $d : \mathcal{X} \times \hat{\mathcal{X}} \rightarrow \mathbb{R}_+$.

Среднеквадратичное искажение: $d(x, \hat{x}) = (x - \hat{x})^2$.

$(2^{nR}, n)$ -код:

- функция-энкодер $f_n : \mathcal{X}^n \rightarrow \{1, 2, \dots, 2^{nR}\}$
- функция-декодер $g_n : \{1, 2, \dots, 2^{nR}\} \rightarrow \hat{\mathcal{X}}^n$

Искажение для $(2^{nR}, n)$ -кода: $D(f_n, g_n) = \mathbb{E}d(X^n, g_n(f_n(X^n))).$

Пара (R, D) называется **достижимой**, если существует последовательность $(2^{nR}, n)$ -кодов (f_n, g_n) такая, что

$$\lim_{n \rightarrow \infty} D(f_n, g_n) \leq D.$$

Определение

Функция rate-distortion $R(D)$ - инфимум таких R , что пара (R, D) достижима.

Информационная rate-distortion функция: $R^I(D) = \inf_{p(\hat{x}|x)} I(X; \hat{X})$,

где инфимум берётся по всем распределениям $p(\hat{x}|x)$, что

$$\sum_{(x, \hat{x})} p(x, \hat{x}) \cdot d(x, \hat{x}) \leq D.$$

Теорема Шеннона-Хартли

$$R(D) = R^I(D).$$

Теорема

Для $\mathcal{X} = \mathbb{R}$ и источника $\mathcal{N}(0, \sigma^2)$ $R(D) = \frac{1}{2} \log \frac{\sigma^2}{D}$.

Оптимальный энкодер

Пусть $s = (s_1, \dots, s_n)$ - набор вещественных чисел, которые хотим закодировать.

- Энкодер: $\hat{\beta} = \operatorname{argmin} \|s - A\beta\|^2$.
- Декодер: $\hat{s} = A\hat{\beta}$.

Кодовое слово - набор индексов ненулевых элементов в векторе $\hat{\beta}$, то есть $L \log M$ бит. На практике количество бит уменьшается в $\log n$ раз.

Successive-approximation энкодер

Идея: итеративно аппроксимировать остатки вида $\mathcal{R}_i = \mathcal{R}_{i-1} - c_i A_{m_i}$;
 $R_0 = s$.

Числа c_i - специального вида, $c_i = \sqrt{\frac{2R\sigma^2}{L}(1 - \frac{2R}{L})^{i-1}}$.

Утверждение (2014)

Пусть s приходит из нормального распределения $\mathcal{N}(0, \sigma^2)$. Тогда предложенный метод асимптотически достигает rate-distortion функции гауссовского источника $\sigma^2 e^{-2R}$, а вероятность эксцесса убывает экспоненциально относительно L .


AMP энкодер

Алгоритм AMP - *Approximate Message Passing*, итеративно решает NP-трудную задачу построения байесовской оценки.

Можно ли применить метод, например, к сжатию изображений?

Растровое изображение - набор чисел от 0 до 255 (например, 4 числа в случае RGBA). К самим наборам и большим блокам применять сжатие имеет мало смысла. Максимум - сжимать сами числа. Но это очень не эффективно.

Сравнение Successive и AMP энкодеров



Планы к отчётной конференции

- Доделать фреймворк для сжатия с потерями на основе SPARC
- Сделать выводы для случая конечного алфавита