

多标签学习和分类浅谈——从语言通信的角度看

鲁晨光

1. 序言

作者以前研究语义信息论，最近研究了多标签分类基本方法，觉得，从语义通信的角度看，结合已有的方法，应该能得到更简单更合理的方法。下面是最近研究的一个总结。

数学定义：

- 实例 instance—— $x \in U = \{x_1, x_2, \dots, x_m\}$
- 标签 label—— $y \in V = \{y_1, y_2, \dots, y_n\}$ ，一个标签可能是由多个原子标签组成复合标签。
- 样本 $D = \{(x(t), y(t)), t=1, 2, \dots, N\}$. $x(t) \in U, y(t) \in V$ ，样本分布 $P(x, y)$ ，实例分布 $P(x)$.
- 条件样本 $D_j =$ 是 D 中 $y(t)=y_j$ 的部分。相应的条件样本分布是 $P(x|y_j)$ 。

本文使用交叉熵方法，即用样本分布代替样本序列。

参考文献：

- Wikipedia 的多标签学习介绍：https://en.wikipedia.org/wiki/Multi-label_classification
- 张敏灵和周志华的多标签学习文章：A Review on Multi-Label Learning Algorithms <http://cse.seu.edu.cn/people/zhangml/files/TKDE%2713.pdf>
- 张敏灵等人关于二元关联的文章：<http://cse.seu.edu.cn/people/zhangml/files/FCS%2717.pdf>
- 徐兆桂的一片中文介绍 <http://lamda.nju.edu.cn/huangsj/dm11/files/xuzg.pdf>
- 本文作者的有关研究：<http://survivor99.com/lcg/CM/Recent.html> 其中有《从贝叶斯推理到逻辑贝叶斯推理》后面简称《逻辑贝叶斯推理》。

2. 多标签学习和分类的区别和联系

假设一个狼孩回到人类社会，他要通过自然语言了解标签“男人”，“女人”，“小孩”，“成年人”，“年轻人”，“中年人”，“老人”...语言含义和用法。了解含义就是得到标签的外延。掌握用法就能传递消息给别人。这是两个任务。可能发生在两个人身上：收信人（看标签者）和发信人（贴标签者）；也可能一个人身兼二值。

流行的分类研究都假设一个人身兼二职，自己学，自己用（参看图1）。所以，学习就是掌握分类器，分类就是使用分类器。学习是复杂的，使用是简单的。所以，张敏灵和周志华的文章都是讲多标签学习，学习中包含优化分类器。Wikipedia 中是这样定义的多标签分类的：Formally, multi-label classification is the problem of finding a model that maps inputs x to binary vectors y (assigning a value of 0 or 1 for each element (label) in y). 这里没有标签外延或语义学习，直接就是分类。

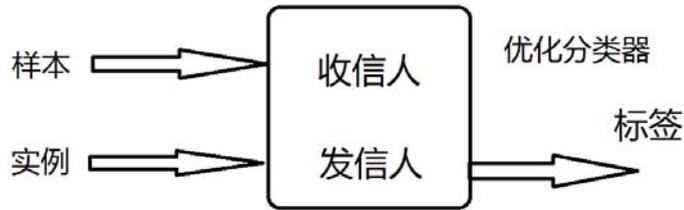


图 1 流行的学习方法中发信人收信人是同一人

但是从语言通信的角度看，我们要把发信人和收信人分开且，并且并列考虑（而不是一个人充当二职）。那么学习就是收信人获得标签外延或隶属函数，并不分类（并不划分实例空间），分类就是发信人划分实例空间，给每个实例或每个类别贴上最大内涵标签（通常是最小外延复合标签）。比如，狼孩学习“小孩”，“年轻人”，“大人”，“老人”，...的外延（几条隶属函数曲线），并不划分。70岁的人同时被理解为“大人”和“老人”。但是，发信人要做划分，并且给实例选择一个外延较小的一个标签，比如“老年人”。不会说了“老年人”还要说他是“成年人”。

