

应用 SVM 技术模拟前向辐射传输模式

谭永强, 费建芳

解放军理工大学气象学院, 江苏 南京 211101

摘要: 提出了一种利用支持向量机(SVM)模拟前向辐射传输模式的方法。利用欧洲中期天气预报中心(ECMWF)的 RTTOV_8_7 前向辐射传输模式和 60L-SD 廓线集生成了 AMSU-A 模拟亮温资料,用模拟亮温和相应的廓线集资料组成训练样本和检验样本,采用 SVM 方法进行训练。对检验样本的模拟显示,SVM 可以用于描写前向辐射传输模式中的非线性映射关系,较好地由大气廓线集资料模拟出与其相关的 AMSU-A 仪器 5—14 通道亮温,其中通道 6—14 的均方根误差在 0.1K 以内,平均误差算术平均值在 0.01K 以内。通过多元线性回归方法对温度廓线进行反演试验,发现用 SVM 模拟的亮温可以用于温度廓线反演,其反演精度可以达到甚至高于 RTTOV_8_7 计算的亮温。

关键词: SVM,前向辐射传输模式,RTTOV

中图分类号: TH765.2 **文献标识码:** A

1 引言

利用卫星资料反演大气温湿廓线对于现代数值天气预报与环境监测,具有十分重要的意义。目前,国内外的温湿廓线反演方法大致分为两类:统计反演方法和物理反演方法。统计方法是利用先验的卫星通道观测辐射值和大气温湿廓线直接建立起统计回归关系,这种方法不能有效地处理非线性问题,反演精度有限。物理反演方法直接求解辐射传输方程,通常这类方法利用前向辐射传输模式计算辐射值和卫星接收真实辐射值之差最小原则构造目标泛函,通过一定的下降搜索方式或迭代方法直接求解温湿廓线。物理反演方法精度较高,但前向辐射传输模式往往很耗计算机时。如果可以采用一种简单可靠的方法,模拟前向辐射传输模式计算亮温,将有利于提高温湿廓线反演效率。同时,在数值天气预报的变分同化系统中,快速准确的前向辐射传输模式对于直接同化卫星数据具有十分重要的作用。

由于辐射传输理论所描写物理过程的复杂性及对辐射传输过程理解有限,通常的辐射传输模式

存在一些不足,计算时间较长。从另外一种角度考虑,遥感领域中的正演与反演问题,实际上是数据映射问题(Krasnopolsky & Schiller, 2003)。对于反演问题,是求取由观测向量(卫星观测辐射值)到状态向量(廓线值)的映射问题;对于辐射传输的正演问题,则是求取由状态向量到观测向量的映射问题。由于辐射传输过程的高度非线性,观测向量和状态向量之间是非线性映射关系。

随着人工智能(AI)技术的发展,人们开始利用神经网络(NN)描写前向辐射传输模式中的非线性映射问题。Smith(1993)利用 NN 模拟了一个简单的二流辐射传输模式;Thiria 等(1993)利用 NN 模拟了卫星散射计的测值;Krasnopolsky 等(1997)利用基于 NN 的 OMBFM1 模式,用于快速计算模拟 SSM/I 数据;Krasnopolsky 等(1996, 1999)结合 OMBFM1 模式,提出一种利用 NN 进行多参数同步反演的快速算法 OMBNN3 模式,该模式自 1998 年在 NCEP/NOAA 业务运行。

NN 还存在一些问题,如多个局部极值、神经网络的层数与神经元的个数等。近几年兴起的另一种智能机器学习方法——支持向量机(Support Vector Machine, SVM)方法能够克服神经网络的一些固有缺

收稿日期:2007-12-24;修订日期:2008-03-01

基金项目:中国科学院大气物理研究所大气科学和地球流体力学国家重点实验室开放课题 2709 和中国气象局上海台风研究所开放课题(编号:2006STB02)。

第一作者简介:谭永强(1977—),男,博士在读,现就读于解放军理工大学气象学院气象学专业,主要从事卫星资料反演研究。E-mail: iamtyq@163.com。

