

讲 座

疾病预测预报方法

辽宁省卫生防疫站

章扬熙

疾病监测的信息反馈主要有两个方面，一是使对策、措施调优，一是预测预报。进行预测预报，可使防病工作有预见性，打主动仗，从而可防患于未然或防微杜渐，以控制疾病的发生和流行。疾病的预测就是根据疾病发生、发展规律及有关因素，收集有关资料，运用分析判断、数学模型等方法，对疾病未来发展的趋势和强度作出预测。本文就常用的疾病预测方法作一介绍。

疾病预测的依据

一、疾病资料：传染病疫情资料、慢性病资料、恶性肿瘤和心血管病等资料。通过漏报调查进行质量控制，计算估计发病率，用于预测。

二、致病因子资料：在传染病方面，包括病原体的群、型、毒力大小、变异情况、耐药性等；在非传染病方面，包括致病物质、危险因子等。

三、宿主资料：在传染病方面，要了解不同病型的患者和病原体携带者的分布及血清学调查资料。在自然疫源性疾病和寄生虫病方面，要了解疾病在动物中的情况、传染来源、储存宿主及中间宿主的种类及其分布等。在非传染病方面，包括疾病谱分布及遗传素质等。

四、环境资料：包括与疾病发生、发展有关的环境因子，如人口、气象、地理、媒介昆虫、环境污染、防制疾病的对策、措施实施情况等。

疾病的定性预测

对疾病的发展趋势和强度作定性的估计，是上升还是下降，是流行还是散发。

一、综合预测法：研究疾病的流行动力学，探求流行的动态规律，综合各有关因素，预测疾病的发展趋势。传染病的流行是有先兆的，可采用“审势法”进行预测。这种先兆常表现为上一流行病学年流行熄止较晚，上一年疫势已有上升，本年该病发生又起步早、病例多、病情重、发展速度快、大年龄组发病

频率增加、涉及面扩大、有爆发点不断发生、密切接触传染指数高、感染谱左移等迹象；也可以结合有关因子进行预测。比如，三带喙库蚊出现早、高峰早，感染率高，人群乙脑HI抗体阳性率低，预兆流行性乙型脑炎流行。黑线姬鼠等鼠密度高，感染多，预兆流行性出血热的流行。脑膜炎双球菌A群带菌率明显上升，人群抗体阳性率低，预兆流行性脑脊髓膜炎的流行。又如，高血压、吸烟、高胆固醇、肥胖等是冠心病的危险因素，危险因素愈多，愈易患冠心病。

二、控制图法：本法适用于有明显季节性的传染病预测。以疾病最低发病月为起始月，划分流行病学年（比如，某地流脑最低发病月为9月，所以从每年9月起到次年8月止为流脑的流行病学年）。以过去若干年（至少包括一个流行周期）该病月发病率资料为基础，用最大、最小和中位数月发病率的数值绘制半对数疾病流行控制图。横坐标为月别，用普通尺度，纵坐标为该病的月发病率，用对数尺度。图中共有三条线，以各月发病率的最大值划出上限线，以各月发病率的最小值划出下限线，以各月发病率的中位数划出中位数线。为了预测某年该病的流行趋势，可以从该年9月起，把该病的每月发病率依次划在控制图上。如果这些点子在中位数以下，点的连线坡度比中位数线小，往往预兆散发；如果这些点子在中位数以上，线的坡度比中位数大，则往往预兆流行。应补充说明的是，控制图的纵坐标用半对数尺度的目的在于直观月发病率的变化速率。又由于传染病各月的发病率多呈偏态，故以中位数、最大值和最小值来作控制图。

三、尤度法：又叫最大似然法。它是把一系列条件概率连乘来求似然值。由于条件概率取值在0~1间，计算较繁，通过对数变换，把条件概率换成整数的指数，把连乘变成连加，得H值，哪个H值大，即判为哪一类，使计算简化。条件概率与指数的对应关系如表1。