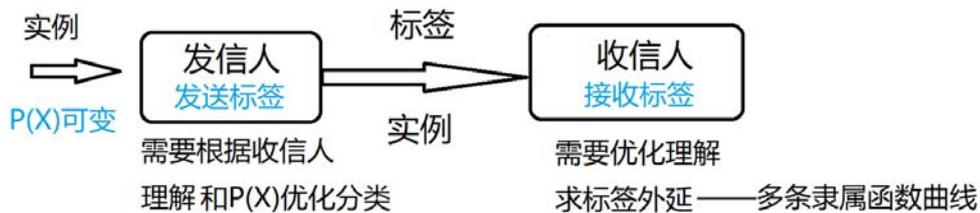


图 2 从语义通信的角度看，发信人和收信人并列，构成一个通信系统

分类贴标签时，对于可见实例，外延越小越好。但是对于不可见实例，可能预测不准，就有可能使用较大外延的标签，比如“是大人”或外延更模糊的标签“可能是老人”。天气预报有一般报“晴”，“小雨”或“中雨”...。如果测不准，就用更模糊标签“小到中雨”。外延小，一般信息量大，但是太小就容易出错，信息损失更大。所以折中考虑，就会使用比较模糊类别。对于可见实例分类，后面我们还要把外延最小准则改进为逻辑概率最小准则，这样就能和 Popper 理论即 Bar-Hillel-Carnap 定义的语义信息兼容。

要求学习和分类分开还有一个原因：如果类别模糊，划分类别并不完全根据外延，还要根据实例的概率分布 $P(X)$ 。比方说：“年轻人”的外延可以用隶属函数表示，从 20-25 岁隶属度是 1，偏差越大，隶属度越小，50 岁大概是 0，划分界限要看 $P(x)$ ，你到部队去，30 岁以上肯定不能算年轻人；但是你要参加政协会议，40 岁甚至 50 岁还算是年轻人。为什么这样？语言是用来传递信息的，分类太少，信息少；分类太多成本又太高。所以传递年龄信息的标签大概“幼年”，“少年”，“青年”，“中年”，“老年”。粗分就是“小孩”和“大人”。人类寿命长了，分界点会自然改变，为的是传递更多信息。而信息准则更重视小概率事件——减少小概率事件的漏报。用法改变样本，样本改变外延（语义）；新的用法又会迁就已形成的外延。两者相互促进。当然，给狮子老虎等动物分类，外延不是模糊的，不存在上述问题。天气预报语句给降雨量分类，用优良中差给学生考试分数分类，都需要根据 $P(x)$ 改变分类边界。

3. 收信人如何求标签或概念外延？——多标签学习问题

假设我们知道普通人群不同年龄 x 的先验概率分布 $P(x)$ (连续的), 又知道成年人年龄概率分布 $P(x|y_1 \text{ 是真的})$ (也是连续的, y_1 等于词或标签“成年人”)。我们是否能得到合适的“成年人”的概念外延? 换为不同人群(比如在学校, 工厂, 部队), 其先验概率分布是 $P'(x)$, 我们能求出相应的后验分布 $P'(x|y_1 \text{ 是真的})$ 吗? 我们能写出一个通用预测模型, 用来求解这样的问题吗?

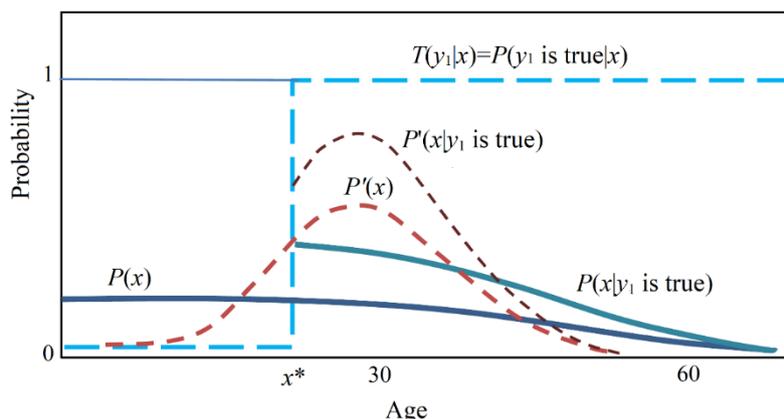


图3 求 $y_1 = \text{“成年人”}$ 的外延和后验分布 $P'(x|y_1 \text{ is true})$.

已有的似然方法不能解决这个问题, 因为似然函数不能加进先验知识, 从一个人群得到的似然函数, 换一个人群就会失效。贝叶斯主义推理即 Bayesian Inference (BI) 声称使用主观概率和逻辑概率, 也考虑先验知识。用它可以吗? 也不行! 因为虽然 BI 用到贝叶斯定理 (Bayes' theorem), 但是实际上没有用到逻辑概率, 因为逻辑概率不是归一化的(别处详谈), 而 BI 用到的先验 $P(\theta)$ (θ 是模型参数) 和后验 $P(\theta|x)$ 都是归一化的; 2) BI 的先验是 θ 或 y (词或标签) 的先验, 它是主观的; 而不是 x 的先验——它比较客观。我们上面例子是 x 的先验分布 $P(x)$ 变了, 求相应的后验分布。

