

文章编号: 1007-4609(2000)增-0031-07

利用遗传算法优化神经网络实现混合 像元组分参数的反演

庄家礼, 陈良富, 徐希孺

(北京大学 遥感与地理信息系统研究所, 北京 100871)

摘 要: 采用热红外多波段遥感数据反演陆面温度 (LST), 由于波段间信息高度相关, 以及难以直接反演混合像元组分温度, 使得 LST 的反演精度和应用价值都受到很大的限制。在建立非同温混合像元热辐射方向性模型基础上指出, 热红外多角度遥感提供了反演组分温度的可能性, 但是, 由于该模型是采用蒙特卡洛方法模拟而建立起来的数值概念模型, 采用一般反演方法很难同时提取所有参数信息。为了有效获取各参数信息, 使用神经网络模型。由于待反演参数中, 组分温度、土壤比辐射率和叶面积指数 (LAI) 都是多角度辐射亮度的非线性函数, 然而, 使用经典的误差后传 (BP) 算法容易陷入局部最优解区域; 虽然遗传算法 (GA) 可以搜索到全局最优解, 但在微机上实现算法速度太慢, 因此, 采用 GA 训练神经网络, 得到网络权重, 然后再以 GA 训练得到的权重作为 BP 算法的初始权重, 继续训练神经网络, 直到获得满意结果。这样既可以发挥 BP 算法快速寻优的特点, 又能得到网络权重的最优组合。数值模拟的结果表明, 基于非同温混合像元热辐射方向性模型, 采用 GA 优化的神经网络模型反演多维参数效果比较理想。

关 词: 多角度热红外遥感; 混合像元热辐射方向性模型; 遗传算法; 神经网络

中图分类号: TP722.5/P423.3 **文献标识码:** A

1 引 言

反演陆面温度 (LST) 的困难之一是陆面目标绝大多数是混合像元, 到目前为止 LST 的反演研究还集中于热红外多波段遥感的范畴内, 它的致命弱点首先是由于波段间信息高度相关^[1]而使反演结果对测量误差较为敏感; 其次, 由于多波段遥感数据中不含有同步目标三维几何结构信息, 因此混合像元只能作为整体来处理, 即使采用比辐射率与温度同步反演技术^[2], 也只能得到混合像元的平均比辐射率值和平均温度值, 而它们的物理含义是含混不清的。真正物理意义明确, 有应用价值的参数是组分温度与组分有效比辐射率。比如对由植被与土壤组成的两相混合像元而言, 获得了植被冠层温度 (T_v) 便可计算植被水分蒸腾量^[3], 进而推算出作物的干物质产量、作物缺水指数 (CWSI) 和二氧

化碳消耗量等遥感作物估产、旱情监测和全球变化研究中的关键因子。相比之下, 求得混合像元的平均温度对解决上述种种问题没有直接的帮助。为了摸清非同温混合像元中多角度辐射亮度与组物理参数和体系几何结构参数的关系, 我们建立了非同温混合像元热辐射方向性模型^[4, 5], 并指出利用多角度热红外遥感数据反演组分温度是可行的^[6]。然而, 由于有效组分比辐射率的计算必须依赖于蒙特卡洛模拟, 所以辐射亮度的方向性变化规律不能和组物理参数、体系几何结构参数建立具体的解析表达关系^[5]。因此, 无法计算梯度, 也就不能实施直接搜索, 这样, 传统的依靠梯度信息优化反演的方法不能使用, 必须寻找新的反演方法。

近些年来, 神经网络技术在多维参数的遥感反演中得到了广泛应用。Smith^[7]利用多层前向神经网络从遥感数据中估算 LAI。网络能够从反射率和

收稿日期: 1999-12-15; 修订日期: 2000-08-10

基金项目: 国家“九五”攀登预选项目 95-预-38。

作者简介: 庄家礼 (1969—), 男, 1997年毕业于中国科学院水土保持研究所水土保持专业。现为北京大学遥感与地理信息系统研究所博士研究生, 主要从事遥感信息建模与反演研究。