[例1] 某地对流脑进行预测，以10个地区1960~1980年的资料，按自上年11月份至当年10月份为一个

表1 条件概率与指数的关系

P值	指数	P值	指数
0~	-10	0.113~	1
0.012~	-9	0.142~	2
0.015~	-8	0.178~	3
0.018~	-7	0.224~	4
0.023~	-6	0.284~	5
0.029~	-5	0.355~	6
0.036~	-4	0.447~	7
0.045~	-3	0.563~	8
0.057~	-2	0.708~	9
0.071~	-1	0.892~	10
0.090~	0		

注：指数 = $[\lg P(S_i/A_G) + 1] \times 10$ 取整

表2

某10个地区流脑预测的资料

自变量		流行 (Y_1)			散发 (Y_2)		
		频数	百分比(%)	指数	频数	百分比(%)	指数
X_1	① ≤ 13	8	12.31	1	53	39.55	6
(上年度流行期病例发 生的众数旬次)	② $= 14, 15, 16$	42	64.61	8	54	40.30	6
	③ ≥ 17	15	23.08	4	27	20.15	3
X_2	① ≤ 8	8	12.31	1	62	46.27	7
(上年度流行期病例累 积发生的 P_{10} 旬次)	② $= 9, 10, 11$	28	43.08	6	48	35.82	6
	③ ≥ 12	29	44.62	6	24	17.91	3
X_3	① 流行	41	63.08	8	25	18.66	3
(上年度流行期流行强度)	② 散发	24	36.92	6	109	81.34	9
X_4	① 升高	42	64.62	8	25	18.66	3
(上年度流行期流行趋势)	② 非升高	23	35.38	5	109	81.34	9
X_5	① 大	49	75.38	9	48	35.82	6
(上年度人群流动量)	② 非大	16	24.62	4	86	64.18	8
X_6	① 大	50	76.92	9	37	27.61	4
(本年度的人群流动量)	② 非大	15	23.08	4	97	72.39	9

注：指数系根据百分比查表1而求得

… A_G 表示类别，当某样品各指标值分别为 S_1, S_2, \dots, S_m 时，属于 A_G 类的概率 $P(A_G/S_1 S_2 \dots S_m)$ 为下式（公式1）：

$$P(A_G/S_1 S_2 \dots S_m) = \frac{P(A_G)P(S_1/A_G)P(S_2/A_G)\dots P(S_m/A_G)}{\sum_{G=1}^g P(A_G)P(S_1/A_G)P(S_2/A_G)\dots P(S_m/A_G)}$$

流行年度。流行分类标准为：流行期（11月～7月）的罹患率 $\geq 50/10$ 万为流行， $< 50/10$ 万为散发、因变量 Y 为流行规模，按流行、散发作两类定性预测，自变量（预报因子）6个， $X_1 \sim X_6$ 。从10个地区1960～1980年中剔除罹患率值恰在 $50/10$ 万左右的样本11个，实际应用了199个样本，其中流行年65个，散发年134个（详见表2）。已知甲地区1983年 $X_1 \sim X_6$ 的观测值分别为②、③、②、①、②、②，试用尤度法对该年流行规模进行预测。

依据已知条件，对照表2中的相应值，得：

$$H_1 = 8 + 6 + 6 + 8 + 4 + 4 = 36$$

$$H_2 = 6 + 3 + 9 + 3 + 8 + 9 = 38$$

$H_2 > H_1$ ，结果预测1983年为散发。

四、Bayes 概率法：这种方法与尤度法相似。如果以 X_1, X_2, \dots, X_m 表示指标（自变量）， $A_1, A_2,$

式中 $P(A_G)$ 为事前概率，不知时可用实际发生的频率来估计。比较计算所得的各 $P(A_G/S_1 S_2 \dots S_m)$ 值，若 $P(A_f/S_1 S_2 \dots S_m)$ 最大，则判断该年属 A_f 类。其值即系判定为 A_f 类的事后概率。