但是人脑求上面问题还是勉强可以的。比如, 我们划出先验和后验分布 $P(x)$ 和 $P(x|y_1 \text{ 是真的})$, 就能知道“成年人”的外延—— x 从哪里 x^* 开始就是成年人。然后我们把 $P(x)$ 中大于 x^* 的部分做归一化处理就行了。

但是类别模糊时, 比如没有法定“成年人”年龄规定的时候, 如何计算“成年人”的外延, 即类别 {成年人} 的隶属函数, 或标签“成年人”的真值函数? 人脑也不容易。

我发现了第三种贝叶斯定理, 用它可以解决上述外延问题, 有了外延, 还可以在 $P(x)$ 改变的情况下做新的预测。求外延公式是

$$T(\theta_j | x) = [P(x | \theta_j) / P(x)] / \max [P(x | \theta_j) / P(x)] \quad (1)$$

其中 θ_j 表示一个模糊集合或预测模型, $P(x|\theta_j) = P(x|y_j \text{ 是真的})$ 。 $T(\theta_j|x)$ 是标签 y_j 的真值函数或 θ_j 的隶属函数。做新的概率预测公式是:

$$P(x | \theta_j) = P(x) T(\theta_j | x) / \sum_i P(x_i) T(\theta_j | x_i) \quad (2)$$

其中 $P(x)$ 是可以变的, 也就是说, 隶属函数作为预测模型, 可以用于不同先验分布 $P(x)$ 的样本。我称上面两个公式为第三种贝叶斯定理。第一种是贝叶斯使用的, 第二种是 Shannon 使用的。现在我提供第三种。其证明详见: <http://survivor99.com/lcg/CM/Homepage->

[NewFrame.pdf](#) (P.12). 当样本足够大时, 求外延公式就变为:

$$T^*(\theta_j|X) = [P(X|y_j)/P(X)] / \max[P(X|y_j)/P(X)] = P(y_j|X) / \max[P(y_j|X)], j=1, 2, \dots, n \quad (3)$$

它和转移概率函数成正比, 最大值是 1——就这么简单!

如果样本足够大, 能得到连续分布 $P(x,y)$ 或 $P(y_j|X)(j=1,2,\dots,n)$, 直接用上面公式得到隶属函数。如果样本不够大, 则用广义 Kullback-Leibler 公式优化隶属函数:

$$\begin{aligned} T^*(\theta_j | X) &= \arg \max_{T(\theta_j|X)} I(X; \theta_j) = \arg \max_{T(\theta_j|X)} \sum_i P(x_i | y_j) \log \frac{T(\theta_j | x_i)}{T(\theta_j)} \\ &= \arg \max_{T(\theta_j|X)} [\log(1/T(\theta_j)) - \text{误差项}] \end{aligned} \quad (4)$$

$T(\theta_j)$ 就是 (2) 中的分母, 表示标签 y_j 的逻辑概率。第一项就是 Bar-Hillel-Carnap 的信息, 第二项反映误差。这是一个特殊的正则化误差准则, 误差是惩罚项。隶属函数覆盖范围小, 逻辑概率就小, 潜在信息就多, 但是相对误差就大了。所以要走“中庸之道”。也不难证明, 语义信息准则等价于最大似然准则。

有了标签外延, 求他们之间蕴含关系就容易了。如果总有 $T(\theta_j|x) \geq T(\theta_k|x)$, 则 y_k 蕴含 y_j 。

4. 发信人如何选择标签? ——分类问题

有了标签外延, 分类就简单了——用最大语义信息准则。 y_j 提供关于 x_i 的语义信息(量)被定义为对数标准(normalized)似然度:

$$I(x_i; \theta_j) = \log \frac{P(x_i | \theta_j)}{P(x_i)} = \log \frac{T(\theta_j | x_i)}{T(\theta_j)} \quad (5)$$

其中用到公式 (2)。这个公式就能反映 Popper 的思想: (先验)逻辑概率越小, 并能经得起检验(后验逻辑概率越大), 信息量就越大; 永真句在逻辑上不能被证伪, 因而不含有信息。

如果实例可见, 分类函数就是

$$y_j^* = f(X) = \arg \max_{y_j} \log [T(\theta_j | X) / T(\theta_j)]$$

当类别清晰时, 隶属函数是 0 或 1, 上述分类函数就变为最小逻辑概率准则——不光外延小, 还要包含的实例概率小。外延小就要求尽可能选择复合句, 比如“男青年”且是“成年人”。逻辑概率小的例子比如: “百岁以上老人”比用“一岁婴儿”外延大, 但是逻辑概率小, 潜在信息更多。

