

神经网络方法在太阳质子事件 短期预报中的应用

龚建村 薛炳森 刘四清 邹自明 苗 娟

(中国科学院空间科学与应用研究中心 北京 100080)

王家龙

(中国科学院国家天文台)

摘 要

在大量统计结果的基础上,深入研究了太阳质子事件预报机理,总结了质子事件爆发与太阳活动区面积、位置、McIntosh结构、磁结构以及前两天活动区爆发耀斑事件数目之间的关系。然后,在神经网络的基础上建立了太阳质子事件短期预报模型,并对2000年以后12个未参加训练的样本进行测试,结果对事件预报的准确率为83%。此外,我们还利用该模型对2002年1—4月发生的几次质子事件进行了预报试验,结果发现,这期间发生的6次事件都被预报,其中3次质子事件系统预报提前了3天,两次事件预报提前了2天,一次事件提前1天预报。

关键词 太阳质子事件; 短期预报; 神经网络

1 引言

短期太阳质子事件预报已经成为空间环境预报的重要组成部分,而且随着人类的空间活动步伐的加快及空间科学与技术的发展,太阳质子事件的影响越来越受到空间界和某些技术领域的重视。正如Allen等^[1]所指出的,其影响之广、之重是绝对不可忽视的。本文所论及的太阳质子短期预报是指提前1—3天的预报。所谓的质子事件是指在地球附近(即1AU处)测量到的能量 $>10\text{ MeV}$,流量 $\geq 10\text{ pfu}$ 的事件。

20世纪50年代后半期苏联的太阳物理学家就研究了利用太阳活动区磁场及其变化作质子事件的短期预报,到了70年代太阳质子事件短期预报准确率已达到70%以上,但相应的虚报率也较高^{[2],[3]}。Shea^[4]和王家龙^[5]对60年代到90年代质子事件短期预报作了回顾,认为:质子事件短期预报在60—70年代有较大发展,其后直到90年代则进展不大,预报水平提高不多。特别是在太阳活动低年,质子事件短期预报的水平更低。例如,1993年到1995年期间发生的5次事件,几乎没有一次被准确预报。

Lundstedt^[7]在1997年讨论地磁暴预报时,认为人工智能系统的应用可能有助于预测水平的提高。胡雄等^[8]选择了以耀斑爆发时电磁辐射的峰通量、上升时间及积分流量为

* 国家重点基础研究发展规划项目(G2000078408),中国科学院空间科学与应用研究中心空间环境预报中心共同资助项目

2002-11-07 收到原稿, 2003-09-11 收到修定稿

主的 5 个参量作为输入量,完成了一种太阳质子事件警报的神经网络模型,王家龙等^[9]以耀斑爆发时的电磁辐射的峰通量、射电爆发频谱类型和黑子群磁场类型等 8 个参量为输入量完成了另一种警报模型.这两种预测模型的输入量中均有耀斑的日面位置,都取得了较好的效果.王家龙等^[10]于 2000 年用双神经网络模型组成的系统作质子事件警报.他们的模型 I 专用于有/无事件的警报,而模型 II 则是在模型 I 发出有事件的警报后,专门输出质子事件强度等级的预测,因而它是一种组合系统,不同于已有的单模型系统.检验结果表明,该双模型系统在保持对有/无质子事件警报水平的同时,增加了对事件强度等级预测的能力.基于以往的工作及短期预测的实际需要,我们在此文中研究与讨论用神经网络的功能完成一种太阳质子事件的短期预报系统.

2 预报方法与预报参量

太阳质子事件是一种强烈的太阳爆发活动,它需要一个较长的能量积累过程,这就必然伴随着蓄能地区(活动区)的演化,以及其他一些太阳活动特征,如射电辐射背景的变化,通过收集这些信息,有助于我们对太阳质子事件的先兆特征的认识.但是,各种参数及其演化特征错综复杂,很难用规范的统计规律加以简单描述,根据我们以往的研究经验选择基于神经网络的算法对太阳活动数据进行分析并建立预报模式是较好的研究途径.

