

Dong Wang

现代机器学习技术导论

2018 年 3 月 17 日

Springer

Contents

机器学习概述	vii
线性模型	ix
神经模型	xi
深度学习	xiii
核方法	xv
图模型	xvii
非监督学习	xix
非参数模型	xxi
8.1 简单非参数模型	xxii
8.2 高斯过程	xxiv
8.2.1 高斯过程	xxv
8.2.2 高斯过程回归	xxvii
8.2.3 高斯过程用于分类任务	xxxii
8.3 狄利克雷过程	xxxii
8.3.1 回顾高斯混合模型	xxxiii
8.3.2 中国餐馆问题	xxxv
8.3.3 狄利克雷分布及性质	xxxvii
8.3.4 狄利克雷过程	xl
8.3.5 狄利克雷过程的表示	xli

8.3.6 狄利克雷过程的构造	xlvi
8.3.7 推理方法	xlviii
8.3.8 Hierarchical DP (HDP)	li
8.4 本章小结	liii
8.5 相关资源	liv
遗传学习	lv
强化学习	lvii
优化方法	lix
References	lxii

Chapter 1

机器学习概述

Chapter 2

线性模型

Chapter 3

神经模型

Chapter 4

深度学习

Chapter 5

核方法

Chapter 6

图模型

Chapter 7

非监督学习

Chapter 8

非参数模型

我们已经讨论了各种模型，这些模型有些是线性的，有些是非线性的，有些是神经网络的，有些是概率图的，有些是描述性的，有些是区分性的，有些是监督学习的，有些是非监督学习的... 这些模型的构造过程都遵循如下步骤：设计好一个模型形式 M ，收集训练数据集 D ，依某种优化方法对 M 进行优化，使之对某一目标函数 L 最大化（或某一损失函数 C 最小化）。特别的，绝大多数模型是由一组参数 P 决定的，如在概率图模型中概率函数的尺度变换参数，神经模型中的连接权重等。因此，参数 P 决定了模型 M ，对模型 M 进行优化的过程即是对 P 的选择过程。对模型的参数化极大简化了学习过程：它相当于预先定义了一个知识表达形式，并通过对这一形式中的参数进行学习来确定具体模型。这事实上提供了一种将先验知识（模型形式）和经验学习相结合的方法。被参数完全定义的模型称为“参数模型”。参数模型的一个重要特点是：这一模型的知识表达形式是确定的，因此模型的规模也是确定的，不会随着训练数据的样本量而发生改变。

参数模型的优势在于其对知识的抽象能力，但这一方法也存在一些问题。例如，当先验知识不足时，对模型形式的设计可能是不合理的；其次，当训练数据较丰富时，我们希望模型的规模可以相应增大，以描述更多细节，而参数模型不具有这种扩展能力；最后，训练数据在不同区域分布可能是不均衡的，我们希望在训练数据较多的区域有细节的模型，但参数模型通常是全局的，难以根据数据实际分布情况进行调节。总而言之，在一些学习任务中，我们希望模型的形式和复杂度由训练数据本身来确定，而不是预先设计的固定形式。这种由数据驱动的模型称为“非参数模型”（No-Parametric Model）。

本章我们将讨论非参数模型的基本概念，并集中讨论两种非参数模型：高斯过程和狄利克雷过程。这两种模型都基于概率图模型，通过设计无限维

空间上的先验概率，实现依训练数据对模型复杂度进行调整，同时保证这种调整不因过度依赖数据而产生太大偏差。

8.1 简单非参数模型

直观地说，非参数模型是不被参数形式限制的模型。例如当我们统计一个一维数据的分布规律时，经常会假设一个高斯分布，通过拟合这一分布的均值和方差对数据的实际分布进行近似。这一方法的优点在于引入了一个高斯假设，因而只要少数几个样本点就可以得到一个很好的估计，但当实际数据本身并不是高斯分布时，由于模型本身形式已经固定（高斯的），因此再多训练数据也无法提高模型的描述能力。换一个思路，我们对分布不做先验假设，而是在数轴上设计若干个区间，并统计在这些区间上的数据分布比例，形成如图 8.1 (a) 所示的直方图。当训练数据较少时，直方图模型给出的概率显然是粗糙的，但当数据量增多时，通过对区间进行细致划分，直方图模型可以完美逼近真实数据分布。注意，直方图模型的复杂度是随着数据量增长而增加的：更多数据支持更细致的区间划分，使得模型的规模增大，从而对数据分布给出更细致的描述。

K近邻（K-Nearest Neighbour, KNN）是另一种用于分类的非参数模型。这一方法的基本假设是数据空间的分类是有连续性的，因而一个待考察点周围的点应具有相似的分类。因此，可以通过考察目标点周围的训练样本所属的类别，通过投票等方式来决定待考察目标点的类别。在KNN中，选择和目标点最近的K个训练样，用这些样本的分类来判断目标点的分类，如图 8.1 (b) 所示。和典型的参数模型（如GMM）相比，KNN不对数据分布做任何假设。这使得该方法在训练数据较少时性能较低，但当数据量增大，可以充满测试数据所在的空间时，KNN可能会显著超过任何一种参数模型。这是因为所有参数模型都对数据的性质做了某些假设（高斯或线性等），这些假设在数据量有限时是一种有价值的先验，但当数据足够多时，将成为模型表达能力的限制。

另一种典型的非参数模型是支持向量机（SVM）。SVM在再生核希尔伯特空间设计一个线性分类器，该分类器不是以参数形式设定的，而是通过保存训练数据中的支持向量来实现。基于这些支持向量，计算未知数据到这些支持向量的距离（用核函数表示），以这些距离为权重对每个支持向量的分类标记进行平均，即得到未知数据的分类标记。和KNN类似，当训练数据较多时，特别是分类面处的数据较多时，SVM中包含的支持向量数会显著增

加。增大的支持向量集合可以提供更细节的分类面，从而提高模型的分类能力。

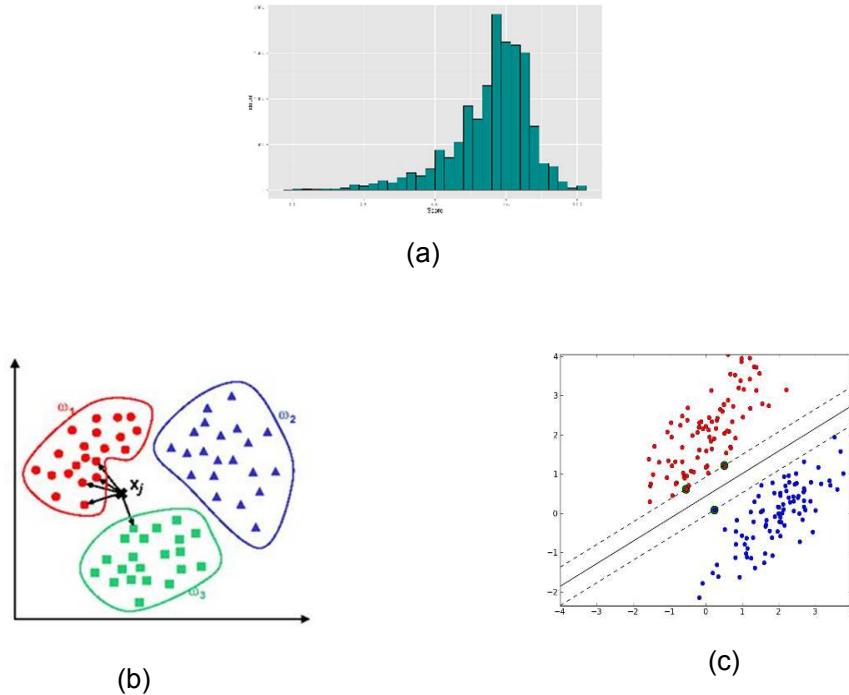


Fig. 8.1 几种典型的非参数模型。(a): 直方图模型; (b): KNN 模型; (c): SVM模型。

通过上述三个典型的非参数模型，我们看到这类模型具有如下特征：(1) 对数据的分布状态不做过强的假设，让数据自己表达自身的分布情况和分类情况；(2) 保留全部或部分训练数据进行推理，因此模型规模随训练数据的增长而增长。这两点显然是相关的，正因为不做过强的假设，因此需要保留众多训练数据来进行推理。

如果将参数模型方法视为抽象学习，则非参数模型更接近联想学习；前者可以看作是对知识的抽象，后者更多是对经验的记忆。和参数模型相比，非参数模型多用在相对复杂的任务中。在这些任务中，人们对任务中的数据分布情况所知有限，无法设计合理的参数形式，但训练数据量相对较大。这时可利用非参数模型，将这些数据记录下来，用联想方式进行推理。

非参数模型并非没有参数，也并非没有受限形式。例如SVM，对数据的表达能力依赖核函数的选择，也依赖目标函数中分类错误的权重参数。非参

数模型是有参数的，只不过很大一部分参数由训练数据决定，如SVM中的支持向量。同时，一个模型也未必是全部非参数的，可以是参数模型和非参数模型的混合。SVM即是这种混合模型，这一模型在核函数映射部分是参数的，但在支持向量选择时是非参数的。

朴素的非参数模型（如直方图或KNN）只能依靠训练数据的增长来提高预测能力。SVM将参数模型和非参数模型结合在一起，因而不再单纯依靠数据覆盖度。事实上，非参数模型在现代机器学习中的意义不在于取代参数模型做简单的联想学习，而在于帮助参数模型打破形式化限制，使得当数据量增长的时候可以自动调整模型复杂度，以提高模型的精度。贝叶斯方法提供了一种灵活的学习和推理框架，在这一框架中可以通过设计非参数的先验概率来打破传统贝叶斯模型的固化形式，实现模型复杂度随数据的自动调整。这一方法称为贝叶斯非参数模型方法（Bayesian Non-Parametric），是本章要介绍的重点内容。

下面我们将讨论两种贝叶斯非参数模型，一种用于预测任务，另一种用于聚类任务。对预测任务，传统贝叶斯参数模型方法定义一个参数结构（如线性回归），并对参数赋以一个高斯先验，因此所有先验都是基于该参数结构所代表的映射函数集的先验。高斯过程定义了另一种先验，这一先验不是基于某种模型形式的参数上的先验，而是某类映射函数的先验[9]。这类映射函数只需符合非常宽泛的假设，因而比传统参数形式具有更广泛的覆盖性。高斯过程在第5章中已经有讨论，当时我们关注的是高斯过程中的核函数意义，本章我们将着重讨论高斯过程的非参数性质。

对于聚类任务，非参数模型将帮助我们解决聚类中的一个重要问题，即聚类数的不确定性。绝大多数聚类算法都需要事先定义好聚类数，或设定某些相关参数（如AF中相关矩阵对角值的相对大小，DBSCAN中的到达半径）。事实上，我们应该让数据自己决定可以聚成几类，特别是当数据量较大时，算法应该有能力聚出更多类。狄利克雷过程通过对所有可能的聚类方式赋予一个先验概率来解决这一问题[13]。通过给定这一先验，应用概率图模型的推理方法即可得到数据应该如何聚类的后验概率。我们从高斯过程开始讨论。

8.2 高斯过程

第5章中我们已经讨论过高斯过程。本节对这一方法做一回顾，并着重强调其非参数模型的意义。

8.2.1 高斯过程

考察如下线性高斯模型

$$y = \mathbf{x}^T \mathbf{w}; \quad \mathbf{w} \sim N(\mathbf{0}, \alpha^{-1} \mathbf{I}).$$

