

利用人工神经网络进行激光等离子体诊断

宋向阳 韩申生 徐至展 黎忠 张令清 张正泉

(中国科学院上海光学精密机械研究所, 上海 201800)

摘 要 利用前馈神经网络对激光等离子体打靶实验中所得的 X 光光谱数据进行处理, 可以方便地求出等离子体的电子温度和电子密度等参数。在对网络的训练时采用误差信号反向传输算法, 训练后的神经网络能够有效地对 X 光光谱数据进行处理。文中给出了用此法算出的 Mg 等离子体电子温度和电子密度的空间分布轮廓, 与用传统方法所得的结果完全吻合。

关键词 人工神经网络, X 射线光谱分析。

1 引 言

神经网络系统是由大量简单的神经元广泛相互连接而成的一种空间不规则的拓扑结构。它是迄今所知功能最强、效率最高的最完美的信息处理系统, 人工神经网络已经被应用于图像处理、模式识别及语音综合等领域。由于人工神经网络具有良好的自适应性、自组织性, 以及很强的学习能力、联想功能和容错性能等诸多优点, 所以用它来对实验数据进行处理将是对传统的实验数据分析方法的一个突破。

在激光等离子体实验中, 运用现代先进的测量仪器可以获得各诊断参量的空间位置、时间演化及光子能量等许多与等离子体状态有关的信息, 但是用传统的数据分析方法从实验数据推导等离子体参数往往十分耗时、困难甚至完全不可能。而利用人工神经网络可以有效、即时地对实验数据进行处理, 所以人工神经网络越来越受到实验物理学家的重视^[1~5]。

2 前馈神经网络与误差反向传输算法

近几年来有关神经网络的研究取得了飞速的发展, 目前已有几十种不同类型的人工神经网络模型, 在不同应用领域都有各自不同的模型来解决某些特定的问题。多层前馈神经网络可以有效地对大量的数据进行归纳和分类, 实现从输入到输出层的信息转换, 在输入和输出层中间可以有一个或多个隐式层, 每层含若干个结点, 称为节点或神经元。输入信号先向前传播到隐节点层, 经过非线性作用函数后, 再把隐节点的输出信号传播到输出节点。节点的激励函数通常选用 S 型函数^[5]:

$$g(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

前馈神经网络中比较成熟的模型是基于反向传播训练算法的多层神经网络模型, 反向传

播算法的学习过程由正向传播和反向传播两部分组成, 在正向传播过程中, 输入模式从输入层经隐单元逐层处理并传向输出层, 每一层的神经元状态只影响下一层神经元状态。如果在输出层得不到期望的输出, 则转入反向传播。此时误差信号从输出层向输入层传播并沿途调整各层间的连接权值以及各层神经元的偏置值, 以使误差信号不断减小。该算法实际上是把一组数据样本问题转化成一个非线性优化的问题。

网络训练开始时, 取一组随机数对权系进行初始化。然后把一训练样本事例从输入节点输入神经网络到达输出节点。每一层节点 j 的输出是上一层所有信号加权和:

$$x_j = g(\sum w_{jk}x_k) \quad (2)$$

其中 g 为非线性激励函数[一般取 Sigmoid 型, 如(1)式], w_{jk} 是连接节点 j 和 k 的权重值, x_k 为上层节点 k 的输出。在输出层, 计算误差函数 E , E 一般和各输出节点值与期望之差的平方和成正比。为使 E 逐步减小, 由线性规划中的最快速下降算法, 求出各层权系的修正项:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = \eta \delta_i x_j, \quad (3)$$

其中 η 称为学习强度或学习步长。

$$\delta_i = g'(\sum w_{ij}) |o_i - x_i|, \quad (4)$$

其中 g' 是相应于 w_{ij} 的激励函数的微分, o_i 为期望输出值。

对训练样本中的每一个事例执行上述过程, 整个样本完成一次后, 权系的量级将确定。重复上述过程并修改权重值, 直到误差函数 E 的值达到收敛标准。为了改善收敛特性, 常常引入一个动量项 α 以抑制训练过程中产生的振荡。此时权值更新量 Δw_{ij} 的修正公式为:

$$\Delta w_{ij}^{k+1} = \eta \delta_i x_j + \alpha \Delta_{ij}^k, \quad (5)$$

即后一次的仅值更新 Δw_{ij}^{k+1} 应适当地考虑到上一次的权值更新值 Δw_{ij}^k 。训练时取 $\eta = 0.001$, $\alpha = 0.95$ 。为加快收敛速度可以对学习强度进行自适应调节, 如果新的误差函数值 E_{new} 大于原先的 E_{old} (当 $E_{new}/E_{old} > 1.04$ 时), 则降低学习强度(一般缩小 0.7), 当 $E_{new} < E_{old}$ 时, 加大学习强度(一般扩大 1.05), 在 $1 \leq E_{new}/E_{old} \leq 1.04$ 范围内学习强度不变。