2.1 预报参量

在预报参量的选取上我们遵照三个原则.其一是选择那些理论上与太阳质子事件的产生或传播有关系的量;其二是选择那些与太阳质子事件的产生或传播有一定的统计关系的量;其三是选择那些容易获取的观测量,以利于预报工作的实际执行.在这三个原则下,我们选取了太阳活动区黑子群的面积 X_1 ,黑子群的 McIntosh 的类型 X_2 ,黑子群的磁类型 X_3 ,活动区内产生的中小级爆发(M 级与 C 级)的数目 X_4 ,全日面 10.7 cm 波长的辐射流量密度 X_5 ,全日面软 X 射线背景辐射强度 X_6 ,以及活动区在日面上的日面经度 X_7 .

实际上,我们对太阳质子事件的预报是需对日面上每一个重要活动区在短期内会不会产生质子事件以及产生何等事件分别进行预测.方法是对被预报的活动区取某一天的上述 7 个参量 $X_1—X_7$,再对该活动区取次日的上述 7 个参量中的前 6 个参量,即 $X_8—X_{13}$.这样,一共有 13 个参量 $X_1—X_{13}$ 作为神经网络预测模型的输入元,预测输出为第 3 日到第 5 日的太阳质子事件情况(无或有以及等级).使用连续两天的参量,是考虑到同一个参量在两天内的变化对质子事件的产生有重要影响.而第二天的输入参量只取前 6 个,不取活动区的日面中经距,是因为连续两天的中经距之间有很肯定的关系.还应该指出的是,神经网络模型中的联系函数是非线性的,并不需要输入参量的分级及数值化是线性的,可以有一定的主观性.这为我们的输入参量数值化过程提供了方便.这样,只需在下面对前 7 个参量($X_1—X_7$)分别给以叙述与解释.

(1) 活动区的黑子群面积

黑子群的面积越大其磁场越强,整个活动区的背景磁场能量越大,相对较小的变化就足以产生较大的爆发^[11].已有的统计工作给出了不同等级黑子群面积对应的 $\geq M$ 级耀斑的产率^[12],我们把它作为粗略的质子耀斑的相对产率.考虑到黑子群面积从 1000 增加

至 2000, 从 2000 增加至 3000 以上, 质子耀斑的产率会成倍或更多地增加, 我们加密了对面积大于 1000 的黑子群等级划分, 将黑子群面积 (S) 分为: $S \leq 200$, $200 < S \leq 500$, $500 < S \leq 1000$, $1000 < S \leq 2000$, $2000 < S \leq 3000$ 和 $S > 3000$ 六个等级. 黑子面积单位为 10^{-6} 太阳半球面积.

(2) 黑子群的 McIntosh 类型

黑子群的 McIntosh 分类是 Zürich 分类的改进, 它不但反映了黑子群中大黑子中间的结构和整群的形态, 更强调了偶极群中间部分是否有小黑子的分布以及小黑子的结构. 此外, 在缺少黑子磁场的观测资料时, McIntosh 分类具有很好的辅助作用. 同时, 作为各级软 X 射线爆发的短期预报参量的黑子群 McIntosh 类型可以通过表 1 转变成各种 McIntosh 类型的黑子群的质子事件产率的粗略近似. 表 1 列出了 X 射线爆发与太阳质子事件的统计关系.

表 1 1989—1991 年软 X 射线爆发与太阳质子事件的统计关系
Table 1 The statistical relation between soft X-rays and solar proton events from 1989 to 1991

	1989	1990	1991	总和
M ₃ —M ₉ 级爆发数	148	62	126	331
质子事件数	8	6	8	22
爆发伴随有质子事件的概率/(%)	5.6	9.7	6.3	6.7
全部 M 级爆发数	584	284	551	1419
质子事件数	8	6	8	22
爆发伴有质子事件的概率/(%)	1.4	2.1	1.5	1.6
全部 X 级爆发数	51	16	49	116
质子事件数	15	6	9	30
爆发伴有质子事件的概率/(%)	29.4	37.5	18.4	25.9

由表 1 可见, 概率是随年代而变化的. 因此这种数值化过程具有相当大的近似性或平均性. 当黑子群的 McIntosh 类型作为预测模型的输入元时, 我们将它们分成 5 类, 如表 2 所示.