因为 \mathbf{w} 具有随机性，因而由 \mathbf{x} 到 y 的映射函数 $y(\mathbf{x})$ 是随机的。我们可以用另一种非参数形式来表达这种随机性。考虑任意一个点集 $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]$ 和对应的预测 $\mathbf{y} = [y_1, \dots, y_N]^T$ ，由于 \mathbf{w} 是高斯的，因此 \mathbf{y} 也是一个高斯分布。且有：

$$\begin{aligned}\mathbb{E}(\mathbf{y}) &= \mathbf{X}^T \mathbb{E}(\mathbf{w}) = \mathbf{0}, \\ \text{cov}(\mathbf{y}) &= \mathbb{E}(\mathbf{y} \cdot \mathbf{y}^T) = \mathbf{X}^T \mathbb{E}(\mathbf{w} \cdot \mathbf{w}) \mathbf{X} = \alpha^{-1} \mathbf{X}^T \mathbf{X} = \mathbf{K},\end{aligned}$$

其中 \mathbf{K} 为Gram矩阵，且：

$$K_{ij} = k(\mathbf{x}_i, \mathbf{x}_j) = \alpha^{-1} \mathbf{x}_i \cdot \mathbf{x}_j.$$

从 K 的表达式我们可以看出，任意两个样本点 \mathbf{x}_i 和 \mathbf{x}_j 的预测值 y_i 和 y_j 是相关的，其协方差取决于 \mathbf{x}_i 和 \mathbf{x}_j 之间以 $k(\mathbf{x}_i, \mathbf{x}_j)$ 描述的“距离”：这两个样本离得越近，他们对应的预测点 $y(\mathbf{x}_i)$ 和 $y(\mathbf{x}_j)$ 越相关。

通过上述讨论，我们看到一个以随机变量 \mathbf{w} 为参数的随机函数 $y(\mathbf{x})$ 可以表达为这一函数在任意点集 X 上取值的分布规律。如果 \mathbf{w} 为高斯分布，则对应的随机函数在任意点集上的取值亦符合高斯分布，且这一分布的性质由协方差函数 $k(\mathbf{x}_i, \mathbf{x}_j)$ 描述。注意上述分布性质在任意点集上都成立，这事实上定义了一个随机过程，称为高斯过程 [16, 9]。

具体而言，高斯过程是定义在映射函数 $y(\mathbf{x})$ 上的一个概率分布（即映射函数的概率分布），该概率分布使得在任意有限点集 $\mathbf{x}_1, \dots, \mathbf{x}_N$ 处计算的 $y(\mathbf{x})$ 服从如下多元高斯分布：

$$\begin{bmatrix} y(\mathbf{x}_1) \\ \vdots \\ y(\mathbf{x}_N) \end{bmatrix} \sim N\left(\begin{bmatrix} m(\mathbf{x}_1) \\ \vdots \\ m(\mathbf{x}_N) \end{bmatrix}, \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_1) & \cdots & k(\mathbf{x}_1, \mathbf{x}_N) \\ \vdots & \ddots & \vdots \\ k(\mathbf{x}_N, \mathbf{x}_1) & \cdots & k(\mathbf{x}_N, \mathbf{x}_N) \end{bmatrix}\right),$$

其中 $m(\cdot)$ 代表随机函数的均值函数， $k(\cdot, \cdot)$ 代表随机函数的协方差函数。记上述高斯过程为 $y(\cdot) \sim G(m(\cdot), k(\cdot, \cdot))$ 。

高斯过程本质上是一个随机函数，描述函数的不确定性。然而，这一随机函数的变量有无限维（每一个 \mathbf{x}_i 看作一维）。为了描述这一随机函数，

我们考察其中任意有限维空间上的取值并确认其具有一致的高斯分布特性，即不论 $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ 如何选择，其所对应的 $\{y(\mathbf{x}_1), \dots, y(\mathbf{x}_N)\}$ 都应满足由均值函数 $m(\cdot)$ 和协方差函数 $k(\cdot, \cdot)$ 定义的多元高斯分布。一致性是所有随机过程的必要条件：对任意一个随机过程，其任意有限个采样集上的函数取值 $\{y(\mathbf{x}_1), \dots, y(\mathbf{x}_N)\}$ 都一致地服从某一特定的联合概率。

在前述线性回归模型的例子中，对应的协方差函数 $k(\mathbf{x}_j, \mathbf{x}_j)$ 为 $\alpha^{-1} \mathbf{x}_j \cdot \mathbf{x}_j$ 。事实上，如果我们将模型取为更复杂的形式，如 $y(\mathbf{x}) = \mathbf{w} \cdot \phi(\mathbf{x})$ ，其中 ϕ 为映射函数，则有 $k(\mathbf{x}_i, \mathbf{x}_j) = \alpha^{-1} \phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j)$ 。在第5章中讲过，我们可以直接定义 $k(\mathbf{x}_i, \mathbf{x}_j)$ ，使之对应复杂的特征映射，实现更复杂的相关性建模（如在原始空间中不满足高斯过程的任务）。这事实上即是我们在第5章中所讨论的核函数方法。进一步，我们可以不关心 $y(\mathbf{x})$ 的具体形式，只需定义 $m(\cdot)$ 和 $k(\cdot, \cdot)$ 即可完整定义一个高斯过程。这意味着高斯过程并不局限于一个明确定义的预测函数，它是由 $m(\cdot)$ 和 $k(\cdot, \cdot)$ 定义的非常广泛的一类随机函数。一般取 $m(\cdot) = 0$ ，这时高斯过程由协方差函数 $k(\cdot, \cdot)$ 唯一确定。

在讨论高斯过程的应用之前，我们首先对高斯过程有个直观印象。注意高斯过程是函数的概率分布，或随机函数，其每一个采样是一个确定的函数。基于高斯过程的定义，我们可以通过采样得到这些函数。首先确定协方差函数 $k(\cdot, \cdot)$ ，然后确定若干个函数取值点 X ，高斯过程保证在这些点上的取值 \mathbf{y} 符合高斯分布，其协方差矩阵由 $k(\cdot, \cdot)$ 确定。由此，对高斯过程的采样转化为对 \mathbf{y} 的采样。由于 $p(\mathbf{y})$ 已知，原则上这一采样不存在困难。一种比较简单的方式是利用高斯过程的性质，从 y_1 开始，依次对 y_2, y_3, \dots 采样。当对 y_i 进行采样时，将既有采样值 $\{y_1, y_2, \dots, y_{i-1}\}$ 作为条件，即依 $p(y_i | y_1, \dots, y_{i-1})$ 进行采样。由于 $p(y_1, \dots, y_i)$ 是高斯的， $p(y_i | y_1, \dots, y_{i-1})$ 也是一个高斯分布，因此采样很容易实现。

图8.2给出从两个具有不同协方差函数的高斯过程采样得到的两簇函数。可见，不同协方差函数决定了采样函数的性质。一般来说，协方差越大，则不同样本间的相关性越强，函数取值越倾向于一致，对应的函数曲线越平坦。反之，协方差越小，相邻点取值间的相关性越弱，对应的函数曲线起伏越大。

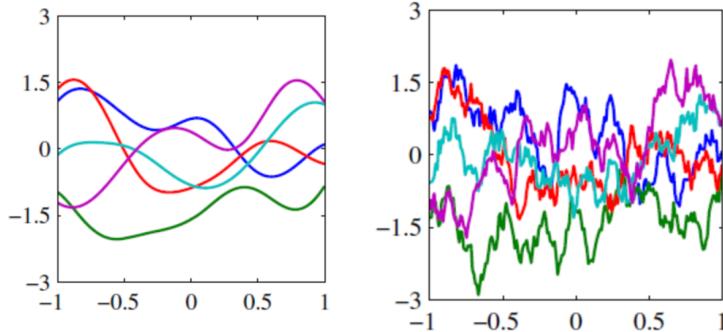


Fig. 8.2 基于两个协方差函数的高斯过程采样出的两簇函数。图片来源于 [1], Figure 6.4。

8.2.2 高斯过程回归

在上一小节中，我们提到高斯过程描述了定义在映射函数上的概率分布，即随机函数。在本小节中，我们将把这一随机函数作为先验应用到贝叶斯回归分析中。

8.2.2.1 贝叶斯线性回归

首先简要回顾贝叶斯线性回归模型。该模型假设数据点 \mathbf{x} 和目标值 t 之间具有如下关系：

$$\mathbf{t} = \mathbf{w} \cdot \mathbf{x} + \boldsymbol{\epsilon} \quad (8.1)$$

其中 \mathbf{w} 是模型参数，该参数是一个高斯随机变量，满足：

$$\mathbf{w} \sim N(\mathbf{0}, \alpha^{-1} \mathbf{I}).$$

$\boldsymbol{\epsilon}$ 是一个高斯噪声，满足：

$$\boldsymbol{\epsilon} \sim N(0, \beta^{-1}).$$

设训练数据集 $\{(\mathbf{x}_i, t_i); i = 1, \dots, N\}$ 。记 $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]$ ，对应的目标为 $\mathbf{t} = [t_1, t_2, \dots, t_N]^T$ 。利用贝叶斯公式，可以得到参数 \mathbf{w} 的后验概率形式为一个高斯分布：

$$\mathbf{w}|\mathbf{X}, \mathbf{t} \sim N(\mathbf{m}_N, \mathbf{S}_N),$$

其中，

$$\mathbf{S}_N^{-1} = \alpha \mathbf{I} + \beta \mathbf{X} \mathbf{X}^T,$$

$$\mathbf{m}_N = \beta \mathbf{S}_N \mathbf{X} \mathbf{t}.$$

对任意一个测试数据 \mathbf{x}_* ，可以计算其输出 t_* 的概率分布。因为 \mathbf{w} 具有随机性，因此需要对所有可能的 \mathbf{w} 做边缘化：

$$p(t_* | \mathbf{x}_*, \mathbf{t}, \mathbf{X}) = \int_{\mathbf{w}} p(t_* | \mathbf{x}_*, \mathbf{w}) p(\mathbf{w} | \mathbf{t}, \mathbf{X}).$$

注意上式右侧积分中两个概率分布都是高斯的，因此 t_* 的分布也是一个高斯分布：

$$t_* | \mathbf{x}_*, \mathbf{X}, \mathbf{t} \sim N(\mathbf{m}_N \cdot \mathbf{x}_*, \sigma_N^2(\mathbf{x}_*)),$$

其中

$$\sigma_N^2(\mathbf{x}_*) = \beta^{-1} + \mathbf{x}_*^T \mathbf{S}_N \mathbf{x}_*.$$

上述贝叶斯线性回归是典型的参数模型：设计一个线性模型形式，定义模型中每个变量的随机性，基于一个训练集，得到参数的后验概率，由此完成模型训练。训练完成后，得到的模型即是对训练数据中知识的抽象，基于该模型即可进行推理，原来的训练数据可以丢弃。注意，这一知识抽象基于预先设计的模型形式，这一形式不会因训练数据的多少而改变。

8.2.2.2 高斯过程回归建模

现在我们从另一个角度来理解贝叶斯线性回归。由上节对高斯过程的讨论可知，式 8.1 中的回归函数 $y = \mathbf{w} \cdot \mathbf{x}$ 是一个高斯过程，因而对训练数据中的样本点 $\{\mathbf{x}_i\}$ ，其预测值 $\{y(\mathbf{x}_i)\}$ 的联合分布是一个高斯分布 $G(\mathbf{0}, \mathbf{K})$ ，其中 $\mathbf{K} = \alpha^{-1} \mathbf{X}^T \mathbf{X}$ 。加入一个高斯噪声 ε 后， $t(\mathbf{x})$ 依然是一个高斯过程。对训练样本集 \mathbf{X} 及其对应的观测值 \mathbf{t} ，容易验证 \mathbf{t} 是一个多元高斯变量，且：

$$\mathbb{E}(\mathbf{t}) = \mathbf{0},$$

$$\text{cov}(\mathbf{t}) = \mathbf{K} + \beta^{-1} \mathbf{I}.$$

和 $y(\mathbf{x})$ 相比, $t(\mathbf{x})$ 是一个协方差更大的高斯过程, 但这一协方差的增加仅表现在对角元素上, 说明加入噪声仅增加了预测时的不确定性, 但不改变不同样本点间目标变量的相关性。