NDVI 数据中映射 LAI, 其精度可与地面观测得到的精度相比较。当应用到不同的土壤背景时, 神经网络技术比标准的回归技术更为稳健。Abuelgasim 等人^[8]的研究表明, 神经网络技术在冠层方向性反射率正向和反演建模中能够发挥关键作用。Gong 等人^[9]利用 BP 算法的神经网络, 采用一个冠层反射率模型计算的数据训练神经网络, 反演 LAI、叶倾角分布函数等冠层、大气和土壤参数。结果表明, 反演效果较好, 但是, 随着反演参数维数的增加, 反演精度降低, 反演花费的时间大量增加。BP 算法及其变形虽然计算速度较快, 但是由于其使用的最速下降算法或者共扼梯度算法难以找到全局最优解, 因此, 必须采用模拟热处理或者遗传算法 (GA) 等全局搜索的优化算法进行网络权重的优化^[10, 11]。但是, 利用 GA 优化神经网络的权重速度较慢, 在微机上实现需要花费大量的机时。因此, 在本研究中, 我们首先采用 GA 训练神经网络, 得到网络权重, 然后再以 GA 训练得到的权重作为 BP 算法的初始权重, 继续训练神经网络, 直到获得满意结果。这样既可以发挥 BP 算法快速寻优的特点, 又能得到网络权重的最优组合。

2 数据模拟

2.1 非同温混合像元热辐射方向性模型

众所周知, 同温同质非黑体的热辐射亮度在 2π 空间的分布规律问题早在本世纪初因引入比辐射率概念而获得解决: 即 $L_\lambda(\theta, T) = \varepsilon_\lambda(\theta) \cdot B_\lambda(T)$, 其中 $B_\lambda(T)$ 是温度为 T 时, λ 波段的普朗克黑体辐射公式。基于基尔霍夫定律, 对于光滑介面, 比辐射率 $\varepsilon_\lambda(\theta)$ 的方向性规律可通过菲涅尔公式计算, 绝对粗糙面的比辐射率不随角度而变化 (朗伯体), 而一般粗糙面比辐射率随视角天顶角 θ 的增加而逐渐减少, 但目前还没有一般的理论计算公式, 只有通过测量才能获得 $\varepsilon_\lambda(\theta)$ 的具体函数形式, 显然它与表面粗糙度及目标的介电常数有关。

至于非同温非黑体混合像元的热辐射方向性的一般规律, 只是在近年来才被遥感学家所认真研究, 我们认为解决这一问题的基本出发点应是:

(1) 在地球环境下, 投射到物体上的热辐射通量密度 (Irradiance) 主要来自周围环境, 直接来自太阳的热辐射是微弱的, 可以忽略不计^[11]。因此物体与周围环境互为热辐射源, 物体间的多次散射不可忽略, 虽然大多数地物垂直比辐射率一般高于 0.9。

(2) 对介质而言 (非导体), 在地球环境条件下, 比辐射率不是温度的函数^[13]。

(3) 严格意义下的热平衡条件是不存在的, 但地球环境条件下的“局地热平衡”是普遍满足的^[12]。我们的非同温混合像元热辐射方向性模型, 可以归纳为如下 3 个等式^[4]:

$$\begin{aligned} L_\lambda(\theta) &= \sum_{k=1}^n \varepsilon_{k\lambda,e}(\theta) \cdot B_\lambda(T_k) \\ \varepsilon_{\lambda,e}(\theta) &= \sum_{k=1}^n \varepsilon_{k\lambda,e}(\theta) \\ \varepsilon_{\lambda,e}(\theta) &= 1 - \rho_{\theta \rightarrow \Omega} \end{aligned} \quad (1)$$

此处脚标“ k ”代表混合像元中的组分排序, 脚标“ e ”代表“等效”之意。 $\varepsilon_{\lambda,e}(\theta)$ 代表混合像元作为一个整体所具有的有效比辐射率, 此值的作用不在于计算该体系在 θ 方向热辐射亮度, 而在于计算它对周围环境辐射 (比如大气下行辐射) 的反射, $\rho_{\theta \rightarrow \Omega}$ 为体系的方向一半球反射率。野外验证结果表明^[4, 5], 非同温混合像元热辐射方向性模型较为准确地揭示了组分温度、组分比辐射率、冠层几何结构参数和方向性辐射亮度之间的关系。

2.2 数据模拟

对于连续植被 (植被冠层和背景土壤) 的两相混合像元, 热辐射亮度值的方向性规律可以表达为如下形式:

$$L_\lambda(\theta) = \varepsilon_{ve}(\theta) B_\lambda(T_v) + \varepsilon_{se}(\theta) B_\lambda(T_s) \quad (2)$$