这个分类准则考虑到先验概率 $P(x)$ 的变化, 因而能解决类别不平衡问题。我们以标签 $y_1 =$ “老年人”为例说明类别划分随实例的先验分布 $P(X)$ 变化(参看图 4)。其中设 X 表示年龄, 标签 $y_1 =$ “老年人”。假设

$$T(\theta_1 | X) = \frac{1}{1 + e^{-0.2(X-75)}}, \quad P(X) = 1 - \frac{1}{1 + e^{-0.15(X-c)}} \quad (6)$$

图 4 显示了有关函数和优化的划分点 x^* 。表 1 显示划分点随 X 的先验分布 $P(X)$ 中参数 c 的变化而变化。

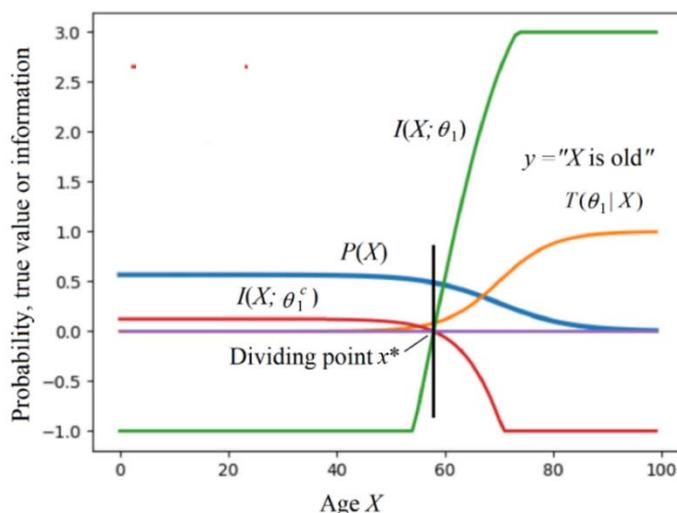


图 4 老年人分类划分点 x^* 。它在老年人人口比例增加时右移。

表 1 “老年人”分类器 $f(X)$ 随人口密度分布 $P(X)$ 中的参数 c 的变化

$P(X)$ 中参数 c	人口密度下降区域	划分点 ($y_1=f(X \geq x^*)$)
50	40-60	49
60	50-70	55
70	60-80	58

注意：这时候“老年人”的外延并没有变化。划分点右移会影响新样本的 $P(x, y)$ 以及转移概率函数 $P(y_1|X)$ ，从而改变词的接收者理解的真值函数。这些变化也会反过来影响划分函数 $f(X)$ 。“老年人”的语义和使用规则就是这样进化的。没有人规定老年人的严格分界年龄在哪里，语言交流过程中会自动形成一个模糊分界，它随人口的年龄分布变化而变化。老年人多的群体，可能 70 岁才算老年人，50 岁算年轻人。以前人的寿命短，50 岁就算老年人了。“大雨”类似，雨水多的地区可能日降雨量 50mm 才算大雨；而雨水少的地区可能日降雨量 20mm 就算大雨了。

上述方法自然考虑了类别不平衡问题——因为信息准则更加重视减少小概率事件的漏报。用流行的方法，分界点不随 $P(x)$ 改变（参看前面 wikipedia 的定义），类别不平衡问题是免不了的。

如果实例是不可见的(比如我们根据人的声音把人分成男女，或者根据西瓜的外观把西瓜分为好瓜和差瓜，我们只知道观察数据 $Z \in C$ ，则可用平均语义信息准则选择标签或划分观察数据空间 C 为 C_1, C_2, \dots ，即

$$y_j^* = h(Z) = \arg \max_{y_j} \sum_i P(x_i | Z \in C_j) \log \frac{T(\theta_j | x_i)}{T(\theta_j)} \quad (7)$$

在预测不准时，模糊集合外延较大可以减小误差带来的信息损失，所以用上式选出来的 y_j^* ，其逻辑概率 $T(\theta_j)$ 未必最小。这也是为什么天气预报经常报“小到中雨”。对于不可见实例分类，划分函数 $h(Z)$ (确定每个 C_j) 会改变 Shannon 信道和与之相匹配的语义信道，所以又要求重新划分... 因此需要迭代方法。参看鲁晨光的求最大似然估计的信道匹配算法 <http://survivor99.com/lcg/CM/CM4tests.pdf>。

5. 流行的多标签学习方法存在的问题

流行的学习方法中用后验概率估计——信息论中称之为转移概率函数—— $P(y_j|X; \theta)$ ($j=1,2,\dots,n$)作为学习函数。因为归一化要求($\sum_j P(y_j|X; \theta)=1$)， $n>2$ 时，很难构造一组转移概率函数。于是大家提出用多个二分类代替多分类，比如用 logistic 函数做二分类的转移概率函数。这也有多种。