特别重要的是, 上式中对 \mathbf{K} 的定义形式来源于式8.1中的线性形式 $\mathbf{w} \cdot \mathbf{x}$ 以及对 \mathbf{w} 的先验概率。事实上, 我们可以抛开这些限制, 让 \mathbf{K} 自由定义一个高斯过程 $y(\mathbf{x})$, 用预测函数本身的随机性(更确切地说, 高斯随机性)来代替基于先验概率和模型形式衍生出的随机性, 这将极大摆脱线性模型形式上的束缚。

8.2.2.3 高斯过程回归预测

因为高斯过程的性质由其采样点上取值的分布特性(联合高斯分布)决定, 因此对新采样点的预测也由训练数据的采样点取值决定。具体而言, 如果给定训练数据集 $\{(\mathbf{x}_i, t_i); i = 1, \dots, N\}$, 对一个测试数据 \mathbf{x}_* , 其预测值为 t_* 。依高斯过程定义, 联合向量 $[\mathbf{t}^T \ t]$ 符合如下高斯分布:

$$\begin{bmatrix} \mathbf{t} \\ t_* \end{bmatrix} | \mathbf{x}_1, \dots, \mathbf{x}_N, \mathbf{x}_* \sim N(\mathbf{0}, \begin{bmatrix} \mathbf{K} + \beta^{-1} \mathbf{I} & \mathbf{k} \\ \mathbf{k}^T & c + \beta^{-1} \end{bmatrix})$$

其中 $\mathbf{K} = \text{cov}(\mathbf{y})$, $\mathbf{k} \in R^{N \times 1}$ 的元素为:

$$k_i = \alpha^{-1} \mathbf{x}_i \cdot \mathbf{x}_*, \quad i = 1, 2, \dots, N$$

$$c = \alpha^{-1} \mathbf{x}_* \cdot \mathbf{x}_*.$$

由这一联合高斯分布形式可求 t_* 的后验概率如下:

$$t_* | \mathbf{t}, \mathbf{x}_1, \dots, \mathbf{x}_N, \mathbf{x}_* \sim N(m(\mathbf{x}_{N+1}), \sigma^2(\mathbf{x}_*)) \quad (8.2)$$

其中:

$$m(\mathbf{x}_{N+1}) = \mathbf{k}^T (\mathbf{K} + \beta^{-1} \mathbf{I})^{-1} \mathbf{t},$$

$$\sigma^2(\mathbf{x}_*) = c - \mathbf{k}^T (\mathbf{K} + \beta^{-1} \mathbf{I})^{-1} \mathbf{k}.$$

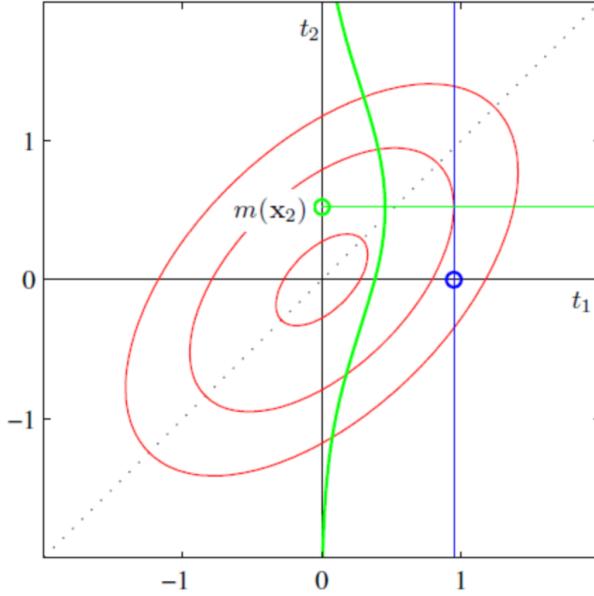


Fig. 8.3 基于高斯过程回归进行预测的后验概率分布。 (\mathbf{x}_1, t_1) 为训练数据， (\mathbf{x}_2) 为预测数据， t_2 为预测数据取值。红色等概率曲线表示 (t_1, t_2) 的联合概率分布，绿色曲线表示给定 t_1 后 t_2 的后验概率分布。图片来源于 [1], Figure 6.7.

图 8.3 给出基于高斯过程回归的预测模型，其中 t_1 为训练数据 \mathbf{x}_1 的目标， t_2 为测试数据 \mathbf{x}_2 的目标。依高斯过程，我们知道 (t_1, t_2) 的联合分布 $p(t_1, t_2)$ 服从二元高斯分布，如图中红色椭圆所示的等概率曲线。在给定具体的 t_1 值（对应于图中蓝色圈）后，依式 8.2 可知， t_2 的后验概率 $p(t_2|t_1)$ 服从另一高斯分布，如图中绿线所示，其中分布的均值 $m(\mathbf{x}_2)$ （即出现概率最大的 t_2 的取值）为红色等高线 $p(t_1, t_2)$ 与取值为 t_1 的直线相切点对应的 t_2 的值。

图 8.4 给出预测的置信度，其中绿色曲线表示数据的真实生成函数，蓝色点为基于这一函数生成数据后在目标值上加入高斯噪声得到的训练数据。红色曲线表示以这些训练数据得到的高斯过程回归模型的均值函数 $m(\mathbf{x})$ ，阴影部分的宽度表示每个取值点 \mathbf{x} 上的预测方差 $\pm 2\sigma(\mathbf{x})$ 。可以看到，高斯过程回归的均值函数与真实生成函数近似，且在训练数据比较多的地方，预测的方差更小，置信度更高。

仔细考察上述基于高斯过程的预测模型，可以发现这一方法与前面所述的贝叶斯线性回归有显著区别。首先，我们并未定义 $y(\mathbf{x})$ 的具体形式，只是确认了 $y(\mathbf{x})$ 是一个以 $k(\cdot, \cdot)$ 为协方差函数的高斯过程；第二，在对测试样本进

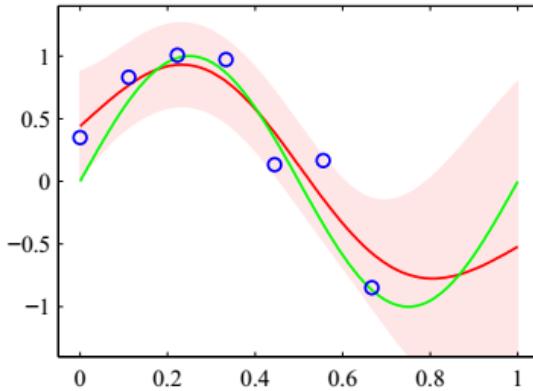


Fig. 8.4 高斯过程回归的置信区间，其中绿线为真实映射函数，蓝点为从这一映射函数采样并加入高斯噪声后的训练数据，红色曲线为后验概率的均值函数，阴影部分的宽度表示预测方差 $\pm 2\sigma(\mathbf{x})$ 。图片来源于 [1], Figure 6.8.

行预测时，高斯过程回归利用了训练集中的所有数据。这意味着训练数据越多，模型的复杂度越高。因此，高斯过程回归是一个无参数模型。

事实上，我们可以将任何模型设计过程认为是一种先验预设过程，从而确定一个有效函数空间，并在此基础上进行训练和推理。例如线性回归模型确定了预测函数只能是线性的，且该函数是确定的；贝叶斯线性回归允许预测函数存在随机性，但这一预测函数必须是线性的。高斯过程提供了另外一种先验，这种先验允许所有符合高斯分布特性的预测函数参与，并为这些函数赋予不同的先验概率。这些函数有可能是线性的，也可能是非线性的，有可能是局部的，也有可能是全局的。高斯过程给这些广泛的可选函数赋予如下先验，即依这一先验，对任意有限样本点，这些函数依概率在这些样本点上进行取值，这些取值一致地符合联合高斯分布。基于这一先验分布，给定训练数据后，即可得到在这些函数上的后验概率，并在预测时基于这一后验概率对所有这些函数进行边缘化。乍一看这似乎是不可能的，因为这一方法包含了无穷多个形式未知的预测函数，难以对它们进行边缘化。然而，我们可以把函数的概率转化为特定样本取值上的联合概率，因为这些样本点（训练样本和测试样本）是有限的，因而可实现前面所述的预测过程。

8.2.3 高斯过程用于分类任务

高斯过程的本质是提供一族函数的先验概率，基于这一先验概率，可实现对任何预测任务的非参数贝叶斯学习。前面介绍的高斯过程回归是一个典型的例子，同样的方法也可用于分类任务。在分类任务中，预测函数为

$$y = \sigma(\mathbf{w} \cdot \mathbf{x}),$$

其中 σ 为一个 Sigmoid 函数。和回归任务类似，我们希望高斯过程给预测函数 $y(\mathbf{x})$ 赋予一个先验概率，使得分类任务摆脱线性形式的束缚。然而，这一思路在实现时遇到一个问题，即 y 的取值是受限的，只能取值在 $[0, 1]$ 区间，而高斯过程假设采样点的取值是高斯的，没有值域上的限制。因此，直接在 $y(\mathbf{x})$ 上设计高斯过程先验并不合理。一个解决方法是将分类任务的预测函数分成两部分：

$$y = \sigma(a(\mathbf{x})),$$

并在 $a(\mathbf{x})$ 上设计高斯过程先验。具体来说，对任何一组数据 \mathbf{X} ，其取值 $a(\mathbf{X})$ 应具有如下高斯形式：

$$[a_1, \dots, a_N] \sim N(\mathbf{0}, \mathbf{K}).$$

预测时，测试数据 \mathbf{x}_* 的预测值 t_* 的后验预测分布形式为：

$$p(t_* | t_1, \dots, t_N) = \int_{a_*} p(t_* | a_*) p(a_* | t_1, \dots, t_N) da_*.$$

上式中后验概率部分 $p(a_* | t_1, \dots, t_N)$ 无法直接求出，一般通过变分推断或者 Laplace 近似给出近似解。关于变分法，可参考第 6 章；关于 Laplace 近似，可参考 [1] 第六章 6.4.6 节。

8.3 狄利克雷过程

高斯过程 $G(m, k)$ 定义了一个在函数上的先验概率，这一先验概率用来对预测任务进行建模，包括回归任务和分类任务，这些任务都属于监督学习范畴。对于非监督学习，特别是聚类任务，我们需要定义另一种先验。

在聚类任务中，我们一般会定义一个贝叶斯生成模型，并确定模型中的聚类数 K ，对该模型参数进行优化使其对训练数据的生成概率最大。这一方式显然是参数的。如果我们不是定义某一个聚类模型，而是定义一个在所有可能聚类方式上的先验概率，并基于训练数据得到在每个聚类方式上的后验，则可让数据自动选择出合理的模型复杂度，实现非参数聚类。狄利克雷过程正是一种定义在所有聚类方式上的先验概率。所谓聚类方式，是指对 N 个数据样本的任何一种可能的分组设计。

8.3.1 回顾高斯混合模型

一个高斯混合模型（Gaussian Mixture Model, GMM）是 K 个高斯概率模型的叠加。对任意一个数据集 $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ ，基于 GMM 的联合概率密度函数如下：

$$\ln p(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N) = \sum_{i=1}^N \ln \sum_{k=1}^K \pi_k N(\mathbf{x}_i | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k),$$

其中参数 π_k 为第 k 个高斯成分的权重，满足：

$$\sum_{k=1}^K \pi_k = 1, \quad 0 \leq \pi_k \leq 1.$$

这一模型中包含如下参数：每个高斯成分的权重 $\boldsymbol{\pi} = \{\pi_k\}$ 和每个高斯成分的参数 $\boldsymbol{\theta}_k = \{\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$ 。贝叶斯方法将这些参数视为随机变量。我们假设 $\boldsymbol{\pi}$ 由一个以 $\boldsymbol{\alpha}$ 为参数的狄利克雷分布 $Dir(\boldsymbol{\alpha})$ 得到：

$$p(\boldsymbol{\pi}) = C(\boldsymbol{\alpha}) \prod_{k=1}^K \pi_k^{\alpha_k - 1},$$