点,可以用于描写辐射传输模式中的非线性映射。本文利用 SVM 方法,模拟前向辐射传输模式 RTTOV_8_7 计算 AMSU-A 仪器通道亮温,应用多元统计回归反演方法检验 AMSU-A 模拟亮温精度。

2 SVM 方法

支持向量机最初由 Vapnik 等于 1992 年引入机器学习领域,在 20 世纪 90 年代中后期得到了发展,应用到了多个领域。其基本学习原理如下 (Cristianini & Shawe-Taylor, 2004)。

在机器学习领域中,最简单的线性学习器可以表示:

$$y = f(\mathbf{x}) = \langle \mathbf{w} \mathbf{g} \mathbf{x} \rangle + b = \sum_{i=1}^n w_i x_i + b \quad (1)$$

式中, w_i 为权重系数, b 为偏置。由于线性学习器的能力有限,现实世界往往需要比线性函数更富有表达能力的假设空间。可以使用一个固定的非线性映射 $\mathbf{x} = (x_1, \dots, x_n) \mathbf{a}$, $\boldsymbol{\varphi}(\mathbf{x}) = (\phi_1(x), \dots, \phi_N(x))$, 将数据映射到高维特征空间,由此增加线性学习器的能力,然后在特征空间使用线性学习器进行学习。考虑单参数输出拟合的情况:

$$y = f(\mathbf{x}) = \sum_{i=1}^N w_i \phi_i(\mathbf{x}) + b \quad (2)$$

式中, y 为输出参数, \mathbf{x} 为输入向量, $\boldsymbol{\varphi}$ 为 $X \rightarrow F$ 的一个特征空间映射。 \mathbf{w} 为权重向量,其可以用测试点和训练点的内积来表示,即对偶形式:

$$f(\mathbf{x}) = \sum_{i=1}^n \alpha_i y_i \langle \boldsymbol{\varphi}(\mathbf{x}_i) \times \boldsymbol{\varphi}(\mathbf{x}) \rangle + b \quad (3)$$

式中, n 为样本数目, α_i 为另一种形式的权重系数,可以使用这种方式直接在特征空间计算内积 $\langle \boldsymbol{\varphi}(\mathbf{x}_i) \times \boldsymbol{\varphi}(\mathbf{x}) \rangle$, 这样就将特征空间映射和对偶形式融合建立了一个非线性学习器,即核函数方法。

$$f(\mathbf{x}) = \sum_{i=1}^n \alpha_i y_i \mathbf{K}(\mathbf{x}_i, \mathbf{x}) + b \quad (4)$$

式中, \mathbf{K} 即为核函数。通过使用恰当的核函数来代替内积,可以隐式地将训练数据非线性映射到高维空间,而不增加可调参数的个数。由于只有最靠近拟合超平面的点对应的 α_i 为非零,所有其他点对应的 α_i 为零,这些点就称为支持向量。

对于所给定的支持向量机模拟前向辐射传输模式为多参数输出,如果有 n 个训练样本, m 个廓线层次, k 个仪器通道,则 SVM 训练回归的表达如式(5)。式中, \mathbf{y} 是正演亮温向量集,为 $n \times k$ 维矩阵; \mathbf{x} 是廓线向量集,为 $n \times m$ 维矩阵。通过核隐式

映射,将输入空间 \mathbf{x} 与输出空间 \mathbf{y} 联系起来,非线性函数可以通过核特征空间中的线性学习器得到。实际上,这个算法又称为核岭回归,其解称为正则化网络,其正则算子通过核隐式选择。

$$\mathbf{y} = \sum_{i=1}^n \alpha_i \mathbf{K}(\mathbf{x}_i, \mathbf{x}) + \mathbf{b} \quad (5)$$

