



E. A. Timofeev, Balls in sequence spaces,
Model. Anal. Inform. Sist., 2012, Volume 19, Number 2, 109–114

<https://www.mathnet.ru/eng/mais223>

Use of the all-Russian mathematical portal Math-Net.Ru implies that you have read and agreed to these terms of use
<https://www.mathnet.ru/eng/agreement>

Download details:
IP: 18.97.14.85
May 19, 2025, 01:27:22



УДК 519.987

Шары в пространствах последовательностей

Тимофеев Е.А.¹

Ярославский государственный университет им. П.Г. Демидова

e-mail: timofeeva@gmail.com

получена 14 января 2012 года

Ключевые слова: энтропия, непараметрическая оценка, шар, мера Бернулли

Предлагается новая метрика на пространстве правосторонних бесконечных последовательностей над конечным алфавитом. Введенная в задаче оценивания энтропии дискретных стационарных процессов, эта метрика обладает рядом интересных свойств. Например, мера шара является разрывной при любом двоично-рациональном значении $\log r$, где r – радиус шара.

Введение

Точность непараметрических оценок энтропии [5] зависит от выбора метрики на пространстве Ω правосторонних последовательностей символов из конечного алфавита. В этой работе вводится новая метрика ρ_1 (см. (3)), которая обладает следующими свойствами:

1. ρ_1 эквивалентна обычной метрике, опирающейся на номер первых несовпадающих символов (см. (2)).
2. Для симметричной меры Бернулли мера шара в Ω , как функция радиуса, разрывна на всюду плотном множестве.
3. Обратная функция к мере шара непрерывна и постоянна почти всюду.

Подчеркнем, что поиск новых метрик обусловлен следующим результатом, доказанным в [5]: степенная точность оценки достигается в том случае, когда усредненная по пространству обратная функция к мере шара является гладкой (кусочно непрерывно дифференцируемой).

¹Работа выполнена при поддержке гранта Правительства РФ по постановлению №220, договор 11.G34.31.0053.

1. Оценки энтропии

В этом разделе приведем краткое описание задачи непараметрического оценивания энтропии стационарного процесса. Стационарный процесс будем представлять как инвариантную относительно сдвига меру μ на пространстве $\Omega = \mathcal{A}^{\mathbb{N}}$, точками которого являются бесконечные правосторонние последовательности символов из конечного алфавита \mathcal{A} , где $\mathbb{N} = \{1, 2, \dots\}$. Таким образом, случайную последовательность, порожденную мерой μ , будем рассматривать как точку в пространстве Ω распределенную по мере μ .

Пусть задана некоторая метрика $\rho(\mathbf{x}, \mathbf{y})$ на пространстве Ω , которая билипшицево эквивалентна метрике (2). Пусть заданы $n + 1$ точек ξ_0, \dots, ξ_n в пространстве Ω , которые независимы и распределены по мере μ . Тогда оценка энтропии [2] определяется следующим образом:

$$h_n = - \left[\frac{1}{(n+1) \log n} \sum_{j=0}^n \log \left(\min_{i:i \neq j} \rho(\xi_i, \xi_j) \right) \right]^{-1}. \quad (1)$$

В [5] эта оценка модифицирована на усредненные логарифмы расстояний разности между k -й и $(k+1)$ -й ближайшими точками.

Наиболее важной характеристикой оценки h_n является ее точность (эффективность) $\mathbf{E}(h_n - h)^2$, где h – энтропия, а n – число наблюдений.

Напомним, что

$$\mathbf{E}(h_n - h)^2 = \mathbf{D}h_n + (\mathbf{E}h_n - h)^2,$$

где $\mathbf{D}h_n$ – дисперсия оценки, а $\mathbf{E}(h_n - h)$ – смещение.

В [5] показано, что $\mathbf{D}h_n = O(n^{-c})$ для довольно широкого класса мер и метрик ($c > 0$ – некоторая константа). Для метрики (2) в [3] эта оценка улучшена до максимально возможного порядка – $\mathbf{D}h_n = O(n^{-1})$.

Как это часто бывает в дискретных задачах, нахождение смещения является намного более трудным. Так, для симметричных мер Бернулли в [4] показано, что смещение является периодической функцией с периодом пропорциональным $\log n$. Для марковских мер смещение имеет аналогичное поведение [6], если логарифмы переходных вероятностей рационально соизмеримы.

Итак, точность оценки энтропии зависит от свойств метрики.