其中 $L_\lambda(\theta)$ 是在 λ 波段、 θ 视角方向上混合像元的辐射亮度值; T_v 和 T_s 分别为植被冠层和土壤的温度; $\varepsilon_{ve}(\theta)$ 和 $\varepsilon_{se}(\theta)$ 分别为植被冠层和土壤表面的有效比辐射率。

以喜直型冬小麦为例, 在冬小麦叶倾角分布函数已知, 单叶片比辐射率为朗伯体 (其值为 0.97), 土壤比辐射率也为朗伯体, 但它是一个只受土壤含水量控制的未知参数时, 我们采用 Monte Carlo 方法对 LAI 和土壤比辐射率 ε_s 取不同值时的 $\varepsilon_{ve}(\theta)$ 和 $\varepsilon_{se}(\theta)$ 进行了模拟。得到了组分有效比辐射率, 再考虑不同的组分温度组合, 就可以计算出给定波段 λ 不同角度的辐射亮度 $L_\lambda(\theta)$ 了。

各参数的取值范围分别为: $1.0 \leq \text{LAI} \leq 5.0$; $0.9 \leq \varepsilon_s \leq 1.0$; $290\text{K} \leq T_v \leq 300\text{K}$; $295\text{K} \leq T_s \leq 305\text{K}$ 。选取不同的 LAI、 ε_s 组合, 利用 Monte Carlo 方法得到视角天顶角 0° 、 15° 、 30° 和 45° 的组分有效比

辐射率 ε_{ve} 和 ε_{se} 。利用方程 (2)，即可计算不同组分温度时不同角度辐射亮度。我们把 4 个角度的辐射亮度作为网络的输入，其对应的 4 个参数作为网络的输出，组成输入-输出对。

3 模型参数的神经网络反演

3.1 神经网络多层感知器

该文使用的神经网络多层感知器 (MLP)，最早由 Rumelhart 等人^[14]提出。MLP 的结构如图 1 所示，它由一个输入层，一个隐藏层和一个输出层组成，层间以不同的权重连接。这样的神经网络经过训练后可以匹配任意一种输入输出之间的映射关系^[15]。一旦神经网络的训练完成，就可以用它来根据已知的观测值反演出合适的参数输入。




图 1 MLP 体系结构

Fig.1 The architecture of MLP

前向反馈概念

在 MLP 算法中，输入模式（数据样本）经过输入层提供给网络，输入信号以前向反馈的方式传递到下一层中的神经元。随着信号从一个神经元传递到另一个神经元，它被神经元间连接的权重所修改。接收神经元对来自与之相连接的前一层中的所有神经元的加权信号求和。对于隐藏层神经元：

$$net_{pj}^h = \sum_{i=1}^N w_{ji}^h x_{pi} + \theta_j^h \quad (3)$$

对于输出层神经元：

$$net_{pk}^o = \sum_{i=1}^L w_{kj}^o i_{pj} + \theta_k^o \quad (4)$$

其中， w_{ji}^h ， w_{kj}^o 表示神经元之间的权重，上标 h ， o 分别表示隐藏层和输出层； x_{pi} ， i_{pj} 分别表示第 p 个输入模式中第 i 个输入层神经元和第 j 个隐藏层神经元的输入； θ 为偏见值 (bias)； N 和 L 分别为输入层和隐藏层的神经元数目。

隐藏层中神经元的输出（以 logistic 函数为例）

为：

$$i_{pj} = f_j^h(net_{pj}^h) = \frac{1}{1 + e^{-net_{pj}^h}} \quad (5)$$

输出层中神经元的输出为：

$$o_{pk} = f_k^o(net_{pk}^o) = \frac{1}{1 + e^{-net_{pk}^o}} \quad (6)$$

函数 f 一般是一个非线性的 sigmoid 函数，在信号传递到下一层之前，把它应用到输入的加权和。当信号到达输出层，它就形成了网络的输出。如果函数 f 是线性的，则神经网络只能处理线性可分的数据；只有非线性的函数才能处理非线性可分的数据。