SVM 训练网络如图 1。




图 1 SVM 训练回归

Fig. 1 Training network of SVM regression

训练将得出 $\boldsymbol{\alpha}$ 矩阵和 \mathbf{b} 向量,这样就可以利用此网络对前向辐射传输模式进行模拟。在 SVM 中,核的选择和参数的调整非常重要,在处理实际问题时必须首先确定。但这个理论问题至今尚未彻底解决,它不仅与所研究的问题有关,而且还和具体数据有关 (Cristianini & Shawe-Taylor, 2004)。通常标准核的选择有线性核、多项式核、径向基函数 (RBF) 核和 MLP 核等。通过对数据进行多次试验,本文使用 RBF 核进行训练,其表达式为式(6),式中 σ^2 为核的方差。

$$\mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / \sigma^2) \quad (6)$$

3 前向辐射传输模式及数据准备

本文采用大气廓线集资料,利用前向辐射传输模式,模拟 AMSU-A 微波观测亮温资料。AMSU-A 有 15 个微波观测通道,模拟该资料的原因是微波能穿透云面,观测到云以下的大气温湿场的垂直分布,可以构建三维温湿场结构。

采用的廓线集资料为 60L-SD 大气廓线集。它是从欧洲中期天气预报中心模拟廓线资料 40 年再分析计划得到的,总共有 13495 个廓线资料集,每一组廓线包含有温度、水汽和臭氧廓线及地面高度、温度、10m 风速分量等资料。

前向辐射传输模式为 ECMWF 发展的前向辐射传输模式 RTTOV_8_7 (Saunders & Brunel, 2005)。

RTTOV 是由 ECMWF 最初发展于 20 世纪 90 年代早期,期间经过了多次发展。通过给定大气温度廓线、各种气体的浓度、云及表面属性组成的状态向量,可以模拟红外及微波辐射计的辐射值。在模式中,唯一需要给定的气体含量廓线是水汽。其他的诸如臭氧、二氧化碳可以假定为常值。

首先将 60L-SD 大气廓线集资料的 13495 个廓线资料分别插值到 RTTOV_8_7 模式指定的 43 层上,然后将之代入到 RTTOV_8_7 模式进行计算,得到模拟 AMSU-A 仪器接收到的大气层顶亮温,视为“真实”亮温。将每条廓线 43 层温度、湿度及表面温度、2 米处湿度和 10 米处风速分量与对应 15 个通道的 AMSU-A 仪器亮温值组成一个训练样本,由此共得到 13495 个样本。要说明的是,本文仅对海面进行亮温正演试验。60L-SD 资料中有海面廓线资料 8015 条。选取其中 4015 条廓线及其对应的亮温资料作为训练样本,然后利用余下 4000 组资料作为检验样本。

微波亮温资料(尤其是窗区通道)不仅与大气温湿度状况相关,而且与大气成分、地表状况尤其是各通道表面比辐射率等相关。在 RTTOV_8_7 中,比辐射率采用 FASTEM-3 进行计算,SVM 的一个优点是不需要考虑具体的辐射传输过程,直接加入已知的影响参数。在海面由于风场使海面粗糙度发生变化,引起了各通道表面比辐射率发生变化,因此在训练中加入了 10m 风分量要素。

4 效果检验

4.1 SVM 模拟亮温与前向模式模拟亮温比较

为检验模拟亮温的准确程度,利用 SVM 计算模拟亮温后与 RTTOV_8_7 计算的“真实”亮温比较。采用均方根(RMS)来衡量正演误差,均方根误差的定义如下:

$$E_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_R - y_T)^2} \quad (7)$$