〔例2〕将例1用 Bayes 概率法进行预测

把原题的事前概率求出，得：

$$P(A_1) = 65/199 \times 100\% = 32.38\%$$

$$P(A_2) = 134/199 \times 100\% = 67.62\%$$

再把有关数据代入公式1，得：

$$P(A_1/S_1S_2\cdots S_6) =$$

$$\frac{3238 \times 6461 \times 4462 \times 3692 \times 6462 \times 2462 \times 2308}{3238 \times 6461 \times 4462 \times 3692 \times 6462 \times 2462 \times 2308 + 6162 \times 403 \times 1791 \times 8134 \times 1866 \times 6418 \times 7239} \\ = 26.87\%$$

$$P(A_2/S_1S_2\cdots S_6) =$$

$$\frac{6762 \times 403 \times 1791 \times 8134 \times 1866 \times 6418 \times 7239}{3238 \times 6461 \times 4462 \times 3692 \times 6462 \times 2462 \times 2308 + 6162 \times 403 \times 1791 \times 8134 \times 1866 \times 641.5 \times 7239} \\ = 73.13\%$$

由于 $P(A_2/S_1S_2\cdots S_6)$ 大，故预测1983年流脑为散发，这个预测的事后概率为 73.13%。

五、逐步判别分析：这是一种多类判别的方法，它根据各预报因子的重要性大小，逐个经过F检验，把有显著意义的变量选入判别函数，当引入新的预报因子后，将原判别函数中的判别能力已减弱到使 F 检验不显著的变量剔出函数，直到再无变量能引入函数，亦无已引入函数中的变量需要剔除时为止。计算判别系数，把判别函数最终确定下来。将各个预报因子 X_i ($i=1, 2, \dots, m$) 代入判别函数，计算各 Y_j 值，若 Y_k 在

Y_j 中为最大，即将该年预测为第 K 类。由于逐步判别分析计算量大，需借助于电子计算机来完成计算。

〔例3〕应用某省1970~1979年的疫情资料及气象资料，选取了七个预报因子（当年4~7月平均月气温 ($x_1 \sim x_4$)，前一年10~11月乙脑月发病率 ($x_5 \sim x_6$)，当年7月乙脑月发病率 (x_7)，来预报乙脑的流行程度（年发病率 < 4/10万为第一类散发，> 4/10万、< 15/10万为第二类小流行，> 15/10万为第三类流行）。试应用逐步判别分析建立预报判别函数。

经电子计算机的逐步判别程序运算，得到以下判

表3 数 据 与 结 果

年别	原 始 数 据							原分类	计算后分 类
	X_1	X_2	X_3	X_4	X_5	X_6	X_7		
1970	10.1	17.1	22.0	23.6	0.28	0.020	0.216	2	2
1971	9.7	17.1	22.3	24.3	1.05	0.068	0.427	3	3
1972	9.8	15.6	21.1	25.7	0.90	0.020	0.115	2	2
1973	10.6	15.2	21.3	25.4	0.47	0.014	0.178	2	2
1974	9.0	16.9	20.2	25.0	0.43	0.034	0.254	3	3
1975	12.3	17.4	22.3	24.4	0.31	0.006	0.221	2	2
1976	8.4	16.3	20.1	23.2	0.56	0.008	0.099	1	1
1977	10.4	17.3	21.8	25.5	0.08	0.003	0.210	1	1
1978	10.2	16.6	22.8	25.3	0.12	0.005	0.113	1	1
1979	7.5	17.2	21.8	23.8	0.25	0.024	0.058	1	1

别函数：

$$Y_1 = -2107.13 - 358.07X_1 + 341.84X_3 + 700.14$$

$$X_5 - 38894.78X_6 + 253.03X_7 + 1n0.4$$

$$Y_2 = -1716.57 - 312.04X_1 + 303.70X_3 + 625.17$$

$$X_5 - 34213.04X_6 + 2170.93X_7 + 1n0.4$$

$$Y_3 = -1312.05 - 271.39X_1 + 264.09X_3 + 540.83$$

$$X_5 - 29471.17X_6 + 1916.21X_7 + 1n0.2$$

将10年的资料回代判别函数，结果判别全部正确，又对1980~1982年进行预报，结果1980年判别为一类散发，实际也是一类散发；1981年判别为三类流行，实际为二类小流行；1982年判别为二类小流行，实际也是二类小流行；预报效果基本满意。

六、其他：还有模糊聚类法等。

疾病的定量预测

一、直线预测模型：对于有趋向性的时间序列，

如果时间不长，可以用直线来拟合，而把其波动性作为剩余误差来处理。

[例4] 某市市区1973~1985年肺癌的标化死亡率如下表，试求其直线预测方程，并预测1986年的肺癌标化死亡率。

表4 某市1973~1985年肺癌标化死亡率

年别	肺癌标化死亡率 (/10万)	年别	肺癌标化死亡率 (/10万)
1973	83.8	1981	99.4
1975	86.2	1983	111.9
1977	92.0	1985	117.2
1979	95.1		