表 2 黑子群的 McIntosh 类型作为神经网络模型输入元时的分级
Table 2 The input McIntosh levels of sunspot group to neural network model

级别	1	2	3	4	5
类型	FKC, EKC	FKI, EKI	FHC, FKO, FHI, EHC, DKC	FAI, EHI, EKO, DKI, DKC	FAO, EHO, EAO, EAI, DKO, HKX, DAO, DAC, DAI, DHI, CAO, CKO, CHO

(3) 黑子群的磁类型

黑子群的磁类型反映了黑子群整体的磁场的定性分布, 也反映了局部区域磁场的结构状态. 复杂结构的磁场. 例如 δ 类型结构, 意味着偏离势场较大, 容易被触发而快速释

放能量. 黑子群磁场类型与黑子群面积分级结合起来, 可以明显区别磁能含量与磁结构稳定程度的差异. 参照文献 [12], 我们对作为预报模型输入元之一的黑子群磁场类型使用表 3 的数值化规定.

表 3 黑子群磁类型的归一化数值分级

Table 3 The value to different levels of sunspot group magnetic configuration

黑子群磁类型	α	β	$\beta\gamma, \gamma$	$\delta, \beta\delta, \beta\gamma\delta$	$\gamma\delta$
取值	0.05	0.25	0.35	0.65	0.98

(4) 活动区 C 级和 M 级 X 射线耀斑爆发数

被预报日之前两天和前一天活动区中产生的较低级 (C 级) 和中级 (M 级) 爆发数目的多少, 显示出该活动区中小活动的频繁程度, 是该活动区近期的重要活动历史指标之一. 对已有的质子事件耀斑发生之前的一、二天作中小爆发数的统计, 使我们给出如表 4 和表 5 的输入元的分级.

表 4 活动区在第 1 日产生的 C 级、M 级爆发数的相对数值分级 (用于 X_4)

Table 4 The relative value of C-class and M-class flares during first day

C 级爆发数目/d	0	1	2	≥ 3
取值	0.02	0.13	0.17	0.25
M 级爆发数目/d	0	1—2	3—4	≥ 5
取值	0	0.17	0.30	0.50

表 5 活动区在第 2 日产生的 C 级、M 级爆发数的相对数值分级 (用于 X_{11})

Table 5 The relative value of C-class and M-class flares during second day

C 级爆发数目/d	0	1—2	3—4	≥ 5
取值	0.02	0.22	0.25	0.30
M 级爆发数目/d	0	1—2	3—4	≥ 5
取值	0	0.33	0.50	0.67

(5) 全日面 10.7 cm 和软 X 射线辐射通量

太阳在 10.7 cm 处的射电辐射通量 (以 sfu 为单位) 和软 X 射线波段 (1—8 Å) 的辐射通量 (单位 W/m^2) 是指宁静太阳的背景辐射. 这两种辐射均为太阳的热辐射. 背景辐射增强实际上是太阳热辐射缓变源的辐射增强. 在物理上应理解为, 作为缓变源的主体的日冕凝聚区的数量增加或者物质增加 (密度增加或范围扩大), 也就是有更多的电子被约束在活动区的磁场里, 导致了辐射的增强. 根据简单的统计, 我们规定了这两个输入元的取值分级 (见表 6 和表 7).

表 6 全日面在 10.7 cm 波长处的背景辐射分级与取值 (X_5 和 X_{12})

Table 6 The different levels of 10.7 cm wavelength on whole disk

10.7 cm 辐射通量	< 150	150—199	200—249	250—299	≥ 300
取值	0.28	0.57	0.71	0.86	0.98

表 7 全日面在软 X 射线 (1—8 Å) 背景辐射的分级与取值 (X_6 和 X_{13})

Table 7 The different levels of soft X-ray on whole disk

X 射线级别	<B5	B5—B6	B7—B8	B9—C1.7	C1.8—C2.4	C2.5—C2.9	≥ 300
取值	0.17	0.20	0.25	0.50	0.70	0.90	0.98

注: C 和 B 分别表示乘以 10^{-6} W/m^2 和乘以 10^{-7} W/m^2 .