其中 $C(\boldsymbol{\alpha})$ 为归一化系数。进一步假设每个高斯成分的参数 $\boldsymbol{\theta}_k$ 由一个连续分布 H 得到。基于上述假设，贝叶斯高斯混合模型可表述为如图 8.5 所示的生成模型，并可形式化为如下过程：

$$\boldsymbol{\theta}_k^* \sim H \quad \text{for } k = 1, 2, \dots, K \quad (8.3)$$

$$\boldsymbol{\pi} \sim Dir(\boldsymbol{\alpha}) \quad (8.4)$$

$$z_i | \boldsymbol{\pi} \sim Multi(\boldsymbol{\pi}) \quad (8.5)$$

$$\mathbf{x}_i | \boldsymbol{\theta}_{z_i}^* \sim N(\boldsymbol{\theta}_{z_i}^*), \quad (8.6)$$

其中 $Multi(\boldsymbol{\pi})$ 是以 $\boldsymbol{\pi}$ 为参数的多项式分布。

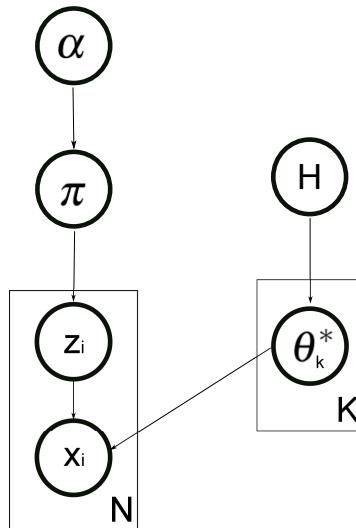


Fig. 8.5 贝叶斯高斯混合模型的有向图模型表示。首先由 H 生成 K 个高斯成分的参数 $\{\boldsymbol{\theta}_k^*\}$ ，并基于 $Dir(\boldsymbol{\alpha})$ 生成高斯成分的权重参数 $\boldsymbol{\pi}$ 。每一个数据样本 \mathbf{x}_i ，首先由 $Multi(\boldsymbol{\pi})$ 生成高斯成分指示变量 z_i ，再由 $N(\boldsymbol{\theta}_{z_i}^*)$ 生成 \mathbf{x}_i 。

与高斯混合模型类似的是 Latent Dirichlet Allocation (LDA) 主题模型 [?]。在这一模型中，数据是离散的且由一个多项式分布生成，如图 8.6 所示。LDA 模型被广泛应用在文档主题建模任务中。注意 LDA 中每篇文档都有一个独立的主题分布概率，这一分布概率由一个狄利克雷分布采样得到。

不论是 GMM 还是 LDA，都需要设定模型中高斯成分或主题的个数。实际应用中，我们很难判断数据应分成多少类或多少个主题；另外，GMM 和 LDA 中的高斯成分或主题数一旦确定后即很难改变，不易随数据规模增大而增加类别或主题。我们希望得到一个模型，它能自动地根据训练数据的多少选取合理的类别数或主题个数，并随数据量的增加对聚类数做合理调整。一种思路是对数据集的不同聚类方式赋予一个先验概率，从而可以

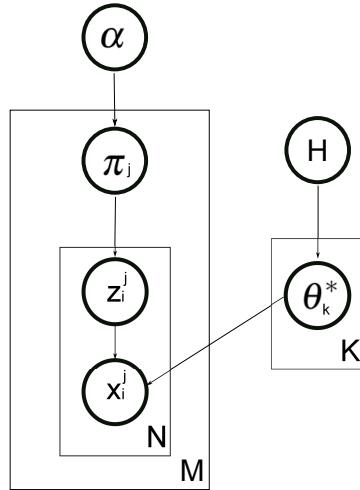


Fig. 8.6 LDA主题模型的有向图模型表示。对第 j 篇文档由狄利克雷分布生成一个主题分布概率 π_j , 对该文档中的每个词, 首先由 π_j 生成一个主题变量 z_i^j , 基于该主题变量, 由 $Multi(\theta_{z_i^j}^*)$ 生成词 x_i^j 。主题 θ_k^* 由一个以 H 为基础变量的狄利克雷分布生成。

利用概率图模型的推理方法得到聚类方式的后验概率。下面将要介绍的狄利克雷过程 (Dirichlet Process, DP) 即是这种先验概率。

8.3.2 中国餐馆问题

我们的目的是对 N 个数据样本的所有可能聚类方式赋予一个先验概率, 从而可设计一个贝叶斯模型, 推理得到聚类方式的后验概率。得到这一后验概率后, 我们可以: (1) 基于最大后验准则, 得到最合理的聚类方式; (2) 对任何一个测试数据样本, 可以基于该后验概率进行贝叶斯推理, 计算该数据样本的生成概率。

中国餐馆问题 (CRP) 给出了对这一先验概率的直观设计方法。CRP可想象成如下过程: 假设一个中国餐馆有无限张桌子, 每张桌子提供不同的菜, 记为 θ_k^* 。顾客依次进入该餐馆; 每个客人进入后, 可选择和其他已经就座的顾客同坐, 也可以选择另开一桌。假设第 N 个顾客到来的时候, 已经有 K 张桌子上有顾客了, 这些桌子上分别坐了 n_1, n_2, \dots, n_K 个顾客。那么第 N 个顾客将以概率 $\frac{n_k}{\alpha+N-1}$ 坐在第 k 张桌子上, 或以概率 $\frac{\alpha}{\alpha+N-1}$ 选择一张新的桌子。

坐下。这样在第 N 个顾客坐定之后，这 N 个顾客聚成为 K 类或 $K+1$ 类。图 8.7 给出了一个CRP过程的实例。

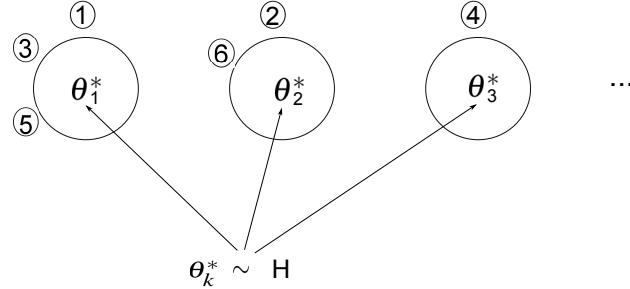


Fig. 8.7 一个CRP过程的实例。顾客1、2、4各选择了一个新桌，其对应的概率分别为1、 $\frac{\alpha}{\alpha+1}$ 、 $\frac{\alpha}{\alpha+3}$ ；顾客3和5选择和顾客1坐到一桌，对应的概率分别为 $\frac{1}{\alpha+2}$ 、 $\frac{2}{\alpha+4}$ ；顾客6选择和顾客2一起坐在第二桌，其对应的概率为 $\frac{1}{\alpha+5}$ 。每一桌的参数由分布 H 随机生成。

设第 N 个顾客坐到了第 c_N 桌，则上述过程可写成如下公式：

$$c_N | c_{1,2,\dots,N-1} = \begin{cases} k & \text{with probability } \frac{n_k}{\alpha+N-1} \\ K+1 & \text{with probability } \frac{\alpha}{\alpha+N-1} \end{cases}$$

上式说明CRP过程具有聚类效应，即当某一桌上的人越多的时候，下一个顾客越倾向于这一桌。基于上述公式，我们可以得到：

$$\begin{aligned} p(c_1, c_2, \dots, c_N) &= p(c_1)p(c_2|c_1)\dots p(c_n|c_1, c_2, \dots, c_{N-1}) \\ &= \frac{\alpha^K \prod_{k=1}^K (n_k - 1)!}{\alpha(1+\alpha)\dots(N-1+\alpha)}. \end{aligned}$$

上式说明，对 N 个顾客的CRP过程，每一位顾客坐哪一桌的联合概率只与每桌的顾客数相关，与顾客的顺序和桌子的顺序都是无关的。换句话说，这一概率表示的是将无差别的客户进行无差别聚类后，每种聚类方式的概率分布。事实上提供了一种在聚类方式上的先验分布，基于这一先验分布和观测数据，可以推理得到这些聚类方式上的后验分布。

值得说明的是，上述CRP过程提供的先验分布是无界但有限的。无界意味着这一分布可以为无限多的数据提供聚类先验，有限是因为对一个特定数据集，样本数总是有限的，CRP只需对有限数据的有限聚类方式提供先验。可以计算CRP对 N 个样本的聚类数的期望值为：

$$\mathbb{E}[K|N] = \sum_{i=1}^N \frac{\alpha}{\alpha+i-1} \approx \alpha \log\left(1 + \frac{n}{\alpha}\right).$$

可见，CRP倾向的聚类方式，既非过于分散（如每个样本自成一类），也非过于聚拢（如所有类自成一类），而是一个与样本数成对数关系的适中聚类方式。随着 N 的增长，CRP先验给出的预期聚类数也会跟着增长，但增长速度与数据增长是对数关系。

基于CRP给出的先验，可以得到如下描述聚类任务的生成模型：设对 $i-1$ 个样本点完成聚类后，已经有 K 类存在，则对第*i*个样本 \mathbf{x}_i ，以 $\frac{n_k}{\alpha+i-1}$ 为概率选择第*k*个类，依该类的参数 $\boldsymbol{\theta}_k^*$ 得到一个数据生成模型 $F(\boldsymbol{\theta}_k^*)$ ，由此生成 x_i ；或以 $\frac{\alpha}{\alpha+i-1}$ 为概率生成一个新的类，由 H 随机得到该类的参数 $\boldsymbol{\theta}_{K+1}^*$ ，并依数据生成模型 $F(\boldsymbol{\theta}_{K+1}^*)$ 生成 \mathbf{x}_i 。记第*i*个样本所属类别的参数为 $\boldsymbol{\theta}_i$ （不同样本 $\boldsymbol{\theta}_i$ 可能共享同一个参数 $\boldsymbol{\theta}_k^*$ ），这一过程可形式化为：

$$\boldsymbol{\theta}_i | \boldsymbol{\theta}_{1,2,\dots,i-1} \sim \frac{\alpha}{\alpha+i-1} H + \sum_{k=1}^K \frac{n_k}{\alpha+i-1} \delta_{\boldsymbol{\theta}_k^*} \quad (8.7)$$

$$\mathbf{x}_i \sim F(\boldsymbol{\theta}_i) \quad (8.8)$$

如果数据 \mathbf{x} 是连续的且生成模型 F 是高斯的，即得到一个基于无参数先验概率的贝叶斯高斯混合模型；如果数据 \mathbf{x} 是离散的且生成模型 F 是多项式分布，即得到一个基于无参数先验概率贝叶斯主题模型。基于上述生成模型，可以通过推理得到聚类形式的后验概率。基于这一后验概率，我们可以知道：(1) 数据应该聚成几类；(2) 对某一样本的生成概率。然而，由于聚类形式是组合增长的，精确推理很困难，一般采用近似推理方法，如蒙特卡洛法[7]或变分法[2]。后面我们会详细讨论基于这一无参数先验的近似推理方法。

8.3.3 狄利克雷分布及性质

通过CRP，我们设计了一个在聚类方式上的先验概率，并依此得到了后验概率的推理方法和对数据样本概率的计算方法。现在我们将CRP放到一个更通用的理论框架里讨论，说明这一方法的合理性。