应用最小二乘法求直线方程 $\hat{Y} = a + bx$ 。首先以年别为x，以肺癌标化死亡率为Y，求出 $\sum x = 13853$, $\sum x^2 = 27415199$, $\sum Y = 685.6$, $\sum Y^2 = 68098.7$, $\sum XY = 1357120.4$, $n=7$, 回归系数b的计算用下式(公式2)：

$$b = \frac{\sum XY - \frac{\sum X \sum Y}{n}}{\sum X^2 - \frac{(\sum X)^2}{n}}$$

$$\begin{aligned} S_{Y.X} &= \sqrt{\left[\frac{\sum Y^2 - \frac{(\sum Y)^2}{n}}{n} - \frac{\left(\sum XY - \frac{\sum X \sum Y}{n} \right)^2}{\sum X^2 - \frac{(\sum X)^2}{n}} \right] \div (n-2)} \\ &= \sqrt{\left[68098.7 - \frac{(685.6)^2}{7} - \frac{\left(1357120.4 - \frac{13853 \times 685.6}{7} \right)^2}{2741.5199 - \frac{(13853)^2}{7}} \right] \div (7-2)} \\ &= 3.04 \end{aligned}$$

$S_{Y.X}$ 越小，预测越精确。

二、指数曲线预测模型：有些传染病已有行之有效的对策，所以其年发病率的时间序列呈单调下降，而下降的速度又往往与其当时的发病率呈正比，对于这一类型疾病的预测方程，可采用指数曲线的数学模型。

[例5] 某地百日咳由于开展了计划免疫，1980~1984年发病率逐年下降，年发病率(/10万)依次为62.82、51.25、42.07、32.62、21.06。试求其指数曲线预测模型，并求1985年该病年发病率的预测值。

为了简化计算，把年度取其缩减值=年度-1980。求各年发病率Y的自然对数ln Y，结果列于表的第4行，分别求得n=5, $\sum x = 10$, $\bar{x} = 2$, $\sum x^2 = 30$,

$$= \frac{1357120.4 - \frac{13853 \times 685.6}{7}}{27415199 - \frac{(13853)^2}{7}} = 2.8393$$

年别平均数为

$$\bar{X} = \frac{\sum X}{n} = \frac{13853}{7} = 1979$$

肺癌死亡率的平均数为

$$\bar{Y} = \frac{\sum Y}{n} = \frac{685.6}{7} = 97.9429$$

截距a的计算用下式(公式3)：

$$a = \bar{Y} - b\bar{X} = 97.9429 - 2.8393 \times 1979 = -5521.0036$$

直线预报方程为

$$\hat{Y} = -5521.0036 + 2.8393X$$

令X=1986，得1986年该市市区预期肺癌标化死亡率的估计值为 $\hat{Y} = -5521.0036 + 2.8393 \times 1986 = 117.82/10万$

$S_{Y.X}$ 为各Y值距回归线的标准差，它是衡量预测误差大小的统计指标，用下式(公式4)计算：

表5 某地百日咳1980~1984年的年发病率(/10万)

年度	年度缩减值X	年发病率Y	Ln Y	年发病率的估计值 \hat{Y}	剩余误差
1980	0	62.82	4.1403	66.50	-3.68
1981	1	51.25	3.9367	51.08	0.17
1982	2	42.07	3.7393	39.24	2.83
1983	3	32.62	3.4849	30.14	2.48
1984	4	21.06	3.0474	23.15	-2.09
1985	5	(14.36)		17.79	-3.43

$\sum Y' = 18.348625$, $\bar{Y}' = 3.669725$, $\sum XY' = 34.059664$, $\sum Y'^2 = 68.053424$, 将所得有关值代入公式2得：

$$b = \frac{34059664 - \frac{10 \times 18.348625}{5}}{30 - \frac{(10)^2}{5}} = -0.2637586$$