(6) 活动区在日面上的日面经度 X_7

太阳质子耀斑在日面上的分布具有所谓东西不对称性, 也就是说, 质子耀斑的数目在太阳可见半球面上的分布与耀斑的日面经度有关. 例如文献 [13] 统计了 1977—1982 年质子耀斑随日面经度的分布. 结果是质子耀斑的数目从日面东边缘经中部到日面西边缘有明显的增加趋势, 西边缘的质子耀斑可以是东边缘的 2 倍或更多. 一般认为, 东西不对称是由质子流在行星际空间的传播条件引起的, 与行星际的磁场状态或磁力线形状强烈相关. 在本文的工作中, 我们规定了这个参量 (X_7) 的分级与取值, 如表 8 所示.

表 8 活动区日面经度的分级与取值

Table 8 The different levels of longitude range of region

活动区中经距	90°E—56°E	55°E—26°E	25°E—15°W	16°W—50°W	51°W—90°W
取值	0.13	0.38	0.88	0.98	0.88

2.2 基于神经网络的预报模型

我们在上节提取出了与太阳质子事件相关性最好的几个因子, 分析并给出了他们与太阳质子事件的相关特性. 但对太阳质子事件的预报是一个综合判断过程, 在太阳活动过程中, 上述因子会表现出各种状态, 而太阳质子事件之前, 它们将表现出多种组合的复杂先兆特征, 需要我们加以判断.

要通过人工从众多线索中准确判断出太阳质子事件先兆无疑是非常困难的, 而且由于个人经验的差异, 还会导致误差的产生. 计算机运算速度的提升和计算方法的进展, 使得这些繁杂的运算、推理过程比较容易实现, 我们要做的就是建立一种合适的计算方法, 然后通过大量的事例对计算机进行训练, 使它能够准确地掌握太阳质子事件的先兆特征, 对新输入的太阳活动参数迅速做出事件有无和规模的判断.

我们要选择的计算方法的标准是它要有学习和自我完善的能力, 而神经网络恰好满足了我们的要求.

神经网络是一个大量简单的处理单元广泛连接组成的人工网络, 用来模拟大脑神经系统的结构和功能. 神经元是神经网络的基本计算单元, 一般是多个输入, 一个输出的非线性单元, 通常神经元所接受的输入信号的总和 X_i 尚不能反映神经元输入和输出之间所应有的各种关系. 因此还需用一个特征函数来描述这种关系, 产生一个新的输出.

一般神经网络模型中的动态特性主要表现在各种神经元改变状态的次序, 神经元计算频率和与时间有关的迭代次数的性质等方面. 当网络的动态特性与输入大小有关系时, 即根据输入大小按一定概率模型计算各神经元, 反映神经元输出计算频率及其状态变化过程是由概率决定的, 这种动态特性在求解最优化问题时起着特殊的作用.

利用反向传播的全连接网络如图 1 所示, 用有监督的学习算法进行训练, 其中 $X_i(t)$ 为输入参量, $Y_i(t)$ 为输出参量, 中间 $m+1$ 至 N 个单元为隐含层. 利用权重 W_{ij} 使 $X_i(t)$

与 $Y_i(t)$ 产生相关, 调整 W_{ij} 使计算的输出 $Y_i(t)$ 与实际输出量 $Y_i(t)$ 相接近, 并达到所期望的误差范围, 这一过程即为学习过程. 利用经过学习后得到的 W_{ij} , 输入需用于预测的输入参量, 我们即可得到一组新的输出参量 $Y_i(t)$, 此组 $Y_i(t)$ 即为预报值. 这就是神经网络的学习过程.

神经网络的学习特性十分类似于人们通过训练来得到技能, 学习的目的就是使一组输入参量, 通过确定的过程 (算法) 调整网络的权值, 产生一组已知的或者是所希望的输出参量, 在整个学习过程中网络的权值是慢慢变更的. 学习训练可分为监督和无监督两类: 监督训练的样本要求每一个输入参量与表示所需输出的目标参量配对, 通常训练一个神经网络要求许多这样配对的样本. 在训练时用训练样本的输入参量, 计算出网络的输出参量, 再与训练样本的目标参量比较, 如存在误差再用算法按误差减小的方向改变网络的权值, 直到整个训练集的误差达到可接受的程度为止.