网络训练

网络训练的目标是建立一个数据产生过程模型，使得网络能够推广，从它没有见过的输入预测输出。对于 MLP，一个训练模式（几个角度的辐射亮度数据）提供给网络，信号象前面描述的那样前向反馈。然后，网络的输出和期望值（例如，和几个角度辐射亮度值相对应的组分温度和叶面积指数等）相比较，计算误差：

$$E_p = \frac{1}{2} \sum_k (t_{pk} - o_{pk})^2$$

对于所有的训练模式，总误差为：

$$E = \frac{1}{2} \sum_p \sum_k (t_{pk} - o_{pk})^2 \quad (7)$$

该误差通过网络后向传输，一般地，连接的权重（通常在开始时随机赋值）根据我们知道的广义 delta 规则，即 BP 算法^[14]而改进。输出层和隐藏层权重改进方程的形式非常接近，对于输出层，权重改进方程为：

$$w_{kj}^o(t+1) = \eta(\delta_{pk}^o i_{pj}) + \alpha w_{kj}^o(t) \quad (8)$$

隐藏层权重改进方程为：

$$w_{ji}^h(t+1) = \eta(\delta_{pj}^h x_{pi}) + \alpha w_{ji}^h(t) \quad (9)$$

其中， η 为学习速率参数， δ 是误差变化速率的指标， α 是动量 (momentum) 参数。信号的前向反馈和误差的后向传递过程重复迭代，直到网络的总误差最小或者达到可接受的量级。正是通过对权重的连续的适应性调整，神经网络才能够学习。

GA 是一种寻优解法，它借用了生物在变迁的环境中“适者生存”的原则去设计在整个解空间中搜索最优解的计算方法而获得很大的成功^[16-20]。利用 GA 训练网络时，我们首先把神经网络中各神经元之间的权重，编码成二进制串，每一个权重作为一个基因；然后把隐藏层和输出层中每一个神经元

与其前一层中所有神经元之间的连接权重构成的基因首尾相连,组成染色体。例如,对于 2-3-2 结构的 MLP,隐藏层有 3 种染色体,每种染色体由 2 个输入层权重基因组成;而输出层有 2 种染色体,每种染色体由 3 个隐藏层权重基因组成。对于每种染色体,我们产生一定数量的个体,个体之间进行选择、杂交和变异等遗传操作,各种染色体之间的个体不发生遗传操作。最后,我们把方程(7)求得的均方误差的倒数作为适应函数(目标函数),它推动着 GA 的演化^[11,20]。

网络的推广和验证

影响网络推广,即神经网络对没有看见过的数据内插和外插能力的因素主要有以下几个^[21,22]:

(1) 神经元的数目和网络的体系结构

如果使用了大量的简单处理单元,数学结构就可以很灵活,神经网络就可以有更广泛的用途。通常情况下,隐藏层中神经元的数目越多,神经网络表达训练数据的效果越好,但是要以推广的能力减弱为代价。

(2) 训练数据集的大小

使用的训练样本必须是整个数值分布空间有代表性的,如果特征空间中数据分布范围没有充分覆盖,网络可能对新的数据预测的精度较低,导致失败。对 MLP 算法而言,这表示在训练时要求有大量的数据,研究人员经常关注的是找到必须的最小规模的训练样本^[23]。要求大的训练数据集还意味着训练时间可能很长。

(3) 训练时间

训练所花费的时间也影响网络的推广能力。对某一特定训练样本,网络训练的时间越长,它对训练样本的表示精度越高,但相应地,其适用于其它数据的能力降低。特别地,网络可能训练过度使得它能够记住训练数据,但不能推广应用到其它的数据。

必须对上述 3 点进行平衡,使得训练样本既能得到最大程度的学习,又使得网络有较好的推广能力。对于训练成功的神经网络,可以用一个验证数据集来评价网络的精度。验证数据集非常重要,因为它能为人们提供独立评价训练好的神经网络精度的依据。验证数据的选择,应该象选择训练样本一样,要在整个解的分布空间中有代表性。实际上,我们常常把能够获得的数据分成训练样本数据和检验数据,检验数据用来评价神经网络模型的性能。

3.2 使用 MLP 反演模型参数

我们利用非同温混合像元热辐射方向性模型模拟出的数据作为训练和验证 MLP 所需要的样本。在 2.2 节中给出的各参数范围内,按给定间隔的参数组合模拟出 2178 个输入-输出对,其中随机选择的 1513 个作为训练样本,另外 665 个作为检验数据。对数值进行预处理以使其范围适合于 MLP,即 0—1 之间;对每个待反演参数都进行线性变换到 0.1—0.9 之间;不同角度的辐射亮度数据线性变换到 0.05—0.95 之间。对模拟的数据经过预处理以后,我们就可以利用它们训练 MLP 和检验 MLP 的训练效果了。