首先我们讨论狄利克雷分布。一个狄利克雷分布可表示为：

$$(\pi_1, \dots, \pi_K) \sim Dir(\alpha_1, \dots, \alpha_K),$$

其中 $\alpha = (\alpha_1, \dots, \alpha_K)$ 为参数。狄利克雷分布的概率密度函数为：

$$p(\pi_1, \dots, \pi_K) = \frac{\Gamma(\sum_k \alpha_k)}{\prod_k \Gamma(\alpha_k)} \prod_{k=1}^K \pi_k^{\alpha_k - 1},$$

其中 $\Gamma(\cdot)$ 为 Gamma 函数：

$$\Gamma(z) = \int_0^\infty \frac{t^{z-1}}{e^t} dt.$$

值得注意的是， $\pi = (\pi_1, \dots, \pi_K)$ 本身是一个概率分布，并满足：

$$\sum_k \pi_k = 1; \quad \pi_k \geq 0.$$

因此， $p(\pi_1, \dots, \pi_K)$ 是一个概率分布的概率分布，或随机概率。这意味着狄利克雷分布的每个采样点是一个离散概率分布，这些采样点分散在一个受限 $K-1$ 维空间中，如图 8.8 所示。

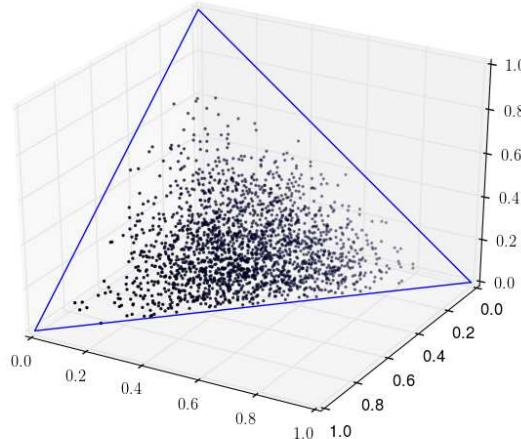


Fig. 8.8 三维空间中的Dirichlet分布 $Dir(4,4,2)$ ，样本点个数为2000。

狄利克雷分布具有交换性，即：

$$(\pi_{e(1)}, \dots, \pi_{e(K)}) \sim Dir(\alpha_{e(1)}, \dots, \alpha_{e(K)}).$$

其中 $e(\cdot)$ 是 $1, 2, \dots, K$ 上的交换函数。

狄利克雷分布具有累加性，即将该分布中的任意两维做加和，依然是一个狄利克雷分布。即如果 $(\pi_1, \dots, \pi_K) \sim Dir(\alpha_1, \dots, \alpha_K)$ ，则有：

$$(\pi_1 + \pi_2, \dots, \pi_K) \sim Dir(\alpha_1 + \alpha_2, \dots, \alpha_K).$$

写成更一般的形式，有：

$$\left(\sum_{i \in l_1} \pi_i, \dots, \sum_{i \in l_j} \pi_i \right) \sim Dir\left(\sum_{i \in l_1} \alpha_i, \dots, \sum_{i \in l_j} \alpha_i \right),$$

其中 l_1, \dots, l_j 是对 $1, 2, \dots, K$ 的一个任意划分。

最后，狄利克雷分布最有可分性，即一个狄利克雷分布可由部分狄利克雷分布嵌套实现。具体来说，如果：

$$(\pi_1, \dots, \pi_K) \sim Dir(\alpha_1, \dots, \alpha_K),$$

且：

$$(\tau_1, \tau_2) \sim Dir(\alpha_1 \beta_1, \alpha_1 \beta_2) \quad \beta_1 + \beta_2 = 1,$$

则有：

$$(\pi_1 \tau_1, \pi_1 \tau_2, \pi_2, \dots, \pi_K) \sim Dir(\alpha_1 \beta_1, \alpha_1 \beta_2, \alpha_2, \dots, \alpha_K).$$

上式可通过狄利克雷分布的概率密度形式证明。

狄利克雷分布可写成更明确的随机分布形式如下：

$$(\pi_1, \dots, \pi_K) \sim Dir(\alpha, H),$$

其中 $\alpha = \sum_i^K \alpha_i$, H 是一个在离散空间 X 上的多项式分布：

$$H = Multi\left(\frac{\alpha_1}{\alpha}, \dots, \frac{\alpha_K}{\alpha}\right).$$

可以证明，如果：

$$\pi \sim Dir(\alpha, H); \quad \mathbf{x} \sim Multi(\boldsymbol{\alpha}),$$

则有：

$$p(\mathbf{x}) = \sum_{\boldsymbol{\alpha}} p(\mathbf{x}|\boldsymbol{\alpha}) p(\boldsymbol{\alpha}|H) = H(\mathbf{x}).$$

上式说明狄利克雷分布 $Dir(\alpha, H)$ 是一个以基础分布 H 为中心的随机分布，其中 α 是控制随机性的参数，可称为中心因子（Contraction Factor）。 α 越大， π 的随机性越小，越接近 H 。

8.3.4 狄利克雷过程

现在我们设想一个 K 非常大的狄利克雷分布 $Dir(\alpha, H)$ 。依累加性，对 H 的支持空间 X 的任意划分都将是一个一致的狄利克雷分布。所谓一致，是指其基础分布都由同一个基础分布 H 衍生（累加）得到，中心因子都是同一个参数 α 。

当我们把 K 扩展到无限维，甚至 X 变成连续空间，依Kolmogorov一致性定理，狄利克雷分布 $Dir(\alpha, H)$ 被扩展成一个随机过程，通常称为狄利克雷过程，表示为 $DP(\alpha, H)$ 。由于无限维空间上的分布很难形式化表示，可以用前面所述的累加过程中的概率一致性来定义狄利克雷过程：所谓狄利克雷过程，是指一个分布在 X 上的随机分布 G ，使得对 X 的任意有限划分 (A_1, A_2, \dots, A_K) ，每个子空间 A_k 的累加概率值一致地符合如下狄利克雷分布：

$$\begin{aligned} (G(A_1), G(A_2), \dots, G(A_K)) &\sim Dir(\alpha H(A_1), \alpha H(A_2), \dots, \alpha H(A_K)) \\ &= Dir(\alpha, [H(A_1), H(A_2), \dots, H(A_K)]) \\ &= Dir(\alpha, H(A_1, A_2, \dots, A_K)), \end{aligned}$$

这时我们说 G 符合狄利克雷过程 $DP(\alpha, H)$ ，或简称DP，记为：

$$G \sim DP(\alpha, H).$$

注意上述用概率一致性来定义无限维上随机过程的方法和高斯过程的定义是一样的：在高斯过程中我们定义无限维映射函数上任意有限个样本集上的分布具有一致性（高斯分布），在狄利克雷过程中我们定义无限维分布函数上任意有限个划分上的分布具有一致性（狄利克雷分布）。Kolmogorov一致性定理保证具有上述一致性的无限维随机分布扩展为一个随机过程。

设 G 是一个DP: $G \sim DP(\alpha, H)$ ， A 是 X 的任意一个子集，则在 A 上的概率 $G(A)$ 是一个随机变量，其均值和方差为：

$$\mathbb{E}[G(A)] = H(A)$$

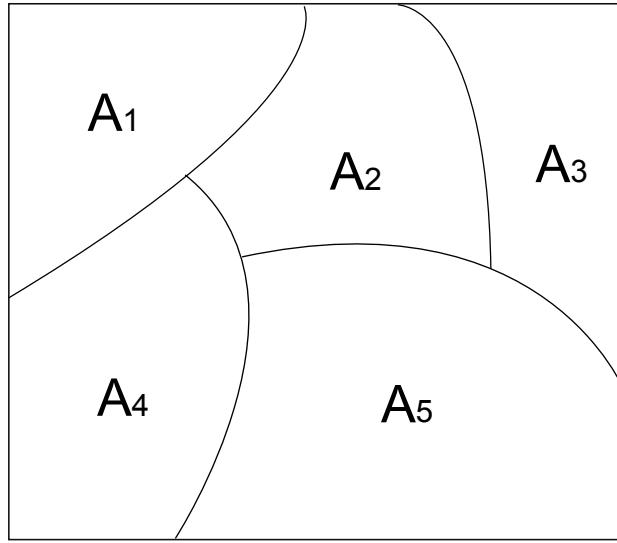


Fig. 8.9 狄利克雷过程是空间 X 上随机分布, 该分布满足如下概率一致性: 对 X 的任何划分, 其累积概率符合狄利克雷分布。图中 A_1-A_5 是 X 一个划分, $G(A_i) = \int_{\mathbf{x} \in A_i} G(\mathbf{x}) d\mathbf{x}$, 狄利克雷过程使得下式成立: $G(A_1, A_2, A_3, A_4, A_5) = Dir(\alpha H(A_1), \alpha H(A_2), \alpha H(A_3), \alpha H(A_4), \alpha H(A_5))$ 。

$$Var(G(A)) = \frac{H(A)(1 - H(A))}{\alpha + 1}.$$

通过考察 G 在 X 的任意子集上的均值和方差, 即可得到 G 在 X 上的全局随机性。

8.3.5 狄利克雷过程的表示

考虑如下一个基于狄利克雷分布的采样过程:

$$\boldsymbol{\pi} \sim Dir(\alpha, H),$$

$$z | \boldsymbol{\pi} \sim Multi(\boldsymbol{\pi})$$

可以计算 z 的边缘概率和 $\boldsymbol{\pi}$ 的后验概率如下:

$$z \sim Multi(H),$$

$$\pi|z \sim Dir(1 + \alpha, \frac{\alpha H + \delta_k(z)}{1 + \alpha}),$$

其中 $\delta_k(z)$ 为指示函数，当 z 取 k 时为 1，否则为 0。

现考察一个狄利克雷过程 $G \sim DP(\alpha, H)$ 。对任一个划分 (A_1, A_2, \dots, A_K) ，有：

$$(G(A_1), G(A_2), \dots, G(A_K)) \sim Dir(\alpha, H(A_1, A_2, \dots, A_K)).$$

依狄利克雷分布的边缘概率，有：

$$P(\boldsymbol{\theta} \in A_i) = H(A_i),$$

特别的，有：

$$P(\boldsymbol{\theta}) = \int p(\boldsymbol{\theta}|G)dG = H(\boldsymbol{\theta}). \quad (8.9)$$

依狄利克雷分布的后验概率，有：

$$(G(A_1), G(A_2), \dots, G(A_K))|\boldsymbol{\theta} \sim Dir(1 + \alpha, \frac{\alpha H(A_1, \dots, A_K) + (\delta_{\boldsymbol{\theta}}(A_1), \dots, \delta_{\boldsymbol{\theta}}(A_K))}{1 + \alpha}).$$

由于上式对任何一个划分都成立，依DP的定义，可知 $G|\boldsymbol{\theta}$ 也是一个狄利克雷过程，且有：

$$G|\boldsymbol{\theta} \sim DP(1 + \alpha, \frac{\alpha H + \delta_{\boldsymbol{\theta}}}{1 + \alpha}). \quad (8.10)$$

狄利克雷过程的后验概率依然是一个狄利克雷过程，这是个非常重要的结论，为我们更深入理解DP的性质并对其进行实际建模提供了基础 [5]。

首先我们考察一个重要结论：任何从DP中抽取出的采样都是一个离散分布，即使 H 是连续的。以一个连续分布作基础分布函数采样出离散分布，而这一采样的期望又是一个连续函数，这看似是非常不符合常识的，但 Ferguson 证明这确实如此 [3]。事实上，如果我们考察DP的后验概率形式，就会发现给定一个观察值 $\boldsymbol{\theta}$ 后， $G|\boldsymbol{\theta}$ 的基础函数已经是非连续的了，这说明DP本身确实具有很强的非连续性。下面我们说明这种非连续性如何导致了DP采样的离散性。