式中, y_R 为 SVM 模拟的各通道亮温值, y_T 为 RTTOV_8_7 模拟的“真实”亮温值, n 为检验样本个数。

为检验各通道模拟亮温与 RTTOV_8_7 计算“真实”亮温平均偏差程度,采用亮温误差算术平均值定义:

$$E_{DEV} = \frac{1}{n} \sum_{i=1}^n (y_R - y_T) \quad (8)$$

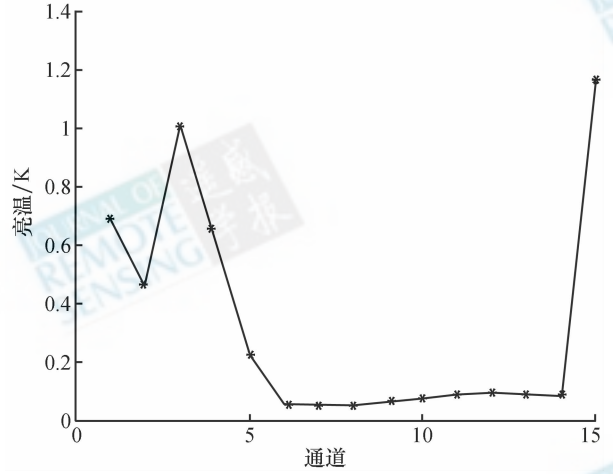


图 2 模拟通道亮温均方根误差

Fig. 2 RMS error of simulate channel brightness temperature

图 2 为利用 SVM 方法模拟各通道亮温的均方根误差。可以看出,通道 5—14 模拟效果较好,其中通道 5 的均方根误差为 0.22K;通道 6—14 的均方根误差在 0.1K 以内,均小于通道标准 NEDT (Noise Equivalent Temperature Difference) (表 1);通道 1,2,3,4,15 的均方根误差较大,均超过了 AMSU-A 通道标准的 NEDT,其中通道 15 的误差最大,为 1.18K。对比 AMSU-A 权重函数(Li *et al.*, 2000),可以发现,通道 1,2,3,15 分别是窗区通道,通道 4 虽然不是窗区通道,但其权重函数峰值能量贡献高度在 1000hPa 附近,也即亮温模拟不好的通道是窗区通道和权重函数峰值近地面的通道,对于与对流层温湿廓线反演相关较大的其他通道,模拟较好。

具体分析窗区通道模拟不好可能的原因有:(1)SVM 方法本身存在的不足,由于其本身不考虑具体的辐射传输过程,要由较少的输入参数(表面温度、10 m 处风速分量)来确定多个参数(窗区通道亮温),是不合适的;(2)RTTOV_8_7 本身对 AMSU-A 仪器窗区通道模拟系统误差的原因。对比 RTTOV8 有效性报告(Saunders, 2005),同样发现其对于窗区通道的模拟误差较大,尤其值得一提的是 RTTOV 对于 AMSU-A 仪器的模拟均方根误差随通道变化的曲线形状与 SVM 均方根误差的形状基本一致,窗区通道均比 SVM 模拟误差要大一倍以上;(3)在微波波段,表面比辐射率变化范围较大,在海面,海表粗糙度的变化引起各通道比辐射率变化,由于比辐射率变化的复杂性,虽然在训练中引了如 10m 处水平风分量,提高了模拟精度,但仍然是不够的。

在实际使用 AMSU-A 资料时,通道 1 往往用于可降水量的反演;通道 2,3,4 用于表面温度的反演;

通道 5—14 用于对流层温度廓线反演;通道 15 用于云顶及积雪的反演。虽然 SVM 模拟窗区通道亮温误差较大,但是对于对流层大气温度廓线的反演,通道 5—14 模拟好就足够了。

为证明表面风速分量对于 AMSU-A 窗区通道的影响,将表面风速分量参数从输入空间去掉后,模拟结果显示,窗区通道亮温模拟结果误差增长较大,说明表面风引起微波比辐射率的变化对于窗区通道亮温模拟具有重要的意义。