3 神经网络的设计与训练

在激光等离子体打靶中, 对等离子体状态最有效的诊断方法之一是对靶物质中所含元素的多电荷离子态所发射的线光谱进行测量分析。目前常用的方法有: 利用类 H 或类 He 离子的共振线与它们伴线的强度比来确定等离子体的电子温度; 利用类 He 离子的共振线和互组合线的强度比确定等离子体的电子密度^[6]。前一方法中的谱线强度比与电子密度无关, 所以可以先由它测量电子温度; 然后再由电子温度和后一方法中的谱线强度比来确定电子密度。为此设计了两个子神经网络, 一个用来计算电子温度, 这一网络有三个输入节点, 分别输入元素的原子序数 Z 、类 H 共振线强度 I_r 及其伴线的强度 I_s , 包含有两个隐式层分别有 8 个隐式节点, 该网络最后输出电子温度 T_e 。另一个子网络有四个输入节点, 分别为原子序数 Z 、电




Fig. 1 A multilayer perceptron neural network nonlinearly transforms an input pattern to an output pattern

子温度 T_e 、类 He 离子共振线强度 I_r 及互组合线强度 I_c ，只有一个隐式层含 10 个节点，输出为电子密度。然后再由这两个子网络组成一个网络系统，如图 2 所示。

对神经网络训练首先要有一套相互独立的训练事例样本，样本中有几十或上百个输入-输出对。输入端的 Z 值、类 H、He 谱线和互组合线与伴线的强度以及输出端的电子温度 T_e 、电子密度 N_e ，由理论模型计算给出^[6]，电子温度的范围为 50~100 eV，电子密度的范围为 $1.0 \times 10^{18} \sim 1.0 \times 10^{21} \text{ cm}^{-3}$ ，这组数据与实验数据无关。

神经网络在经过大量样本事例的训练之后将得到一个正确的权系并加以存储，在实际应用中只需要把线光谱的强度输入已训练好的神经网络，它就会通过在训练时所学到的存储于其权系中的知识正确地产生相应的输出。图 3 是从光谱数据利用已经训练好的神经网络分析得出的线状 Mg 等离子体距靶面不同处的电子温度和电子密度，与用常规方法所得结果完全一致^[7]。

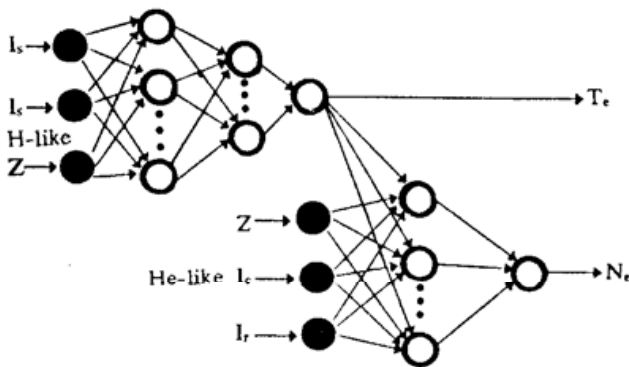


Fig. 2 Network structure used for determining electron temperatures and electron densities




Fig. 3 Line shaped Mg laser plasma electron temperature (□) and electron density (×) versus distance from the target deduced from the neural network

4 讨 论

网络模型设计的好坏将直接影响输出的结果，所以需要经过多次验算来确定网络的层数、每层的结点数以及期望的输入与输出的大小等。本文设计的网络是由两个子网络组成，可以对每个子网络分别验算并根据其收敛程度对它们进行合理的设计。图 4 为确定电子温度的子网络在训练过程中误差函数 E 随训练次数的变化情况，在选取两个隐式层(第一层 8 个神经元，第二层 6 个神经元)时收敛效果最佳。