考虑如下采样过程：

$$G \sim DP(\alpha, H)$$

$$\boldsymbol{\theta} \sim G,$$

我们得到了 $(G, \boldsymbol{\theta})$ 的一个联合采样。然而，因为分布函数 G 是未知的，无法由 G 得到采样 $\boldsymbol{\theta}$ ，因而上述采样过程事实上只是理论的，无法实用。幸运的是，基于DP的后验概率，我们可以得到采样过程的一个等价过程：

$$\boldsymbol{\theta} \sim H$$

$$G \sim G|\boldsymbol{\theta}$$

通过上式得到的 $(G, \boldsymbol{\theta})$ 具有和原始采样相同的联合概率（虽然这里边的 G 依然是不可见的）。我们已经知道，后验概率 $G|\boldsymbol{\theta}$ 是一个如式8.10所示的新的DP。

对上述采样进行扩展，依 G 得到两个独立同分布采样，即：

$$G \sim DP(\alpha, H)$$

$$\boldsymbol{\theta}_1, \boldsymbol{\theta}_2 \sim G,$$

其等价采样为：

$$\boldsymbol{\theta}_1 \sim H$$

$$\boldsymbol{\theta}_2 \sim \boldsymbol{\theta}|\boldsymbol{\theta}_1$$

$$G \sim G|\boldsymbol{\theta}_1, \boldsymbol{\theta}_2.$$

其中 $\boldsymbol{\theta}|\boldsymbol{\theta}_1$ 是已知 $\boldsymbol{\theta}_1$ 后的后验概率。因为 $G|\boldsymbol{\theta}_1$ 是一个DP：

$$G|\boldsymbol{\theta}_1 \sim DP\left(1 + \alpha, \frac{\alpha H + \delta_{\boldsymbol{\theta}_1}}{1 + \alpha}\right),$$

依DP采样的边缘概率公式8.9， $\boldsymbol{\theta}|\boldsymbol{\theta}_1$ 是该 $G|\boldsymbol{\theta}_1$ 的基础分布 $\frac{\alpha H + \delta_{\boldsymbol{\theta}_1}}{1 + \alpha}$ 。上述过程重复进行，可得 G 的 N 个采样如下：

$$\boldsymbol{\theta}_n|\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_{n-1} \sim \frac{\alpha H + \sum_{i=1}^{n-1} \delta_{\boldsymbol{\theta}_i}}{n - 1 + \alpha} \quad n = 1, 2, \dots, N \quad (8.11)$$

基于这 N 个采样点， G 的后验概率为：

$$G|\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_N \sim DP(N + \alpha, \frac{\alpha H + \sum_{i=1}^N \delta_{\boldsymbol{\theta}_i}}{N + \alpha}) \quad (8.12)$$

式8.11给出了一个从DP的某一采样 G 中随机抽取采样 $\boldsymbol{\theta}$ 的过程。注意的是，我们事先并不知道我们正在采样的是哪个 G ，但是我们知道通过这一采样方法得到的 $\{\boldsymbol{\theta}_i\}$ 是基于 G 的独立同分布采样，因而 $\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_N$ 本身即代表了 G 的分布特性。同时，我们也知道 N 个采样点是有限的， G 中还有一些分布

性质无法由这些采样点得到，而这些不确定性即是式 8.12 所代表的后验概率。由该式可知，当得到越来越多的采样点， G 的特性越来越清晰地表现出来。让人惊讶的是，随着 N 的增加， G 的绝大部分概率值越来越多地分布在若干离散点上，而这些离散点正是已经得到的采样值（不同采样可能有相同采样值）。极限情况下，当 N 趋近于无穷时，采样点的概率分布可以准确描述 G 的分布，这时对一个新 θ 的采样分布即为 G 所代表的概率分布：

$$[\theta | \theta_1, \dots, \theta_N]_{N \rightarrow \infty} \sim G = \frac{\sum_{i=1}^N \delta_{\theta_i}}{N + \alpha} \quad (8.13)$$

注意上述概率分布正是当 N 取无穷大时， G 的后验概率 8.12 所趋近的极限值（注意当 N 取无穷大时， G 无限趋近其基础分布）。式 8.13 清晰地表明， G 是一个离散分布，该分布有无穷多个取值点，但这些点是离散的。图 8.10 给出一个由 $DP(\alpha, H)$ 的采样过程。由图中可以看到，虽然 H 是个连续分布， G 却是个离散分布。值得注意的是， G 中每个采样点的高度 $p(\theta | G) = G(\theta)$ 与 $H(\theta)$ 没有直接关系，更多取决于哪个 θ 先被选中。依采样过程，越先被随机选中的 θ 其 $G(\theta)$ 越大。由于 θ 的采样依赖 $H(\theta)$ ，因而 $H(\theta)$ 较大的 θ 容易被选中，因此 G 会倾向在 $H(\theta)$ 较大处表现出更大的 $G(\theta)$ 。

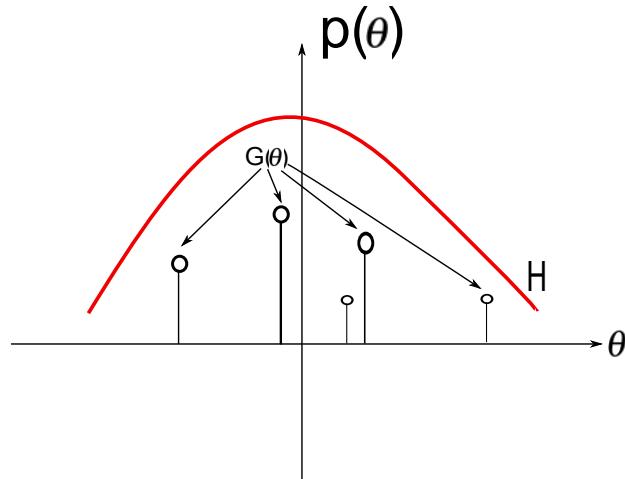


Fig. 8.10 狄利克雷过程 $DP(\alpha, H)$ 的一个采样 G 。

上述采样过程可用如下假想实验来模拟：假设我们有颜色分布 H ，现在我们拿到一个空袋子，从下面的两种方式中随机选择一种往袋子里放球：

方式一：从 H 中抽样出一种颜色，并将一个该种颜色的球放入袋中；

方式二：从袋中随机抽取出一个球，将球放回袋中，并往袋中放入一个同样颜色的球。

上述两种方式的比例为 $\alpha : N$ ，其中 N 为袋中已有球数。当袋中球的个数无限大时，袋中不同颜色球的分布即是一个狄利克雷过程的抽样。上述假想实验称为BlackWell-MacQueen Urn。图 8.11 给出这一过程。

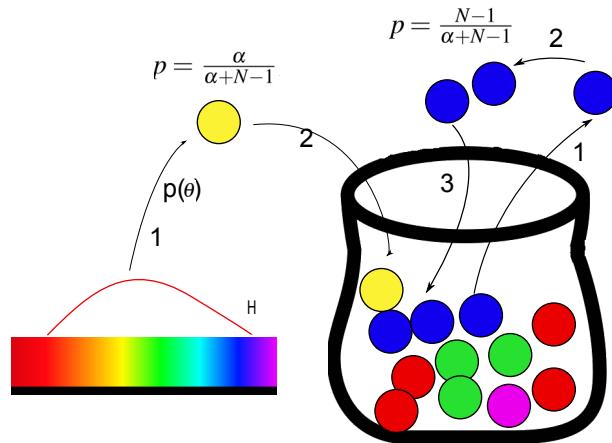


Fig. 8.11 狄利克雷过程的BlackWell-MacQueen Urn表示。进行第 N 次采样时，以 $p = \frac{N-1}{\alpha+N-1}$ 为概率选择从袋中取出一个球，按该球颜色“复制”一个同颜色的球放入袋中；或以 $p = \frac{\alpha}{\alpha+N-1}$ 为概率选择一种新颜色，制作一个该种颜色的球放入袋中。颜色选择依分布 H 。

进一步，如果我们观察BlackWell-MacQueen Urn过程，可以发现放入一个新球时，所选颜色的概率与当前袋中该颜色球的个数成正比。以 θ_i 代表第 i 个球的颜色， θ_k^* 为第 k 种颜色， K 为已有颜色总数， n_k 为第 k 个颜色的个数，则有：

$$\theta_N | c_{1,2,\dots,N-1} = \begin{cases} \theta_k^* & \text{with probability } \frac{n_k}{\alpha+N-1} \\ \theta_{K+1}^* & \text{with probability } \frac{\alpha}{\alpha+N-1}. \end{cases}$$

上式事实上正是CRP过程中的选座位方式， θ_k^* 相当于第 k 桌（或桌上的菜）， K 为已经被占的总桌数， n_k 为第 k 桌的顾客数。因此，CRP所定义的先验概率事实上正是DP定义在概率分布函数上的先验，每一次CRP过程得到DP的一个采样 G 。

由BlackWell-MacQueen Urn得到的 θ_i 其联合概率与顺序无关（见CRP的概率分布公式），且是依 G 条件独立同分布的。依de Finetti 定理，必然存在一

个在 G 上的概率分布来保证这一独立同分布属性。这一 G 上的概率分布即是狄利克雷过程。

8.3.6 狄利克雷过程的构造

前面所述的CRP过程和BlackWell-MacQueen Urn从数据生成角度描述了DP的性质，该过程通过采样 $\boldsymbol{\theta}$ 来间接生成 G ，其中每一步采样出的 $\boldsymbol{\theta}$ 有很大概率与前面得到的 $\boldsymbol{\theta}$ 相等。现在我们讨论一种通过采样各异值 $\boldsymbol{\theta}^*$ 直接生成DP采样 G 的方法，即每次采样都得到一个新的 $\boldsymbol{\theta}^*$ 。这一方法称为Stick-breaking。

回到 $(G, \boldsymbol{\theta})$ 的联合采样， G 可由下述采样过程得到：

$$\boldsymbol{\theta} \sim H$$

$$G|\boldsymbol{\theta} \sim DP(\alpha + 1, \frac{\alpha H + \delta_{\boldsymbol{\theta}}}{1 + \alpha}).$$

考虑将 X 分成两部分： $A_1 = \boldsymbol{\theta}, A_2 = X \setminus \boldsymbol{\theta}$ 。依DP定义，有：

$$\begin{aligned} (G(\boldsymbol{\theta}), G(X \setminus \boldsymbol{\theta})) &\sim Dir((1 + \alpha) \frac{\alpha H + \delta_{\boldsymbol{\theta}}}{1 + \alpha}(\boldsymbol{\theta}), (1 + \alpha) \frac{\alpha H + \delta_{\boldsymbol{\theta}}}{1 + \alpha}(X \setminus \boldsymbol{\theta})) \\ &= Dir(1, \alpha) \end{aligned}$$

注意 $(\beta, 1 - \beta) \sim Dir(1, \alpha)$ 等价于 $\beta \sim Beta(1, \alpha)$ ，因此， G 包含两部分，或者以 $Beta(1, \alpha)$ 为概率取 $\boldsymbol{\theta}$ ，或者以 $1 - Beta(1, \alpha)$ 为概率取 $X \setminus \boldsymbol{\theta}$ 上的值，因此有：

$$G = \beta \delta_{\boldsymbol{\theta}} + (1 - \beta)G'; \quad \beta \sim Beta(1, \alpha) \quad \boldsymbol{\theta} \sim H$$

进一步，将 X 做如下划分 $X = \{\boldsymbol{\theta}\} \cup A_1 \cup A_2 \dots \cup A_K$ ，依DP定义，有：

$$(G(\boldsymbol{\theta}), G(A_1), \dots, G(A_K)) = (\beta, (1 - \beta)G'(A_1), \dots, (1 - \beta)G'(A_K)) \sim Dir(1, \alpha H(A_1), \dots, \alpha H(A_K))$$