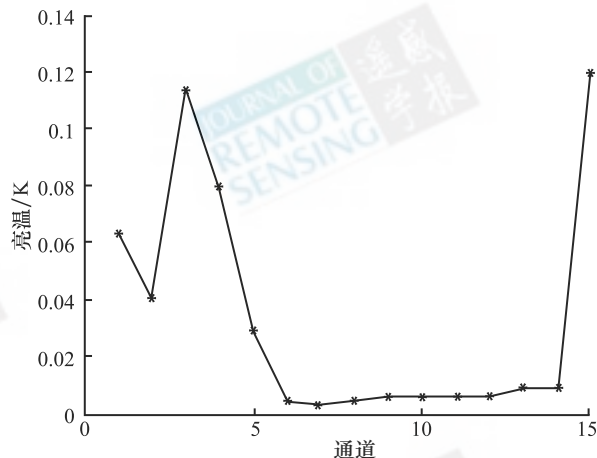


图 3 模拟通道亮温的误差算术平均值

Fig. 3 Standard deviation of simulate channel brightness temperature

图 3 为各通道利用 SVM 方法模拟亮温的误差算术平均值。可以看出,与均方根误差图一样,通道 5—14 模拟效果较好,通道 5 的误差算术平均值为 0.027K,通道 6—14 的误差算术平均值均在 0.01K 以内,所有通道的误差算术平均值均大于 0,但其值很小,远小于通道标准 NEDT。

通过以上两个实验可以看出, SVM 方法可以很好地模拟 AMSU-A 通道 5—14 的亮温,这些通道恰恰对于温度廓线的反演具有重要意义。在目前的温湿廓线反演算法中,精度较高的是物理反演算法,如非线性迭代方法(Li *et al.*, 2000),但这种方法要采用精确的前向辐射传输模式反复迭代计算卫星接收辐射

值,这是一个十分耗时的操作,使用起来十分不方便,可采用 SVM 方法来模拟卫星接收辐射值。为了检验 SVM 方法模拟亮温的精度是否可以用于温度廓线反演工作,尤其是在窗区通道亮温模拟不是很好的情况下,是否会对低层温度廓线反演产生不利的影响,有必要对 SVM 模拟亮温和实际卫星亮温同时进行廓线反演实验,对比反演精度。

4.2 SVM 模拟亮温用于温度廓线反演

利用 RTTOV 模式模拟亮温作为“实际”亮温值,和 SVM 方法模拟的亮温同时进行温度廓线反演,采用的反演方法为多元线性回归方法(Liou, 2004; 官莉, 2006)。

假设温度廓线与通道亮温的关系如下:

$$Y = KX \quad (9)$$

式中, Y 为温度廓线,为 $m \times n$ 维矩阵,其中 n 训练样本个数, m 为温度廓线层次个数; X 为 AMSU-A 仪器 15 个通道的亮温,为 $15 \times n$ 维的矩阵; K 为多元回归反演的系数矩阵,为 $m \times 15$ 维矩阵。多元回归就是在训练样本的温度廓线及卫星观测辐射值之间寻找一个最佳的拟合矩阵 K , K 的计算由最小二乘法得到,使得观测值与回归值之间的差最小化,即:

$$\frac{\partial}{\partial K} |KX - Y|^2 = 0$$

则:

$$K = YX'(XX')^{-1} \quad (10)$$

式中, XX' 是亮温值之间的协方差矩阵, YX' 为亮温值与大气廓线之间的协方差矩阵。利用训练样本可以得到统计回归反演的系数矩阵,然后用此系数矩阵即可对检验样本进行统计回归的廓线反演。

在实际亮温资料中,由于有通道噪声的存在,会引起反演误差的加大。因此,在多元线性回归的训练和检验样本各通道亮温资料中加入均值为零,标准差如表 1 所示通道标准 NEDT 高斯分布噪声。这样会降低拟合程度,但在实际反演中,将增加反演的精度。

表 1 AMSU-A 通道 NEDT
Table 1 AMSU-A Channel NEDT

通道	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
噪声/K	0.30	0.30	0.40	0.25	0.25	0.25	0.25	0.25	0.25	0.40	0.40	0.60	0.80	1.20	0.50