GA 训练 MLP 寻找全局最优解区域

GA 可以全局搜索,找到全局最优解,但是花费时间太长,难以忍受,尤其是当 MLP 网络中神经元较多时。但经过一定迭代次数后,GA 比较容易找到全局最优解所处的区域^[16-17]。我们提出的使用 GA 训练 MLP 的方法建立了训练程序。MLP 网络结构是 4 个输入层神经元, N 个隐藏层神经元和 4 个输出层神经元。采用试错法确定 GA 的控制参数和 MLP 隐藏层中神经元个数。经过 GA 训练得到的 MLP 网络权重作为 BP 算法 MLP 网络的初始权重值,继续训练。

BP 算法训练 MLP 寻找最优解

如果 GA 训练得到的 MLP 网络权重位于全局最优权重组合的空间范围内,那么再经过 BP 算法的迭代优化,显然能够找到最适合给定训练样本的最优网络权重配置。我们仍然采用试错法确定 BP 算法控制参数(学习速率和动量)的取值,MLP 网络的隐藏层神经元个数保持不变。只要控制参数选择恰当,GA 的特点决定其训练得到的网络权重一定位于全局最优权重组合的空间范围内,但是控制参数的选择是否合适必须根据训练样本的拟合精度和检验数据的反演效果来确定。因此,我们采用 GA 获得 BP 算法初始权重组合后,再利用 BP 算法优化获得的最优权重,计算训练样本的拟合精度并使用检验数据观察参数的反演精度。可见,GA 和 BP 算法的控制参数必须联合选取,优化组合,才能获得满意的结果。利用 GA 获得网络权重的最优解区域后,我们把得到的网络权重作为 BP 算法的权重初值,再按照上节中给出的 BP 算法的权重调整改进的方法就可以获得最有权重组合。

反演结果

经过反复试验，我们选择 GA 控制参数：群体规模为 40，杂交概率 $P_c = 0.6$ ，变异概率 $P_m = 0.15$ ，迭代次数为 300；BP 算法控制参数：学习速率 $\eta = 0.3$ ，动量 $\alpha = 0.2$ 。MLP 网络中隐藏层神经元个数为 9 个时，反演效果较为理想。

使用 GA 训练 MLP 网络获得初始权重组合，当群体中个体数为 40，迭代 300 次时，训练数据和检验数据的均方误差分别为 0.18137 和 0.183903。训练样本均方误差随迭代次数的变化情况见图 2。




图2 利用 GA 训练 MLP 网络时，训练样本均方误差随迭代次数变化情况

Fig.2 Mean squared errors of training exemplars varied with iteration numbers when using GA to train MLP neural network

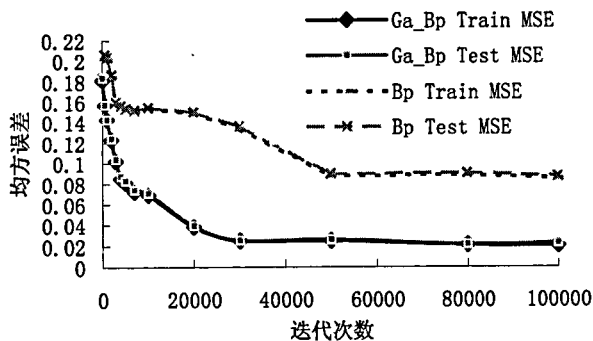


图3 有和没有 GA 训练时，训练样本和检验数据反演的模型参数的总均方误差随 BP 算法迭代次数变化的比较

Fig.3 Comparison of total mean square errors of model parameters retrieved from train and test exemplars varied with iteration numbers of BP algorithms with and without GA training neural network

从图 2 可以看出，随着迭代次数的增加，训练样本的均方误差减小，但减小的趋势逐渐变缓。我们把 GA 训练获得的 MLP 网络权重，作为 BP 算法的初始权重值，继续迭代反演。图 3 中实线表示经过 GA 初始化后，训练样本和检验数据均方误差随