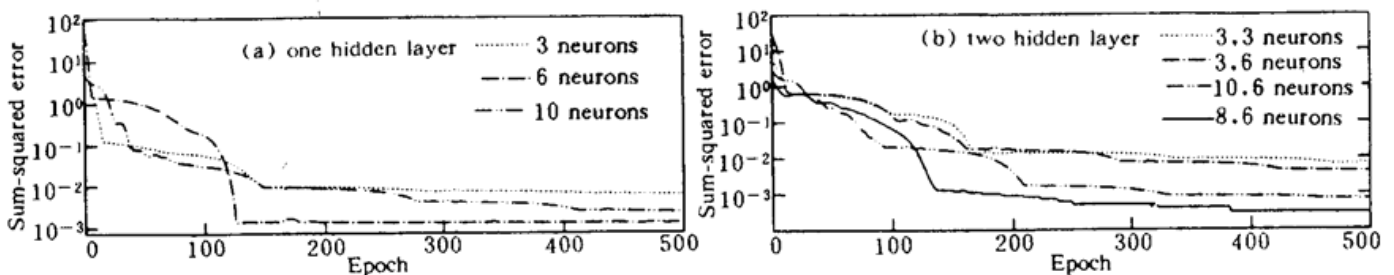


Fig. 4 A plot of (a) one hidden layer (b) two hidden layers neural network sum-squared error vs. training epochs

由于前馈神经网络采用有监督的反向传输方法进行训练，所以其函数操作功能依赖于所

选取的事例样本, 等离子体光谱诊断模型相对比较简单、直观, 训练所耗机时也要小, 但是对所测的电子温度和电子密度范围有一定的限制, 从图 3 可以看出在近靶面处(150 μm 以内)所测的电子密度误差较大, 但这与网络无关; 如果要求精度更高则必须借助大型的产生高温等离子体 X 射线的辐射输运程序来获得训练样本, 但这必然要占用大量的机时来对网络进行训练^[1], 所以在对网络训练之前要根据具体情况对提供样本的理论模型进行筛选。

结 论 设计了一种用于激光等离子体光谱诊断中数据分析的前馈神经网络模型, 并且利用比较简单的理论模型产生的光谱数据对该网络进行训练, 训练后的神经网络能即时、有效地对实验光谱数据进行处理。

参 考 文 献

- [1] A. L. Osterheld, W. L. Morgan, J. T. Larsen *et al.*, Analysis of spectra from laser produced plasmas using a neural network. *Phys. Rev. Lett.*, 1994, 73(11): 1505~1508
- [2] W. L. Morgan, The feasibility of using neural networks to obtain cross section from electron swarm data. *IEEE Tran. Plasma Science*, 1991, 19(2): 250~255
- [3] K. L. Peterson, Classification of Cm I energy levels using counterpropagation neural networks. *Phys. Rev. (A)*, 1990, 41(5): 2457~2461
- [4] K. Tanabe, T. Tamura, H. Uesaka, Neural network system for the identification of infrared spectra. *Appl. Spectrosc.*, 1992, 46(5): 807~810
- [5] C. M. Bishop, Neural networks and their applications. *Rev. Scient. Instrum.*, 1994, 65(6): 1803~1832
- [6] E. V. Aglitskii, V. A. Boiko, A. V. Binogradov *et al.*, Diagnostic of dense laser plasmas based on the spectra of hydrogen-like and helium-like multiply charged ions. *Sov. J. Quant. Electron.*, 1974, 4(3): 322~329
- [7] Han Shensheng, Zhang Lingqing *et al.*, Experimental study on the properties of line-shaped laser-plasma. *Chin. Phys. Lett.*, 1994, 11(5): 277~280

Laser Plasma Spectral Diagnostic Using a Neural Network

Song Xiangyang Han Shensheng Xu Zhizhan Li Zhong
Zhang Lingqing Zhang Zhengquan

(Shanghai Institute of Optics and Fine Mechanism, Chinese Academy of Sciences, Shanghai 201800)

(Received 28 March 1995; revised 29 May 1995)

Abstract A feedforward neural network is applied to the analysis of K-shell X-ray line spectra from a laser produced plasma, and to the accurate determination of the plasma parameters. After training on error backpropagation algorithm, the network can effectively produce the electron temperatures and the electron densities. The use of this method for X-ray is illustrated. Spectroscopy of a high density and high temperature Mg plasma is illustrated. The both parameters are produced, and agree well with the results from conventional method.

Key words neural network, analysis of X-ray line spectra.