2. Метрики в пространстве $\Omega = \mathcal{A}^{\mathbb{N}}$

Пусть $\Omega = \mathcal{A}^{\mathbb{N}}$ – пространство правосторонних последовательностей символов из конечного алфавита \mathcal{A} . Пусть $\mathbf{x} = (x_1, x_2, \dots)$ и $\mathbf{y} = (y_1, y_2, \dots)$ – две точки из Ω . Определим следующие две метрики на Ω :

$$\rho_0(\mathbf{x}, \mathbf{y}) = \theta^{-\min\{k: x_k \neq y_k\}}, \quad (2)$$

$$\rho_1(a\mathbf{x}, b\mathbf{y}) = \begin{cases} \theta^{-1} \rho_1(\mathbf{x}, \mathbf{y}), & a = b; \\ \theta^{-\lambda(-\log_{\theta} \rho_1(\mathbf{x}, \mathbf{y}))}, & a \neq b; \end{cases} \quad (3)$$

где $\theta > 1$ and $\lambda(t) = \min\{1, t/2\}$.

Подчеркнем, что метрика (3) билишпицево эквивалентна метрике (2), т.е.

$$\rho_0(\mathbf{x}, \mathbf{y}) \leq \rho_1(\mathbf{x}, \mathbf{y}) \leq \theta \rho_0(\mathbf{x}, \mathbf{y}). \quad (4)$$

Отметим, что согласно терминологии [1], ρ_1 является *слабой* метрикой (или *near-metric*), поскольку неравенство треугольника для нее выполняется с некоторой константой $C > 1$.

Поскольку каждая точка \mathbf{x} имеет бесконечное число координат, то для прикладных вычислений нужно ограничить число координат, используемых при расчетах. Для этого определяется *усечение* метрики, которое использует только m первых координат точки.

Определим *усечение* $\rho^{(m)}$ метрики ρ следующим образом:

$$\begin{aligned} \rho^{(0)}(\mathbf{x}, \mathbf{y}) &= 1; \\ \rho^{(m)}(a\mathbf{x}, b\mathbf{y}) &= \begin{cases} \theta^{-1} \rho^{(m-1)}(\mathbf{x}, \mathbf{y}), & a = b; \\ \theta^{-\lambda(-\log_{\theta} \rho^{(m-1)}(\mathbf{x}, \mathbf{y}))}, & a \neq b. \end{cases} \end{aligned} \quad (5)$$

Для упрощения вычислений введем

$$\alpha(\mathbf{x}, \mathbf{y}) = -\log_{\theta} \rho_1(\mathbf{x}, \mathbf{y}), \quad \alpha^{(m)}(\mathbf{x}, \mathbf{y}) = -\log_{\theta} \rho_1^{(m)}(\mathbf{x}, \mathbf{y}). \quad (6)$$

$$\alpha^{(m)}(a\mathbf{x}, b\mathbf{y}) = \begin{cases} \alpha^{(m-1)}(\mathbf{x}, \mathbf{y}), & a = b; \\ \lambda(\alpha^{(m-1)}(\mathbf{x}, \mathbf{y})), & a \neq b. \end{cases} \quad (7)$$

Подставив (6) в (3), получим

$$\alpha^{(m)}(a\mathbf{x}, b\mathbf{y}) = \begin{cases} \alpha^{(m-1)}(\mathbf{x}, \mathbf{y}) + 1, & a = b; \\ \min\{1, \alpha^{(m-1)}(\mathbf{x}, \mathbf{y})/2\}, & a \neq b. \end{cases} \quad (8)$$

Подчеркнем, что $-1/\log_{\theta} \rho_0(\mathbf{x}, \mathbf{y})$ также является метрикой на Ω , а $1/\alpha(\mathbf{x}, \mathbf{y})$ не является даже слабой метрикой.

3. Мера шара

Рассмотрим симметричную (с равновероятными символами) меру Бернулли μ на пространстве Ω с метрикой (3) и $\mathcal{A} = \{0, 1\}$. Обозначим открытый шар радиуса r с центром в точке \mathbf{x} через $B(\mathbf{x}, r) = \{\mathbf{y} \in \Omega : \rho_1(\mathbf{x}, \mathbf{y}) < r\}$.

Определим функцию $f(t)$, положив

$$f(t) = \mu(B(\mathbf{x}, \theta^{-t})).$$

Пусть ξ – случайная точка в Ω распределенная по мере μ . Рассмотрим случайную величину

$$\eta = \alpha(\xi, \mathbf{x}).$$

Заметим, что $f(t)$ и η , очевидно, не зависят от \mathbf{x} , и $1 - f(t)$ является функцией распределения случайной величины η .

Справедлива следующая

Лемма 1. η – дискретная случайная величина, принимающая значения $\frac{2m+1}{2^k} + n$, и имеющая следующее распределение:

$$\begin{aligned} P\left(\eta = \frac{2m+1}{2^k} + n\right) &= \frac{1}{6}2^{-k-s(m)-n}, \\ m &= 0, 1, \dots, 2^{k-1} - 1, k = 1, 2, \dots, n = 0, 1, \dots, \\ P(\eta = n) &= \frac{1}{3}2^{-n}, \quad n = 1, 2, \dots, \end{aligned} \quad (9)$$

где через $s(m)$ обозначается число '1' в двоичном разложении числа m .