BP 算法迭代次数变化的情况；虚线为没有经过 GA 初始化，单独使用 BP 算法优化网络权重时，训练样本和检验数据均方误差随迭代次数的变化情况。从图 3 中可以看出，经过 GA 全局寻优，再经 BP 算法局部寻优训练的 MLP 网络，其训练效果和推广能力均优于单独使用 BP 算法训练的 MLP 神经网络。经过 GA 和 BP 算法训练后的神经网络被用来反演检验数据，反演的模型参数的均方根误差随迭代次数的变化情况见图 4。从图 4 可以看出，GA 全局寻优后，BP 算法迭代 80000 次，经过这样训练的神经网络反演的模型参数，其均方根误差精度分别达到 $T_v = 0.79845$ ， $T_s = 0.96358$ ， $\epsilon_s = 0.01214$ 和 $LAI = 0.224$ 。




图4 从检验数据反演的模型参数均方根误差随 BP 算法迭代次数的变化情况

Fig.4 Root mean squared errors of model parameters retrieved from test exemplars varied with iteration numbers of BP algorithm

4 结论和讨论

本文利用我们建立的非同温混合像元热辐射方向性模型模拟得到组分温度、土壤比辐射率和叶面积指数等模型参数和几个角度辐射亮度之间的数值关系，作为训练 MLP 神经网络的实例。我们首先利用 GA 全局寻优的特点，训练神经网络找到网络权重的最优配置区域，然后根据 BP 算法局部寻优和快速的特点，找到网络的最优权重配置。我们看到，经过 GA 和 BP 算法组合训练的神经网络，能够以满意的精度同时反演 4 个模型参数。由于 GA 和 BP 算法的控制参数选择具有随意性，必须经过大量实验才能给出恰当的参数组合，需要花费大量的机时。因此，各控制参数的合理组合，需要进一步研究。但是神经网络一旦训练成功，就可以迅速完成反演。在多维遥感数据定量信息提取方面，本文提出的神经网络训练方法有更大的应用价值。

参 考 文 献 (Refereneces)