图 1 全连接神经网络示意图

Fig.1 The profile of artificial neural network

我们依照这一过程, 用实测的太阳活动数据对神经网络进行训练, 这些数据包括有和没有太阳质子事件的情况, 网络经过反复的学习后, 积累了一定的“预报经验”. 我们用参加过训练的数据对神经网络模式进行了回测, 结果网络对太阳质子事件预报的准确率达到到了 90% 以上, 经过多组数据的测试后, 证明模式已具备了较好的稳定性.

完成基于神经网络的预报模式的测试后, 我们用没有参加过训练的历史数据和最新的监测数据, 再次对模式的准确性进行验证, 都取得了较好的效果.

3 模型验证和预报试验结果

3.1 抽样验证结果

在建立模型过程中, 取 2000 年以前太阳质子事件为样本, 训练神经网络; 取 2000 年以后的 12 个样本进行样本试验. 表 9 列出了预测与实测的比较.

实测项目的 0.1 代表无质子事件, 0.9 代表有质子事件. 预测项中, 以 ≥ 0.5 为有质子事件, < 0.5 为无质子事件. 因此, 由表 9 可知在 12 次预报中报错 2 次, 报准率约为 83% (注: 预报的总报准率是指做出正确预报的总次数 t (含正确预报有质子事件与正确预报无质子事件两类次数) 与实际发生的总数 T (含有质子事件实际的次数与无质子事件的次数) 之比, 即 $R = t/T$).

表 9 神经网络模型的检测试验
Table 9 The test of neural network model

预测	0.51	1.00	0.80	0.38	1.00	1.00
实测	0.90	0.90	0.90	0.90	0.90	0.90
预测	1.00	0.92	0.76	0.06	0.42	0.41
实测	0.90	0.90	0.10	0.10	0.10	0.10

3.2 事件预报

下面我们通过模型对 2001 年 1—4 月发生质子事件的预报情况与实际发生情况进行对比, 结果是 2001 年 1 月至 4 月 27 日, 共发生质子事件 6 次. 本系统对该 6 次质子事件都能提前做出正确的预报. 其中 3 次事件, 系统预报提前了 3 天; 两次事件预报提前了两天; 一次事件是提前一天预报的.

3.3 2001 年 4 月的预报试验

同时我们对 2001 年 4 月 1—23 日每天对未来三天是否发生质子事件进行了预报试验. 将预报结果与实际发生情况比较, 结果是在试验的 23 天中, 有 13 天模型准确地预报了未来 3 天是否发生质子事件, 报准率约为 56.5%; 有 7 天预报未来 3 天会发生质子事件, 但实际并未发生, 预报结果为虚报; 有 3 天, 模型预报结果为未来 3 天不发生质子事件, 但实际后三天有质子事件发生, 预报结果为漏报.

4 结论与讨论

通过以上对模型的验证结果可以得出如下结论.

(1) 模型对事件的预报能力很强. 而对无质子事件时间段的预报结果欠佳, 虚报率较高. 造成这种结果的主要原因是, 用于训练的样本有质子事件和无质子事件的比例与实际情况相差较大. 样本挑选的一个前提条件是有中等以上耀斑或质子事件爆发. 所以, 在此基础上训练的模型参数对质子耀斑爆发可能性预测结果较好. 要将平静时期无质子事件预报准确, 还需要在训练中多加入无质子事件、无耀斑爆发的平静期样本.

(2) 由于质子加速机制有两种, 除耀斑和 CME 加速外, 还有一种就是激波加速机制. 由于激波加速引起的质子事件, 也可能没有大的耀斑事件相对应. 所以, 模型对这种机制产生的质子事件的预报能力偏弱.

(3) 预报因子的选取还受到观测手段的限制. 最新的研究表明, 太阳质子事件的产生与活动区的磁结构特征关系密切. 因此, 如果在预报因子的选取上, 加上活动区的精细结构特征, 可以进一步提高对质子事件的预报水平.