因此有：

$$G' \sim DP(\alpha, H).$$

重复上述过程，即有：

$$\begin{aligned}
G &\sim DP(\alpha, H) \\
G &= \beta_1 \delta_{\theta_1^*} + (1 - \beta_1) G_1 \\
G &= \beta_1 \delta_{\theta_1^*} + (1 - \beta_1)(\beta_2 \delta_{\theta_2^*} + (1 - \beta_2) G_2) \\
&\dots \\
G &= \sum_{k=1}^{\infty} \beta_k \prod_{i=1}^{k-1} (1 - \beta_i) \delta_{\theta_k^*}
\end{aligned} \tag{8.14}$$

其中:

$$\beta_k \sim Beta(1, \alpha); \theta_k^* \sim H.$$

注意上式中 β_k 和 θ_k^* 的随机性是重要条件，否则 G 的分解形式不能成立。

式8.14提供了一种非常简便的DP采样方法：每次从 H 中随机采样出一个值 θ_k^* ，由 $Beta(1, \alpha)$ 生成一个 β_k ，依式8.14计算 θ_k^* 上的概率 $\beta_k \prod_{i=1}^{k-1} (1 - \beta_i)$ 。这一过程可用一个折筷子游戏模拟，称为Stick-breaking 过程。假设一根单位长度的筷子，密度分布均匀。首先采样 $\beta_1 \sim Beta(1, \alpha)$ ，按 $\beta_1 : 1 - \beta_1$ 将筷子折成两半，取第一半为第一个采样点 θ_1^* 的概率；再将剩余的 $1 - \beta_1$ 部分作为整体，采样 $\beta_2 \sim Beta(1, \alpha)$ ，取第一部分作为第二个采样点 θ_2^* 的概率...如此往复进行，每次都对前次折后的剩余部分依 $Beta(1, \alpha)$ 进行再次拆分，作为下一个采样点的概率。经过上述拆分过程后，每一小段的长度即等于对应采样点的概率，剩余部分即为所有其它采样值的概率和。Stick-Breaking 过程首先由Sethuraman于1994年提出 [11]，并在文章中证明该过程得到的随机概率确实是DP先验。由Stick-Breaking 得到的对单位筷子的长度分布亦称为Griffiths-Engen-McCloskey (GEM) 分布 [8]。

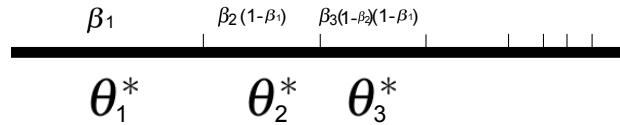


Fig. 8.12 Stick-breaking 过程。一根单位长度的筷子被分割成无数小段，每一个小段长度代表一个概率值。这一分割由无数次二分过程得到，其中第 k 个二分过程包含如下步聚： $\beta_k \sim Beta(1, \alpha)$, $\theta_k^* \sim H$ ，则第 i 次分割的比例为 $\beta_k : 1 - \beta_k$ ，对应的采样为 θ_k^* 。

8.3.7 推理方法

本节以DPGMM为例，讨论贝叶斯非参数模型中基于采样的推理方法。另一种常用的推理方法是变分法，读者可参考 [2]。关于采样和变分两种推理方法的基本原理，我们在第 6 章中已有细致讨论，本节只关注将采样法应用于DPGMM的具体做法。

DPGMM是对高斯成分 $\boldsymbol{\theta}_k^*$ 和高斯成分的先验概率 π_k 都引入随机性的GMM模型，其中 k 可以无穷大。从生成模型角度看，DPGMM可以有三种表示，如图 8.13 所示。

在表示 (A) 中，首先由CRP生成 z_i ，再由 $\boldsymbol{\theta}_{z_i}$ 生成数据：

$$z_i | z_1, \dots, z_{i-1} \sim CRP(\alpha) \quad (8.15)$$

$$\boldsymbol{\theta}_k^* \sim H \quad if \quad z_i \neq z_j \quad \forall j < i \quad (8.16)$$

$$\mathbf{x}_i \sim F(\boldsymbol{\theta}_{z_i}). \quad (8.17)$$

在表示 (B) 中，首先由BlackWell-MacQueen Urn过程生成 $\boldsymbol{\theta}_i$ ，再由该参数生成数据：

$$\boldsymbol{\theta}_i \sim DP(\alpha, H) \quad (8.18)$$

$$\mathbf{x}_i \sim F(\boldsymbol{\theta}_i). \quad (8.19)$$

在表示 (C) 中，首先由Stick-breaking过程（即GEM过程）生成 $\boldsymbol{\theta}_k^*$ 和 $p(k)$ ，由此计算出 n_k ，再由这些参数对每个高斯成分生成 n_k 个数据：

$$n_k \sim GEM(\alpha) \quad k = 1, 2, \dots, \quad (8.20)$$

$$\boldsymbol{\theta}_k^* \sim H \quad k = 1, 2, \dots \quad (8.21)$$

$$\mathbf{x}_i^k \sim F(\boldsymbol{\theta}_k^*) \quad k = 1, 2, \dots; i = 1, 2, \dots, n_k \quad for \ each \ k \quad (8.22)$$

研究表明，基于表示 (A) 来设计采样推理方法相对简单直观。在这一模型中，观测变量为数据 $\{\mathbf{x}_i\}$ ，隐藏变量为指示变量 $\{z_i\}$ 和模型参数变量 $\{\boldsymbol{\theta}_k^*\}$ 。注意上述观测数据和模型参数一般是向量而非数值，但这对下述推理算法没有影响。模型推理的任务是基于观测变量求隐藏变量的后验概率，即 $p(\mathbf{z}, \{\boldsymbol{\theta}_k^*\} | \mathbf{X})$ ，其中 $\mathbf{z} = [z_1, \dots, z_N]^T$, $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]$ 。

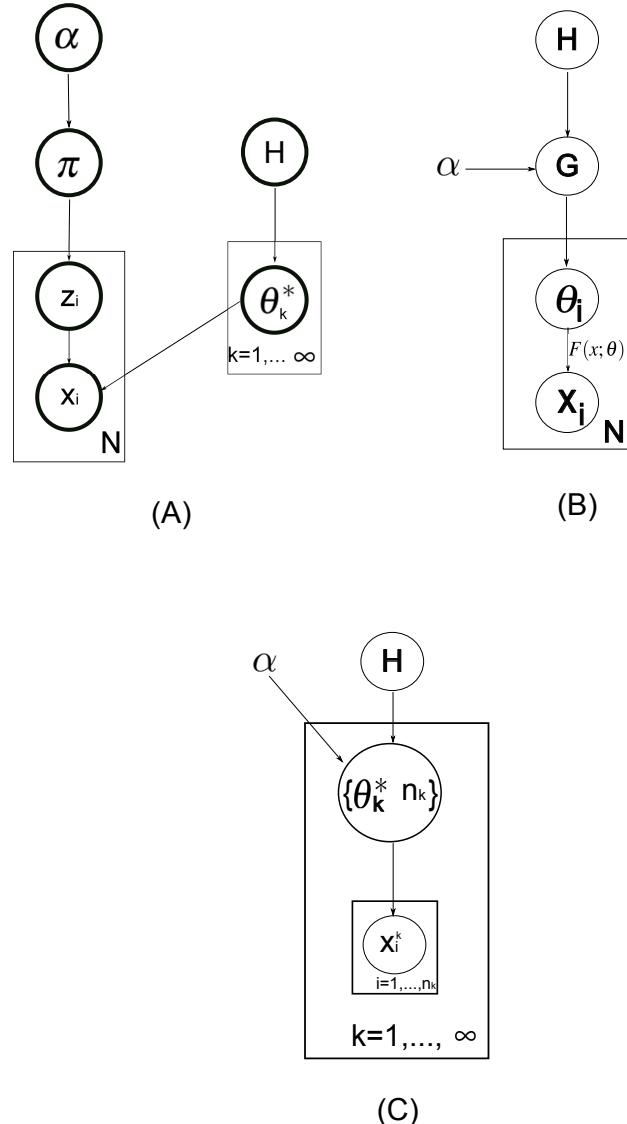


Fig. 8.13 三种DPGMM的表示方法。(A) 基于CRP生成指示变量 z_i 和参数 θ_{z_i} , 再由 $F(\theta_{z_i})$ 生成数据; (B) 基于DP生成每个样本的参数 θ_i , 再由 $F(\theta_i)$ 生成数据样本; (C) 基于Stick-Breaking生成取类参数 θ_k^* 和 n_k , 再对每个类k依 $F(\theta_k^*)$ 生成 n_k 个数据样本。

我们用Gibbs采样法来进行近似推理。第6章中介绍过，该方法的基本原理是通过构造一个马尔可夫过程，该过程运行到稳定状态时得到的采样符合要推理的后验概率。这一马尔可夫过程可由Gibbs采样得到。该采样过程的采样点为后验概率中的目标变量，包括每个数据样本的指示变量 z_i 和每个高斯成分的参数 $\boldsymbol{\theta}_k^*$ ，即 $\{z_i\}, \{\boldsymbol{\theta}_k^*\}$ 。Gibbs采样时，每次采样选择一个变量，保持其它变量不变，从而简化采样过程。

z_i 采样

我们首先对每个 z_i 采样。记除 z_i 外的所有指示变量为 \mathbf{z}^{-i} ，则可计算对 z_i 采样所需的条件概率如下：

$$\begin{aligned} P(z_i | \mathbf{z}^{-i}, \mathbf{X}, \{\boldsymbol{\theta}_k^*\}) &\propto P(z_i, \mathbf{z}^{-i}, \mathbf{X}, \{\boldsymbol{\theta}_k^*\}) \\ &\propto p(\mathbf{X} | \mathbf{z}, \{\boldsymbol{\theta}_k^*\}) p(z_i | \mathbf{z}^{-i}) \\ &\propto p(\mathbf{x}_i | z_i, \{\boldsymbol{\theta}_k^*\}) p(z_i | \mathbf{z}^{-i}). \end{aligned}$$

其中，后验概率 $p(z_i | \mathbf{z}^{-i})$ 依CRP过程计算得到：

$$p(z_i | \mathbf{z}^{-i}) = \begin{cases} \frac{n_k}{\alpha + N - 1} & z_i = k \\ \frac{\alpha}{\alpha + N - 1} & z_i = K + 1 \end{cases}$$

其中 K 是当前 \mathbf{z}^{-i} 中不同取值的个数。

下面我们计算条件概率 $p(\mathbf{x}_i | z_i; \{\boldsymbol{\theta}_k^*\})$ 。如果 $z_i \leq K$ ，可计算 $p(\mathbf{x}_i | z_i; \{\boldsymbol{\theta}_k^*\}) = F(\mathbf{x}_i, \boldsymbol{\theta}_{z_i}^*)$ ；如果 $z_i = K + 1$ ， $p(\mathbf{x}_i | z_i; \{\boldsymbol{\theta}_k^*\})$ 需要考虑所有可能的新参数 $\boldsymbol{\theta}_{K+1}^*$ ，因而有：

$$p(\mathbf{x}_i | z_i; \{\boldsymbol{\theta}_k^*\}) = \int p(\mathbf{x}_i | \boldsymbol{\theta}) p(\boldsymbol{\theta}) d\boldsymbol{\theta} = \int F(\mathbf{x}_i, \boldsymbol{\theta}) H(\boldsymbol{\theta}) d\boldsymbol{\theta}. \quad (8.23)$$

如果 $H(\boldsymbol{\theta})$ 是 $F(\mathbf{x}, \boldsymbol{\theta})$ 的共轭先验，则上式可较方便计算出来。

综合上述后验概率和条件概率的计算过程，可得对 z_i 采样的过程如下：

1. 如果 z_i 和所有 \mathbf{z}^{-1} 中的值都不同，则说明第 z_i 个高斯只包含 \mathbf{x}_i 这一个点。因为要重新随机 z_i ，这意味着当前第 z_i 个高斯里已经不包含任何数据，因此需要将 $\boldsymbol{\theta}_{z_i}^*$ 去掉，相应需要 K 减1。