- [1] Chen Liangfu, Zhuang Jiali, Xu Xiru. The correlationship of multi-channel thermal infrared remote sensing information and its effect on retrieval of land surface temperature [J]. *Chinese Science Bulletin*, 1999, 44(17): 1627—1632.
- [2] Xu Xiru, Liu Qinhuo, Chen Jiayi. Synchronous retrieval of land surface temperature and emissivity[J]. *Science in China (Series D)*, 1998, 41(6):658—668.
- [3] Jackson, R. D. Canopy Temperature and crop water stress [J]. *Irrigation Science*, 1984, 5:43—80.
- [4] Chen Liangfu, Zhuang Jiali, Xu Xiru *et.al.* The Concept of Effective Emissivity of Non-isothermal Mixed Pixel and Its Test [J]. *Chinese Science Bulletin*, 2000, 45(7): 788—795.
- [5] Chen Liangfu. The Model of radiant directionality of non-isothermal mixed pixel: Doctoral dissertation [D]. Beijing: Peking University library, 1999. [陈良富, 非同温混合像元热辐射方向性模型. [学位论文], 北京: 北京大学图书馆, 1999.]
- [6] Chen Liangfu, Zhuang Jiali, Xu Xiru. Feasibility of retrieval of component temperature of mixed pixel from multi-angle data [J]. *Geography Research*, 2000, (2). [陈良富, 庄家礼, 徐希孺. 用多角度遥感数据反演混合像元组分温度的可行性分析. 地理研究, 2000, (2).]
- [7] Smith A.J. LAI inversion using a back-propagation neural network trained with a multiple scattering model[J]. *IEEE Transaction on Geoscience and Remote Sensing*, 1993, 31:1102—1106.
- [8] Abuelgasim A.A, Gopal S., Strahler A.H. Forward and inverse modeling of canopy directional reflectance using a neural network [J]. *International Journal of Remote Sensing*, 1998, 19(3): 453—471.
- [9] Gong P, Wang D.X., Liang S. Inverting a canopy reflectance model using a neural network [J]. *International Journal of Remote Sensing*, 1999, 20(1): 111—122.
- [10] Masters, T. Practical Neural Network Recipes in C++ [M]. Academic Press, 1993.
- [11] Freeman J.A. Simulating neural networks with Mathematica [M]. New York: Addison-Wesley publishing company, 1994.
- [12] Zhou Xiuji, Tao Shanchang, Yao Keya. Advanced Atmospheric Physics [M]. Beijing: Meteorological Press, 1991. [周秀骥等. 高等大气物理学 (上, 下册). 北京: 气象出版社, 1991.]
- [13] Shaoyan Ge, Hongyue Na. The feature of thermal irradiance and its measurement [M]. Beijing: Science in China Press, 1989. [葛绍岩, 那鸿悦编著. 热辐射性质及其测量. 北京: 科学出版社, 1989.]
- [14] Rumelhart D.E. G.E. Hinton, R.J. Williams. Learning internal representations by error propaGation. In *Parallel Distributed Processing: Explorations in the Microstructures of Cognition* [C]. vol.1 edited by D.E. Rosenblatt and J.L. McClelland, Cambridge, MA: MIT Press, 1986, 318—362.
- [15] Hornik K., M. Stinchcombe, H.White. Multilayer feedforward networks are universal approximators [J]. *Neural Networks*, 1989, 2: 359—366.
- [16] Goodberg D E. Genetic Algorithms in Search, Optimization and Machine Learning [M]. Addison Wesley, Reading MA, 1989.
- [17] Deb K. Genetic Algorithms for Function Optimization [C]. In F. Herrera and J. L. Verdegay edited, *Genetic algorithms and soft computing*. Physica-Verlag, Springer-Verlag Company. 1996, 3—29.
- [18] Winter G., M. Galan, P. Cuesta, D. Greiner. Genetic algorithms: A stochastic improvement technique: tools, skills, pitfalls and examples [C]. In G. Winter, J. Periaux, M. Galan, P. Cuesta, *Genetic algorithms in engineering and computer science*. USA., John Wiley and Sons. 1996, 217—247.
- [19] Pan Zhengjun, Kan Lishan, Chen Yuping. Evolutionary Computation [M]. Beijing: Tsinghua University Press, 1998. [潘正军, 康立山, 陈毓屏. 演化计算. 北京: 清华大学出版社, 1998.]
- [20] Holland J H. Adaptation in Natural and Artificial Systems [M]. The University of Michigan Press, 1975.
- [21] Atkinson P.M., A.R.L. Tatnall. Neural Networks in Remote Sensing [J]. *Int. J. Remote Sensing*, 1997, 18(4): 699—709.
- [22] Devillers J. Strengths and weakness of the backpropagation neural network in QSAR and QSPR studies [C]. In *Neural Networks in QSAR and Drug Design*, Devillers J. edited, Academic Press, London, 1996, 1-46.
- [23] Hepner G.F., T. LoGAN, N. Ritter, N. Bryant. Artificial neural network classification using a minimal training set: comparison to conventional supervised classification [J]. *Photogrammetric Engineer and Remote Sensing*, 1990, 56: 469—473.

Component Parameters of Mixed Pixel Inversion Using a Neural Network Trained by Genetic Algorithm

ZHUANG Jia-li, CHEN Liang-fu, XU Xi-ru

(Institute of Remote Sensing and GIS of Peking University, Beijing, China, 100871)

Abstract: After carefully studying the results of retrieval of land surface temperature (LST) acquired by multi-channel thermal infrared remote sensing data, the authors point out that the accuracy and significance for applications are seriously damaged by high correlation coefficient among multi-channel information and its disablement of direct retrieval of component temperature. Based on the model of directional radiation of non-isothermal mixed pixel, we point out that the multi-angle thermal infrared remote sensing can offer the possibility to directly retrieve component temperature. But it is difficult to synchronously retrieve all parameters using traditional inversion methods because the model is a numerical conception model based on Monte Carlo simulation. In order to effectively derive the parameters, we use neural network model. The parameters to be retrieved, such as component temperatures, soil emissivity and LAI, are all nonlinear function of multi-angle radiation, and when the classical back-propagation (BP) algorithm was employed to retrieve these parameters, it was easily entrapped at local optimal regions. Therefore, we first employ genetic algorithm (GA) to train the neural network, and obtain the weights between the layers of neural network, which were used as the initial weights of the BP algorithm, then continue to train the network until the results are satisfied. Thus, the speediness of BP algorithm was developed and the optimal configuration of network weights are obtained. Based on the model of radiant directionality of non-isothermal mixed pixel, simulated results show that retrieved multi-dimensional parameters are superior when using GA to optimize the neural network weights.

Key words: multi-angle thermal infrared remote sensing; model of radiant directionality of non-isothermal mixed model; genetic algorithms; neural networks