参 考 文 献

- [1] Allen J H, Wilkinson D C. Solar-terrestrial activity affecting system in space and on earth. In: Hruska J *et al* ed. Solar-Terrestrial Predictions-IV, Ottawa: NOAA, 1993, 175—107
- [2] Simon P, McIntosh P S. Survey of current solar forecast centers. In: McIntosh P S, Dryer M ed. Solar Activity Observations and Predictions, Alpine Press Inc., 1972, 343—358
- [3] Solar Activity Prediction Group of Beijing Astronomy Observatory, In: Donnelly R F eds. Solar-Terrestrial Predictions Proc., Boulder, NOAA, 1979, 154—162
- [4] Shea M A, Smart D F. Solar proton events: History, statistics and predictions. In: Hruska A *et al* eds., Solar-Terrestrial Predictions-IV, Ottawa: NOAA, 1993, 48—70
- [5] Wang Jialong. A review of the short-term prediction of solar proton event flares. *Chin. J. Astron. Astrophys.*, 1999, **19**(4):412—418. in Chinese (王家龙. 太阳质子事件耀斑的短期预报. 天体物理学报, 1999, **19**(4):412—418)
- [6] Meidig D *et al*. Objective forecasts for solar flares. In: Solar-Terrestrial Predictions: Proceedings of a Workshop at Meudon, 1986. 300—305
- [7] Lundstedt H. Coronal Mass Ejections. In: Proc. Chapman Conf., 1997. 13—16
- [8] Hu Xiong *et al*. Warning of solar proton events. *Chin. J. Space Sci.*, 1998, **18**(4):323—328. in Chinese (胡雄等. 太阳质子事件警报. 空间科学学报, 1998, **18**(4):323—328)
- [9] Wang Jialong, Zhang Xunjie, Huang Zerong. A neural network method for solar proton event warning. *Chin. J. Astron. Astrophys.*, 1999, **19**(3):318—323. in Chinese (王家龙, 张训械, 黄泽荣. 神经网络用于太阳质子事件警报. 天体物理学报, 1999, **19**(3):318—323)
- [10] Wang Jialong, Sun Jinglan, Gong Jiancun, Zhang Xunjie. A two-pass neural network method for proton events warning. *Chin. Sci.*, 2000, **30**(supp.):92—95. in Chinese (王家龙, 孙敬兰, 龚建村, 张训械. 二阶神经网络用于太阳质子事件警报. 中国科学, 2000, **30**(增刊):92—95)
- [11] Shi Zhongxian. Relation of solar flares with magnetic field. In: Hu Wenrui *et al*. ed. Solar flares. Beijing: Science Press, 1983. 77—110. in Chinese (史忠先. 耀斑与磁场的关系. 见: 胡文瑞等编, 太阳耀斑. 北京: 科学出版社, 1983. 77—110)
- [12] Zhang Guiqing *et al*. Short-term prediction of X-ray bursts. *Prog. Geophys.*, 1994, **9**(supp.):48—53. in Chinese (张桂清. 短期 X 射线耀斑预报. 地球物理学进展, 1994, **9**(增刊):48—53)
- [13] Wang Jialong, Zhang Borong. On solar activity predictions. *Prog. Astron.*, 1990, **8**(2):89—97. in Chinese (王家龙, 张柏荣. 太阳活动预报简论. 天文学进展, 1990, **8**(2):89—97)

SHORT TERM FORECAST OF SOLAR PROTON EVENT

GONG Jiancun XUE Bingsen LIU Siqing ZOU Ziming MIAO Juan
(Center for Space Science and Applied Research, The Chinese Academy of Sciences, Beijing 100080)

WANG Jialong
(Notional Astronomical Observatories, The Chinese Academy of Sciences)

Abstract

Solar Proton Events (SPE) are one kind of the major, severe space environmental events that induces errors even failure of the satellites on the orbit. In this paper, a model of SPE forecasting employing artificial neural network technology by Space Environment Prediction Center (SEPC) is introduced.

The strength of solar event is related with released from the solar burst. The size of area of the sunspot indicates the maximum strength of local magnetic field. The McIntosh classification of the sunspot indicates the structure of the root area of the magnetic rope from the sunspot regions. The joint applying of the McIntosh classification and the magnetic type enable us to describe the structure of the sunspot.

In this paper, 10.7 cm radio and X-ray fluxes were used, and the Artificial Neural Network (ANN) is employed. The digitized morphology data are then arranged and “feed” into the neural network. Through training the model based on ANN algorithm a forecast model was constructed. With it, the forecast of SPE 1—3 days ahead can be made. Statistics shows that the accuracy of our forecast is about 80%.

Key words Solar proton event, Forecast, Artificial neural network