图 4 为采用多元线性回归方法,分别利用 SVM 模拟亮温和 RTTOV_8_7 模拟“真实”亮温进

行温度廓线反演 RMS 误差随高度的分布。其中圈线为 SVM 模拟亮温反演的 RMS,点线为 RTTOV

_8_7“真实”反演的 RMS。从图 4 可以看出,两种亮温反演的误差基本一致,在一定程度上,SVM 模拟亮温甚至优于其训练亮温反演的能力,尤其是在近地面层。在 SVM 模拟窗区通道 1,2,3,15 及通道 4 时,其正演误差较大,但从温度廓线的反演试验来看,其误差对于温度廓线反演的作用不大。对于在低层 SVM 模拟亮温甚至优于“真实”亮温反演,是一个值得思考的问题,这可能与检验样本和训练样本的差异有关,也可能是由于前向辐射传输模式计算的误差有关。从另外一个角度出发,模拟不是很好的与表面温度相关的窗区通道亮温,却得到了低层较高的反演精度,这说明 SVM 方法模拟的窗区通道亮温更有利于低层温度廓线的反演,也从另外一个侧面说明:SVM 方法对于描写前向辐射传输模式的非线性映射具有特别的优势。

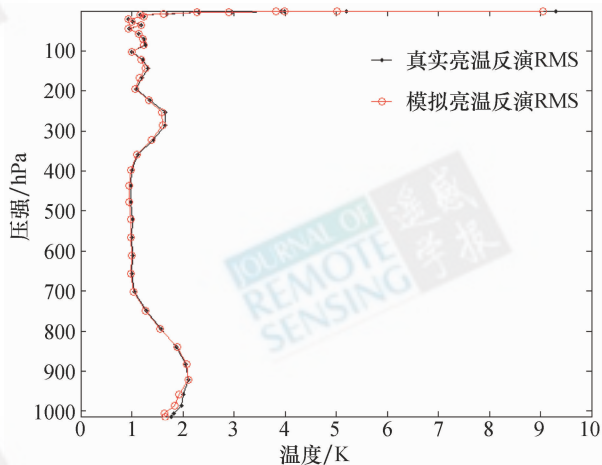


图 4 模拟亮温反演均方根误差

Fig. 4 Retrieve RMS error using simulate brightness temperature

5 结 论

本文提出了利用支持向量机模拟前向辐射传输模式的方法。利用 ECMWF 的 60L-SD 廓线集资料和前向辐射传输模式 (RTTOV_8_7) 模拟的 AMSU-A 亮温资料形成训练样本。通过对检验样本的 SVM 模拟亮温和 RTTOV_8_7 模拟亮温及温度廓线反演试验分析表明:

(1) SVM 方法可以较好地模拟 AMSU-A 的 5—14 通道亮温,其中通道 6—14 的均方根误差在 0.1K 以内,误差算术平均值的绝对值在 0.01K 以内,均远远小于通道标准 NEDT。

(2) 输入空间中加入对表面比辐射率有较大影

响的风速分量对窗区通道亮温的模拟有较大地改进,SVM 对于窗区通道 1,2,3,15 及用于表面温度反演的通道 4 模拟误差较大,大于通道 NEDT。

(3) 多元线性回归温度廓线反演试验表明,SVM 模拟亮温可以用于温度廓线的反演,与 RTTOV_8_7 模拟亮温反演廓线的反演效果相当,在低层稍微优于 RTTOV_8_7 模拟亮温反演效果。

相对于前向辐射传输模式而言,SVM 有一个重要的优势在于,一旦训练完成,其计算速度很快、计算精确;可以灵活地加入已知影响卫星接收辐射值的地球物理参数,而不需要考虑具体的辐射传输过程,增加前向辐射传输计算过程的准确性。但是,对于 SVM 模拟前向辐射传输模式而言,成功的关键在于要获得高质量、有代表性的训练数据集,同时这个训练数据集也要有一定的大小,便于成功的训练。下一步工作应当收集具有代表性的实际廓线与对应的卫星观测辐射值组成数据集。同时,要将 SVM 模拟前向辐射传输过程和物理反演温湿廓线进行结合。

