

ОЦЕНКА КАЧЕСТВА АППРОКСИМАЦИИ ПЛОТНОСТЕЙ РАСПРЕДЕЛЕНИЯ ПЛОТНОСТЯМИ ИЗ ЭКСПОНЕНЦИАЛЬНОГО СЕМЕЙСТВА РАСПРЕДЕЛЕНИЙ

М.С. Лохвицкий, к.т.н., доцент, Московский технический университет связи и информатики.

УДК 621.396

Аннотация. Рассматриваются вопросы оценки качества аппроксимации неизвестных плотностей распределения плотностями из экспоненциального семейства распределений и полигауссовыми распределениями. В качестве критериев качества используются как статистические (критерий Хи-квадрат), так и критерии близости функций плотностей распределения в пространстве L_2 .

Ключевые слова: аппроксимация неизвестных плотностей; экспоненциальное семейство распределений; критерии качества; критерий Хи-квадрат; пространство L_2 .

QUALITY ASSESSMENT OF APPROXIMATION DISTRIBUTION DENSITIES BY THE DENSITIES FROM DISTRIBUTION EXPONENTIAL FAMILY

Mikhail Lokhvitsky, candidate of technical science, associate professor, Moscow technical university of communications and informatics.

Annotation. The problems of assessing the quality of approximation of unknown distribution densities by densities from the distribution exponential family and poly-Gaussian distributions are considered. As the quality criteria both statistical (Chi-square criterion) and the proximity criteria of the distribution density functions in the space are used.

Keywords: approximation of unknown densities; distribution exponential family; quality criteria; Chi-square criterion; L_2 space.

Введение

При приеме сигнала в современных системах телекоммуникаций часто приходится работать с плотностями распределений вероятностей, имеющих нестандартный вид [1, 2]. Это определяется тем, что передаваемая информация обладает различными статистическими свойствами. В общем случае, аналитическое выражение для плотности (в дискретном случае – для вероятности) можно получить по формуле полной вероятности [1]. Как правило, это будет многомодальное распределение. Аналогичные ситуации возникают и при анализе новых физических явлений. Один из способов решения таких задач – это аппроксимация плотностей распределения плотностями из некоторого семейства распределений. В качества такого семейства в [1, 2] предлагается использовать экспоненциальное семейство, а в работах [3, 4] полигауссовы распределения. Плотности распределений из этих семейств в качестве аппроксимирующих обладают рядом полезных свойств.

Выбор экспоненциального семейства в качестве аппроксимирующего связан с тем, что только плотности из этого семейства распределений обладают достаточными статистиками [2], что позволяет существенно сократить число вычислений при обработке выборок большого объема. Кроме этого, плотностями из этого семейства хорошо аппроксимируется широкий класс плотностей. Само экспоненциальное распределение возникает при разложении в ряд логарифма плотности распределения. Плотность распределения из этого семейства имеет вид:

$$p(x|\bar{\alpha}) = \exp \left\{ \sum_{i=1}^N \alpha_i \varphi_i(x) + C(\bar{\alpha}) + \varphi_0 \right\}, \quad (1)$$

где: α_i – неопределенные параметры, которые оцениваются на первоначальном этапе работы системы в режиме обучения по выборке;

$\varphi_i, i = \overline{1, N}$ – первые N - базисные функции полной системы функций на пространстве входных реализаций X ;

$C(\vec{\alpha})$ – функция, определяемая из условия нормировки плотности.

$$\int_X \exp(C(\alpha)) \cdot \exp\left(\sum_{i=1}^N \alpha_i \varphi_i(x)\right) dx = 1$$

$$\exp(C(\alpha)) = \frac{1}{\int_X \exp\left\{\sum_{i=1}^N \alpha_i \varphi_i(x)\right\} dx} \quad (2)$$

$$C(\alpha) = -\ln \int_X \exp\left\{\sum_{i=1}^N \alpha_i \varphi_i(x)\right\} dx$$

Для экспоненциального семейства распределения необходимые и достаточные статистики будут иметь вид:

$$S_i(x[1], \dots, x[n]) = \sum_{k=1}^n \varphi(x[k])$$

$$(i = \overline{1, N}). \quad (3)$$

Если в качестве функции $\varphi_i = x^i$ используются степенные функции, то достаточные статистики имеют вид:

$$S_i(x[1], \dots, x[n]) = \sum_{k=1}^n x^i[k]$$

$$(i = \overline{1, N}). \quad (4)$$

К недостаткам выбора экспоненциального распределения следует отнести невозможность, в общем случае, получить в явном виде аналитическое выражение для функции нормировки (2).