一种方法是 One-vs-Rest，比如对于“年轻人”标签，分成“年轻人”和“非年轻人”。然而，一个实例（24岁）没有标注某个标签（“年轻人”），不等于它就是反例。比如一个样本中有两个例子：（25岁，“年轻人”）和（24岁，“成年人”）。标注都是对的。按照 One-vs-Rest，对于“年轻人”，（24岁，“成年人”）就是反例。这是不合理的。

另一种是二元关联（Binary relevance，简称 BR）。这种方法用一个长度为 n 的二进制数字表示一个复合标签，1 表示“Yes”，0 表示“No”。 n 原子标签就有 2^n 种复合标签。这种方法不会出现上面问题，但是又有新的问题：1）对样本要求太高，从自然语言很难得到复合要求的样本。比如“非年轻人”，“非老年人”在自然语言中很少见。要把原来的 D 分成 n 个 D_j ，每次训练一个标签 y_j ，但是包括所有实例。2）存在标签相关性问题。比如，我们不会在说一个是“老年人”之外，还说他是“成年人”或“非年轻人”。BR 方法提供太多标签，不符合经济学要求，不符合自然语言习惯。

上面两种方法都很难解决类别不平衡问题。因为标签学习的时候就已经分类了，选择标签的时候，尽管 $P(x)$ 不同，也没法改变分类边界了。

本文前面方法可以做到：

- 1) 使用隶属函数取代后验概率估计，就可以避免归一化难题；
- 2) 训练一个标签的隶属函数的时候，把所有样例分为 3 种（正例，反例，不清楚例）。不考虑不清楚样例就可以了。不需要筛选样本。第三种贝叶斯定理就可以忽略不清楚样例。
- 3) 因为学习的时候并不划分，所以训练一个标签的隶属函数不一定要用反例（要用也可以，参看英文文章）。因为 2) 和 3)，这种方法对样本没有特别要求，能得到 $P(x,y)$ 或 $P(y|x)$ 就行。
- 4) 求最小逻辑概率就已经考虑标签相关性，多余的标签自然就不要了。
- 5) 始终使用和最大似然准则兼容的最大语义信息准则。但是也考虑到 $P(x)$ 变化后，原来的似然函数失效——流行的方法都有这个问题。用隶属函数学习就能解决失效问题。

6. 关于优化准则和泛化能力

我们常常看到有人抱怨：用原来的样本正确率高，换一个样本就差了，泛化能力不行。原因在哪里？通常认为是因为过度拟合。我以为更重要的原因是：1) $P(x)$ 会变，用正确率准则， $P(x)$ 变了，总体正确率必然差了。2) 我们需要根据新的 $P(x)$ 改变分类器。

先看正确率准则的问题。对于地震预测（或艾滋检测），永远报没有地震（没有病毒），准则率很高，但是没有意义。如果总是根据今天有无雨预测明天有雨，根据今天股市涨或跌预测股市明天涨或跌，正确率也比较高，但是也没啥意义。因为你不说别人也估计得差不多。好的预测要能提高相对正确率。最大似然准则和信息准则（包括语义信息准则）就是这样的准则。正则化误差平方（RLS）也是类似准则（参看《逻辑贝叶斯推理》）。

医学界还用似然比或置信水平（而不用正确率）评价检验本身的好坏。因为检验好坏在

于检验本身，在于信道，而和信源 $P(x)$ 无关。而正确率和 $P(x)$ 有关。机器学习也应该采用置信水平或确证度这样的评价（参看《逻辑贝叶斯推理》）。

关于正确率准则和信息准则的差别，打个比方。一个教师 A 重在提高全班学生学习总成绩（重视概率较大群体），另一个教师 B 重在提高每个学生的相对成绩。如果换一批学生， $P(x)$ 变了，两人还用原来教学方案，A 教的班级的总成绩就可能下降很多。而 B 教的班级学习成绩会比较稳定。也就是说，B 的泛化能力强。要提高学生相对成绩，老师还需要根据 $P(x)$ 重新划分小组施教。多标签学习和分类是类似的，用信息准则可以提高隶属函数的泛化性能；根据 $P(x)$ 做多标签分类就是优化分组，以便提高平均“相对成绩”。

关于本文方法的进一步讨论见 《逻辑贝叶斯推理》
<http://survivor99.com/lcg/CM/Recent.html>

欢迎批评交流！lguang@foxmail.com