Доказательство. Из определения (3) для симметричной меры Бернулли получаем рекуррентное соотношение для функции $f(t)$

$$\begin{cases} f(t) = \frac{1}{2}f(t-1), & t \geq 0, \\ f(t) = \frac{1}{2} + \frac{1}{2}f(2t), & 0 \leq t < 1. \end{cases}$$

На интервале $0 \leq t < 1$ функция $f(t)$ является самоподобной и для нее выполняется так называемое условие "открытых множеств":

$$\begin{cases} f(t) = \frac{1}{2} + \frac{1}{2}f(2t), & 0 \leq t < 1/2. \\ f(t) = \frac{1}{2} + \frac{1}{4}f(2t-1), & 1/2 \leq t < 1. \end{cases} \quad (10)$$

Отсюда получаем, что

$$f(1-0) = \frac{2}{3}, \quad P(\eta = 1) = \frac{1}{6}.$$

Для распределения случайной величины η из (10) получаем

$$P\left(\eta = \frac{2m+1}{2^k}\right) = \begin{cases} \frac{1}{2}P\left(\eta = \frac{2m+1}{2^{k-1}}\right), & m < 2^{k-2}; \\ \frac{1}{4}P\left(\eta = \frac{2m+1-2^{k-1}}{2^{k-1}}\right), & 2^{k-2} \leq m < 2^{k-1}; \\ \frac{1}{2}P\left(\eta = \frac{2m+1-2^k}{2^{k-1}}\right), & m \geq 2^{k-1}. \end{cases}$$

Решив эти рекуррентные уравнения, получим (9).

Для завершения доказательства осталось показать, что η принимает только двоично-рациональные значения. Для этого нужно доказать равенство

$$\sum_{n=1}^{\infty} \frac{1}{3}2^{-n} + \sum_{n=0}^{\infty} \sum_{k=1}^{\infty} \sum_{m=0}^{\infty} \frac{1}{6}2^{-k-s(m)-n} = 1.$$

Последнее вытекает из легко проверяемого тождества

$$\sum_{m=0}^{2^k-1} 2^{-s(m)} = \left(\frac{3}{2}\right)^k.$$

□

Из леммы 1 получаем следующее утверждение

Утверждение 1. Функция $\mu(B(x, r))$ разрывна при каждом двоично-рациональном значении $\log_{\theta} r$.




Рис. 1. Функция $1 - f(t) = 1 - \mu(B(x, \theta^{-t}))$ на интервале $0 \leq t < 1$.

График функции $1 - f(t)$ на интервале $0 \leq t < 1$ показан на рисунке 1. Отметим, что

$$f(t+1) = \frac{1}{2}f(t).$$

Определим обратную (обобщенную обратную) функцию $r = \nu(t)$ к функции $t = \mu(B(\mathbf{x}, r))$ следующим образом

$$\nu(t) = \sup\{r : \mu(B(\mathbf{x}, r)) < t\}. \quad (11)$$

Следует подчеркнуть, что участки постоянства функции $r = \nu(t, \mathbf{x})$ соответствуют разрывам функции $t = \mu(B(\mathbf{x}, r))$, поэтому справедливо следующее

Утверждение 2. *Функция $\nu(t, \mathbf{x})$ является непрерывной.*

Список литературы

- [1] M. Deza, T. Deza, *Encyclopedia of Distances*, Springer, 2009.
- [2] P. Grassberger, “Estimating the information content of symbol sequences and efficient codes”, *IEEE Trans. Inform. Theory*, **35** (1989), 669–675.
- [3] A. Kaltchenko, N. Timofeeva, “Entropy Estimators with Almost Sure Convergence and an $O(n^{-1})$ Variance”, *Advances in Mathematics of Communications*, **2:1** (2008), 1–13.
- [4] A. Kaltchenko, N. Timofeeva, “Rate of convergence of the nearest neighbor entropy estimator”, *AEU – International Journal of Electronics and Communications*, **64:1** (2010), 75–79.
- [5] E. A. Timofeev, “Statistical Estimation of measure invariants”, *St. Petersburg Math. J.*, **17:3** (2006), 527–551.
- [6] E. A. Timofeev, “Bias of a nonparametric entropy estimator for Markov measures”, *Journal of Mathematical Sciences*, **176:2** (2011), 255–269.

Balls in Sequence Spaces

Timofeev E.A.

Keywords: entropy, nonparametric statistic, ball, Bernoulli’s measure

We introduce a new metric on a space of right-sided infinite sequences drawn from a finite alphabet. Emerging from a problem of entropy estimation of a discrete stationary ergodic process, the metric is important on its own part and exhibits some interesting properties. For example, the measure of a ball is discontinuous at every binary rational value of $\log r$, where r is the radius.

Сведения об авторе:

Тимофеев Евгений Александрович,
Ярославский государственный университет им. П.Г. Демидова,
доктор физико-математических наук,
профессор кафедры теоретической информатики