Оценки параметров плотностей из экспоненциального семейства $\vec{\alpha}$ для больших n , используя метод максимального правдоподобия, можно получить из рекуррентных формул [1, 2]:

$$\alpha_i[n] = \alpha_i[n-1] + \frac{1}{n} \sum_{j=1}^N b_{ij} \left\{ x^i[n] - \frac{1}{n-1} \sum_{k=1}^{n-1} x^i[k] \right\}, i = \overline{1, N}. \quad (5)$$

Здесь коэффициенты b_{ij} являются элементами матрицы (6):

$$B = \|b_{ij}\| = \left\| -\frac{\partial^2 C}{\partial \alpha_i \partial \alpha_j}(\vec{\alpha}[n-1]) \right\|^{-1}. \quad (6)$$

При малых n оценки параметров $\vec{\alpha}$ определяются по формулам (7). Это связано с тем, что при малых n матрица, элементы которой используются в формуле (6), будет вырожденной.

$$\alpha_i[n] = \alpha_i[n-1] + \sum_{j=1}^N \gamma_{ij}[n] \left\{ \frac{\partial C}{\partial \alpha_j}(\vec{\alpha}[n-1]) + x^j[n] \right\}. \quad (7)$$

Элементы матрицы γ_{ij} для формулы (7) можно определить [1, 2] так:

$$\gamma[n] = \frac{1}{n} \|b_{ij}\| = \begin{pmatrix} \frac{a}{n} & 0 & \dots & 0 \\ 0 & \frac{a}{n} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{a}{n} \end{pmatrix}, a > 0. \quad (8)$$

Алгоритм нахождения оценок параметров, используя метод максимального правдоподобия (ММП), показан на рис. 1.

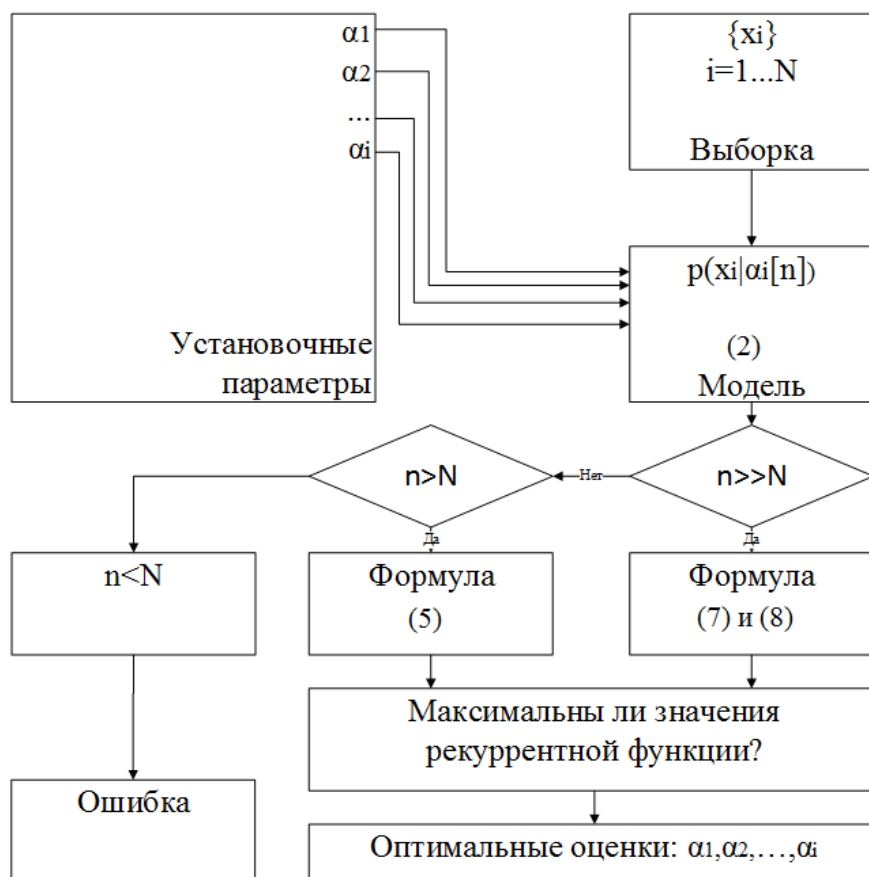


Рисунок 1

Для сравнения различных методов оценивания параметров распределения использовался так же и метод моментов (ММ).

Все выше изложенные идеи были проверены для случая аппроксимации плотностью из экспоненциального семейства смеси двух нормальных законов с различными параметрами (табл. 1, 2). Во всех рассмотренных примерах параметры распределений были: $m_1 = 0, m_2 = 4, \sigma_1^2 = 1, \sigma_2^2 = 1, \alpha = 0,5$.

Последний параметр – это весовой коэффициент в смеси плотностей.