2. 依如下概率采样 z_i ：

$$P(z_i | \mathbf{z}^{-i}, \mathbf{X}, \{\boldsymbol{\theta}_k^*\}) = \begin{cases} \frac{n_k}{\alpha + N - 1} F(\mathbf{x}_i, \boldsymbol{\theta}_{z_i}^*) & z_i = k \\ \frac{\alpha}{\alpha + N - 1} \int F(\mathbf{x}_i, \boldsymbol{\theta}) H(\boldsymbol{\theta}) d\boldsymbol{\theta} & z_i = K + 1 \end{cases}$$

3. 如果 $z_i = K + 1$, 则将 K 加 1, 并随机抽取一个新的 $\boldsymbol{\theta}_K^*$ 如下:

$$P(\boldsymbol{\theta}^* | \mathbf{x}_i) \propto F(\mathbf{x}_i, \boldsymbol{\theta}^*) H(\boldsymbol{\theta}^*).$$

$\boldsymbol{\theta}_k^*$ 采样

对 $\{z_i\}$ 做完采样后, 我们将这些变量固定, 接下来对每个高斯成分的参数 $\boldsymbol{\theta}_k^*$ 采样。记除第 k 个高斯外的所有高斯成分的参数为 $\boldsymbol{\theta}_{-k}^*$, 这一采样的概率为:

$$\begin{aligned} p(\boldsymbol{\theta}_k^* | \mathbf{X}, \mathbf{z}, \boldsymbol{\theta}_{-k}^*) &\propto p(\boldsymbol{\theta}_k^*, \mathbf{X}, \mathbf{z}, \boldsymbol{\theta}_{-k}^*) \\ &\propto \prod_{i:z_i=k} p(\mathbf{x}_i | \boldsymbol{\theta}_k^*) p(\boldsymbol{\theta}_k^*) \\ &= \prod_{i:z_i=k} F(\mathbf{x}_i, \boldsymbol{\theta}_k^*) H(\boldsymbol{\theta}_k^*). \end{aligned} \quad (8.24)$$

值得说明的是, 上述 Gibbs 采样算法需要 H 和 F 是共轭的, 否则式 8.23 可能无法计算。如果确实要选择非共轭先验, 可采用第 6 章中所讨论的 Metropolis-Hastings 算法, 这一算法不需要计算条件概率。Neal 2000 年的论文给出了 DPGMM MCMC 近似推理算法的细节 [7]。

8.3.8 Hierarchical DP (HDP)

DP 可以对相似条件下的数据进行有效学习, 但有时数据比较复杂, 包括在不同场景下的数据, 这些数据的分布规律有相似性, 同时也包含特异性。例如在对互联网文章进行聚类时, 不同类别的文章其分布规律是不同的, 如果把这些文章用一个模型来描述, 分布可能过于复杂, 但如果完全分开建模又会降低统计显著性, 毕竟不同类的文章间依然具有很多相似性。

研究者将 DP 扩展成层次结构来处理这个问题 [15, 14, 12]。其基本思路是不同场景下的数据共享相同的 DP 作为“先验分布的先验”, 基于该先验分布, 对不同场景下的数据生成新的 DP 作为条件相关的先验。基于这些场景

相关的DP进行建模，即可实现多场景数据联合学习。这一层次性DP模型称为Hierarchical DP (HDP)，如图 8.14 所示。在HDP中，首先以 $DP(\gamma, H)$ 抽样出一个概率函数 G_0 ；对第 j 个场景，首先以 $DP(\alpha, G_0)$ 抽样出一个概率函数 G_j ，再由 G_j 抽样出每个样本对应的 θ_i^j ，最后由数据分布概率 $F(x; \theta)$ 抽样出数据样本 x_i^j 。

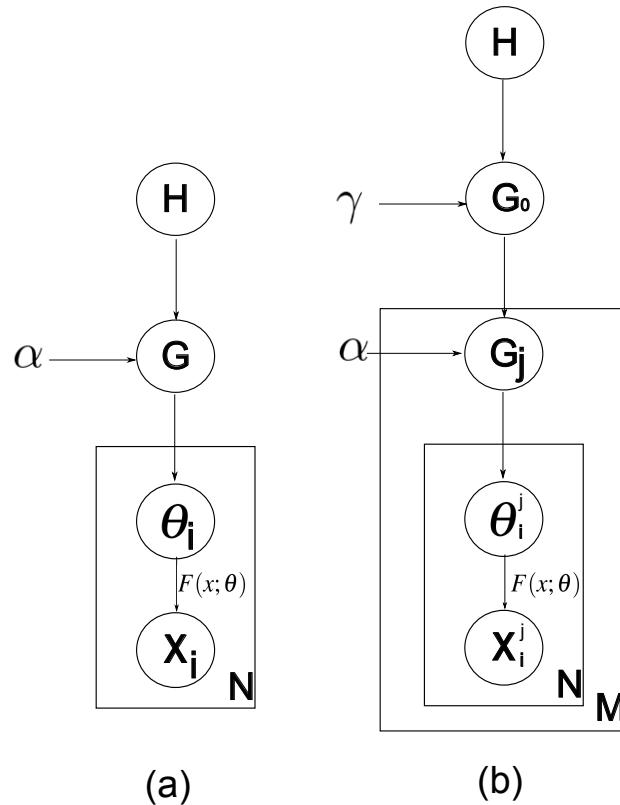


Fig. 8.14 基于DP(左)与HDP(右)的数据生成模型。 $F(x; \theta)$ 为数据分布概率。在HDP中，首先由场景共享的 $DP(\gamma, H)$ 中得到 G_0 ，再由 $DP(\alpha, G_0)$ 得到不同场景下的概率 G_j 。由 G_j 即可抽样得到每个数据样本对应的模型参数 θ_i^j ，进而生成数据 x_i^j 。

由HDP的数据生成过程可知，不同场景下的数据事实上共享一个基础分布 G_0 。由于 G_0 是离散的，且具有很强的聚类性， G_j 只能取 G_0 所确定的参数点，且有较大概率集中在 G_0 中概率较大的参数，由此实现类间的参数取值及参数分布形式的共享。用于DP的近似推理方法可同样用于HDP。

8.4 本章小结

本章讨论了非参数模型的基本概念和方法。我们讨论了几种朴素的非参数模型，包括用于概率描述的直方图模型和用于分类的KNN方法。这些方法不设计模型的具体形式，依靠大量数据对数据空间的覆盖实现对测试数据的描述和分类。因为没有模型结构的限制，只要训练数据量足够大，这些非参数模型可实现对未知数据非常精确的描述和预测。

SVM是另一种典型的非参数模型。这一模型并非完全没有模型结构，而是将参数模型和非参数模型结合起来，在特征映射上采用参数模型（即核函数），但在预测时采用非参数模型，通过计算测试数据和部分训练数据（即支持向量）间的距离，用训练数据的类别来预测测试数据的类别。这种将参数模型和非参数模型结合起来的方法既可以避免非参数模型对数据量的过度依赖，也可以摆脱参数模型对预测函数形式的限制，从而极大提高建模的精确性，实现模型依数据的调整。从另一个角度看，这一方法也极大提高了对训练数据的利用效率。

基于这一思路，我们着重讨论了贝叶斯框架下的非参数模型。贝叶斯框架提供了非常强大的建模能力，但基于参数的贝叶斯方法其模型结构是固化的，这极大限制了模型对数据的描述上限。贝叶斯非参数模型通过提供非参数的先验概率，打破了固化模型带来的限制，使得贝叶斯模型的建模能力随数据的增长而提高。

我们讨论了两种贝叶斯非参数模型方法。在预测任务中，我们引入对预测函数的先验概率，即高斯过程（GP）。这一先验概率不依赖预测函数的具体形式，而是对无限多的值域在 $(-\infty, +\infty)$ 上的预测函数赋予适当的先验概率，使得基于该先验概率，任何有限采样点上的取值是高斯分布的。这一普适的先验概率大大丰富了贝叶斯方法中可选的预测函数范围，使得当训练数据足够多时，其后验概率更加灵活地趋近于真实预测函数。

在聚类任务中，我们讨论了狄利克雷过程（DP）。总体来说，DP可以认为是狄利克雷分布向无限维空间的扩展。在贝叶斯框架下，这使得我们可以在无限维参数空间上设计概率密度函数的先验概率，从而实现依训练数据选择最合适聚类形式。特别是，这一方法考虑所有可能的聚类形式，因而无需对聚类数进行人为指定。通过推算在所有聚类形式上的后验概率，可以让数据自动选择最合理的聚类数和在每个类上的分布概率。将狄利克雷分布扩展到狄利克雷过程具有可行性，不论是Kolmogorov一致性定理还是de Finetti定理都表明DP是存在的；同时，Blackwell-MacQueen Urn和CRP给出了基于

数据生成过程的构造方法，Stick-breaking给出了基于参数生成过程的构造方法。利用这些构造方法，我们可以设计基于MCMC的推理算法。

8.5 相关资源

- 本章对高斯过程的讨论，参考了Bishop的《Pattern recognition and machine Learning》第六章。
- 本章对狄利克雷过程的讨论，参考了Yee Whye Teh的《Dirichlet Processes: Tutorial and Practical Course》。¹
- 关于高斯过程，可参考Seeger的综述文章 [10]，Williams等人的《Gaussian Processes for Regression》[16]，Rasmussen等人的《Gaussian processes for machine learning》[9]。
- 关于贝叶斯非参数模型，请参考Gershman等的Review论文 [4] 以及Muller等的论文 [6]。

¹ <https://www.stats.ox.ac.uk/~teh/teaching/npbayes/mlss2007.pdf>

Chapter 9

遗传学习

Chapter 10

强化学习

Chapter 11

优化方法

References

- [1] Bishop CM (2006) Pattern recognition and machine Learning. Springer
- [2] Blei DM, Jordan MI, et al (2006) Variational inference for dirichlet process mixtures. *Bayesian analysis* 1(1):121–143
- [3] Ferguson TS (1973) A bayesian analysis of some nonparametric problems. *The annals of statistics* pp 209–230
- [4] Gershman SJ, Blei DM (2012) A tutorial on bayesian nonparametric models. *Journal of Mathematical Psychology* 56(1):1–12
- [5] Ghosal S (2010) The Dirichlet process, related priors and posterior asymptotics, vol 2. Chapter
- [6] Müller P, Mitra R (2013) Bayesian nonparametric inference—why and how. *Bayesian analysis (Online)* 8(2)
- [7] Neal RM (2000) Markov chain sampling methods for dirichlet process mixture models. *Journal of computational and graphical statistics* 9(2):249–265
- [8] Pitman J, et al (2002) Combinatorial stochastic processes
- [9] Rasmussen CE (2006) Gaussian processes for machine learning
- [10] Seeger MW (2004) Gaussian processes for machine learning. *International Journal of Neural Systems* 14(2):69–106
- [11] Sethuraman J (1994) A constructive definition of dirichlet priors. *Statistica sinica* pp 639–650
- [12] Teh YW (2006) A hierarchical bayesian language model based on pitman-yor processes. In: Proceedings of the 21st International Conference on Computational Linguistics and the 44th annual meeting of the Association for Computational Linguistics, Association for Computational Linguistics, pp 985–992
- [13] Teh YW (2011) Dirichlet process. In: *Encyclopedia of machine learning*, Springer, pp 280–287
- [14] Teh YW, Jordan MI (2010) Hierarchical bayesian nonparametric models with applications. *Bayesian nonparametrics* 1
- [15] Teh YW, Jordan MI, Beal MJ, Blei DM (2005) Sharing clusters among related groups: Hierarchical dirichlet processes. In: *Advances in neural information processing systems*, pp 1385–1392
- [16] Williams CKI, Rasmussen CE (1996) Gaussian processes for regression pp 514–520