REFERENCES

- Guan L. 2006. Retrieving atmospheric profiles from MODIS/AIRS observations I. eigenvector regression algorithms. *Journal of Nanjing Institute of Meteorology*, **29**(6):756—761
- Krasnopolsky V M. 1997. A neural network-based forward model for direct assimilation of SSM/I brightness temperatures, OMB contribution No 140, NCEP/NOAA
- Krasnopolsky V M, Gemmill W H and Breaker L C. 1999. A multiparameter empirical ocean algorithm for SSM/I retrievals. *Canadian Journal of Remote Sensing*, **25**(5): 486—503
- Krasnopolsky V M, Gemmill W H and Breaker L C. 1996. A new transfer function for SSM/I based on an expanded neural network architecture. OMB contribution No137, NCEP/NOAA.
- Krasnopolsky V M and Schiller H. 2003. Some neural network applications in environmental sciences. Part I: forward and inverse problems in geophysical remote measurements. *Neural Networks*, **16**(3): 321—334.
- Li J, Wolf W W, Menzel W P, Zhang W, Huang H L and Achtor T H. 2000. Global soundings of the atmosphere from ATOVS measurements: the algorithm and validation. *Journal of Applied Meteorology*, **39**(8): 1248—1268
- Saunders R. 2005. RTTOV_8_Science and Validation Report http://www.metoffice.gov.uk/research/interproj/nwpsaf/rtm/rtm_rttov8.html
- Saunders R and Brunel P. 2005. RTTOV_8_7 user guide http://www.metoffice.gov.uk/research/interproj/nwpsaf/rtm/rtm_rttov8.html
- Smith J A. 1993. LAI inversion using a back-propagation neural network

trained with a multiple scattering model. *IEEE Transactions on Geoscience and Remote Sensing*, **31**(5): 1102—1106

Thiria S, Mejia, Badran C F and Crepon M. 1993. A neural network approach for modeling nonlinear transfer functions: application for wind retrieval from spaceborn scatterometer data. *Journal of Geophysical Research*, **98**(12): 22827—22841

附中文参考文献

Cristianini N and Shawe-Taylor J. 2004. 支持向量基导论. 北京:电子工业出版社

LIU K N. 2004. 大气辐射导论. 北京:气象出版社

官莉. 2006. 利用 AIRS 卫星资料反演大气廓线 I. 特征向量统计反演法. 南京气象学院学报, **29**(6): 756—761

Simulating radiative transfer forward model using support vector machine technique

TAN Yong-qiang, FEI Jian-fang

Institute of Meteorology, PLA University of Science and Technology, Jiangsu Nanjing 211101, China

Abstract: Based on Support Vector Machine(SVM), a technique simulating radiative transfer forward model is presented. Using European Centre for Medium-Range Weather Forecasts (ECMWF) RTTOV_8_7 radiative transfer forward model and 60L_SD profile database, we simulate the brightness temperature received in AMSU-A instrument. Combine this brightness temperature datasets and correspondence profile datasets as training and validation database. After training the SVM network, the simulating technique is validated. The results show that SVM network describes the nonlinear projection relationship between input space and output space very well, and the simulated brightness temperature of channel 5—14 is precise. The RMS error of channel 6—14 is less than 0.1K and the mean standard deviation is less than 0.01K. In order to find whether SVM simulated brightness temperature is appropriate for temperature retrieval, multi-regression retrieval method is used to retrieve temperature profile. Experiment result shows that the SVM simulate brightness temperature is appropriate for the purpose, and the retrieval precision is not only equally but also a little more precise than the RTTOV_8_7 simulated brightness temperature.

Key words: SVM, radiative transfer forward model, RTTOV