Таблица 1

№	Объем выборки	Оценка m_1	Оценка дисперсии1	Оценка m_2	Оценка дисперсии2	Оценка весового коэф.
1	50	0,114	0,845	4,115	0,731	0,501
2	200	0,065	0,944	4,09	0,953	0,509
3	10000	-0,015	1,008	3,982	1,003	0,497

Таблица 2

№	Объем выборки	Оценка m_1	Оценка дисперсии1	Оценка m_2	Оценка дисперсии2	Оценка весового коэф.
1	50	0,171	0,731	3,957	1,176	0,462
2	200	-0,106	0,662	4,021	0,938	0,485
3	10000	0,081	1,142	3,993	1,015	0,503

В задачах аппроксимации плотностей естественно важным является качество аппроксимации. При этом можно и нужно использовать различные критерии качества. Первый класс критериев – это статистические. Самые универсальные и популярные из них – это критерии согласия χ^2 .

Основная гипотеза: $H_0: p(x) = \hat{p}(x)$. Альтернативная гипотеза: $H_1: p(x) \neq \hat{p}(x)$.

Т. е. проверяется гипотеза о том, что статистические данные (выборка) соответствуют полученной аппроксимирующей плотности. Чтобы проверить основную гипотезу будем использовать критерий согласия Фишера. Суть критерия: числовая ось разбивается на l интервалов. Затем вычисляются относительные частоты O_i , вероятности E_i попадания в интервалы и статистика критерия:

$$\chi_n^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \quad (9)$$

По таблице χ^2 находится порог, и значение статистики (9) сравнивается с величиной этого порога. Если порог превышен, то гипотеза отвергается. В нашем случае это показывает, что качество аппроксимации неудовлетворительное. В противном случае – нет оснований отвергнуть основную гипотезу.

Второй класс критериев – это критерии, основанные на оценке близости графиков функций. Естественно такие критерии можно использовать только тогда, когда нам известна плотность, которую мы хотим заменить на близкую к ней плотность из экспоненциального семейства. Для нас эти критерии интересны тем, что, используя их, можно оценить эффективность самих методов аппроксимации. Рассмотрим два таких критерия. В первом критерии вычисляется модуль максимального отклонения теоретической плотности от ее оценки:

$$\max |p(x) - \hat{p}(x)| \quad (10)$$

Второй критерий основан на оценке близости функций в пространстве L_2 :

$$\int_a^b (p(x) - \hat{p}(x))^2 dx \quad (11)$$

Рассмотрим качество оценивания для примеров вычисления, приведенных в табл. 1 и 2. Начнем с метода максимального правдоподобия (табл. 3), затем рассмотрим метод моментов (табл. 4).

Таблица 3

№	Максимум модуля разности	Отклонение в пространстве L_2	Статистический критерий согласия
1	0,024	0,018	Гипотеза H_0
2	0,009	0,015	Гипотеза H_0
3	0,001	0,0087	Гипотеза H_0

Таблица 4

№	Максимум модуля разности	Отклонение в пространстве L_2	Статистический критерий согласия
1	0,0022	0,019	Гипотеза H_0
2	0,005	0,016	Гипотеза H_0
3	0,002	0,0089	Гипотеза H_0

Заключение

Если параметры аппроксимирующей плотности были хорошо оценены (т.е. близки к теоретическим значениям параметров), то и качество аппроксимации плотностей по всем критериям будет хорошим.

Литература

1. Лохвицкий М.С. Качество аппроксимации плотностей распределения плотностями из экспоненциального семейства распределений // Мобильный бизнес: перспективы развития и реализации систем радиосвязи в России и за рубежом. Сборник материалов 44-ой Международной конференции РАЕН, 2019. – С. 8-10.
2. Шахгильдян В.В., Лохвицкий М.С. Методы адаптивного приема сигналов. – М.: Изд-во: Связь, 1974. – С. 3-158.
3. Застела М.Ю. Основы радиоэлектроники. – М., Юрайт, 2019.
4. Матвеев В.А., Сикарев А.А., Фалько А.И. Подавление сосредоточенных помех. Радиэлектроника, – Т. XX. – № 4. 1977.
5. Лохвицкий М.С., Сорокин А.С., Шорин О.А. Мобильная связь: стандарты, структуры, планирование. – М.: Изд-во Горячая линия - Телеком, 2018. – С. 264.
6. Дынкин Е.Б. Необходимые и достаточные статистики для семейства распределений вероятностей. – «Успехи математических наук», 1951. – Вып. 1. – С. 68-90.
7. Большаков И.А., Гуткин Л.С., Левин Б.Р., Стратонович Р.Л. Математические основы современной радиоэлектроники. – М.: Изд-во «Советское радио», 1972. – С. 447.