应用公式2, 得:

$$\begin{aligned} a &= \bar{Y} - b\bar{X} = 3.669725 - (-0.2637586) \times 2 \\ &= 4.1972422 \end{aligned}$$

所求的指数曲线预测模型为下式(公式5)得:

$$\hat{Y} = e^{bX+a} = e^{-0.2637586X+4.1972422}$$

预测1985年, 该年缩减值 $x=1985-1980=5$, 代入上式得: $\hat{Y}=17.79$

即1985年预测百日咳的年发病率为 $17.79/10$ 万, 结果实际其年发病率为 $14.36/10$ 万, 二者基本吻合。

预测误差大小可用相关指数来考察, 用下式(公式6):

$$R^2 = 1 - \frac{\sum(Y - \hat{Y})^2}{\sum(Y - \bar{Y})^2}$$

表6

原始数据及用预报方程测得值与实际值的比较

测查类别	年别	X_1	X_2	X_3	X_4	X_5	X_6	X_7	流脑发病率(/10万)		差数
									实际值	预测值	
复	1970	1.737	0.273	0.371	0.637	22.4	5.7	6.5	22.15	22.65	-0.50
	1971	1.914	0.172	0.330	0.947	17.5	22.0	1.7	21.85	20.77	1.08
	1972	1.705	0.160	0.300	0.645	12.7	9.3	12.2	23.70	26.02	-2.32
	1973	1.524	0.189	0.428	0.775	21.4	0.8	3.2	18.90	20.08	-1.18
	1974	1.637	0.204	0.266	0.630	17.7	0.6	0.4	27.94	24.92	3.02
	1975	2.774	0.153	0.385	0.929	0.7	0	9.8	47.93	45.84	2.09
	1976	2.642	0.174	0.257	0.914	17.5	18.6	7.2	36.41	37.98	-1.57
	1977	1.717	0.151	0.255	0.638	73.6	4.3	3.6	26.25	28.01	-1.76
测	1978	0.882	0.131	0.171	0.376	20.7	31.7	4.2	10.94	9.78	1.16
	1979	0.549	0.073	0.151	0.274	1.1	13.7	0.9	10.21	11.52	-1.31
	1980	0.912	0.052	0.110	0.259	36.1	32.4	2.3	16.17	16.37	-0.20
	1981	1.490	0.095	0.185	0.444	3.7	19.5	4.6	28.15	26.05	2.10
预	1982	1.742	0.177	0.316	0.652	48.0	18.6	9.3	21.48	23.74	-2.26

注: $x_1 \sim x_4$ 分别为当年1月, 前1年10~12月流脑月发病率, $x_5 \sim x_7$ 分别为前一年11~12月, 当年1月的降水量

经电子计算机进行逐步回归分析, 在七个预报因子中最后选中四个, 得预报方程为:

$$\begin{aligned} \hat{Y} &= 21.7235x_1 - 44.9128x_2 - 20.7680x_4 - \\ &\quad 0.2345x_6 + 11.7477 \end{aligned}$$

本例, $R^2 = 1 - \frac{32.0987}{1045.5013} = 0.9693$, R^2 接近于1,

说明误差较小。若再预测1986年, 宜把1985年的发病率加进去, 用1980~1985年疫情重新建立预测模型, 这样误差小。

三、应用多元逐步回归分析建立预报方程: 用于根据影响疾病流行的的因素(预报因子)对疾病的流行强度进行定量预测。逐步回归分析的原理是按预报因子对疾病流行的作用大小, 由大到小依次逐个引入回归方程, 每引入一个因子, 都要对方程中每个因子作F检验, 当发现作用无显著意义的因子即予剔除, 每剔除一个因子后, 还要对留在方程中的因子逐个检验, 这样引剔反复, 直到无因子可再引入, 亦无因子需要剔除为止。由于计算冗繁, 本法通常应用电子计算机程序上机计算。

[例6] 应用某省1970~1978年的流脑疫情及气象资料(如下表), 采用逐步回归分析方法建立流脑预报方程(规定选剔预报因子的F界值为2.25)。

该方程的剩余标准差为2.6726, 复相关系数为0.9841, 应用此方程对1970~78年进行复测, 并对1979~82年进行预测, 结果满意(表6)。