

一种改进海面风速反演的分类神经网络方法*

孟雷^{1,2} 何宜军¹ 伍玉梅^{1,2}

(1.中国科学院海洋研究所 青岛 266071; 2.中国科学院研究生院 北京 100049)

提要 为了提高使用 SSM/I 资料反演全球海面风速的精度, 发展了一个新型的神经网络方法。在这个方法中, 使用高风速、中、低风速状态和天气状态分类的方法分别训练神经网络, 然后根据其类别的不同使用不同的神经网络计算风速。此方法较好地去除了由于高风速和云天天气状态下训练样本数据的缺少所产生的误差, 改进了在高风速状态下反演风速值比实际风速偏低的情况, 使得反演的高风速值被校正到了正常位置。本方法反演海面风速的值与浮标实测风速值之间的均方根误差达到 1.60m/s。

关键词 神经网络, SSM/I 资料, 海面风速

中图分类号 P753

SSM/I(Special Sensor Microwave/Imager)是美国国防气象系列卫星 DMSP(Defense Meteorological Satellite Program)上搭载的被动微波辐射计, 共测量 19.35 GHz、22.235 GHz、37.0 GHz 和 85.5 GHz 四个频率的微波辐射亮温。其中, 19.35 GHz、37.0 GHz 和 85.5 GHz 为水平(H)和垂直(V)双极化, 22.235 GHz 只有垂直(V)极化。SSM/I 辐射计在研究全球海洋和大气系统中具有多方面的应用, 除了海面风速, 还可以反演出水汽含量、海面温度、相对湿度、海面气温、云中液态水和海面降水等参数。SSM/I 通过测量与海面风场存在相关性的海面亮温, 可以提供全球大多数海域的每天两次的面风场信息, 具有实时性、全球性和全天候性, 是目前可操作的测量海面风场信息的最主要的星载辐射计之一。

Goodberlet 等(1989)提出了使用 SSM/I 辐射计亮温反演全球海面风速的线性统计算法(GSW 算法)。此方法在有云天反演效果不好, Goodberlet 等(1992)对其进行了改进, 提出了基于非线性回归的算法。由于这个算法只适用于 DMSP F8 卫星上的 SSM/I 辐射计亮温值, 误差也较高, 因而限制了其使用范围。此外, Wentz 提出了一种基于辐射传输和海面微波发射率的算法(Wentz, 1992), 该方法精度较高, 但不能提供实

时的 SSM/I 风速反演。神经网络方法在反演海面风速的时候不需要深入研究海面微波发射和大气辐射传输的物理机制, 只需使用选定区域的亮温和风速的匹配数据训练神经网络即可进行海面风速的反演, 具有精度高、非线性、自学习、适应性和容错性强等优点。Thiria 等(1993)将神经网络模型用于散射计资料反演风速, 然后 Stogryn 等(1994)又提出了使用 SSM/I 辐射计亮温数据反演风速的单参数神经网络模型。该方法必须使用两个网络分别对晴天和有云层天气计算风速。Krasnopolsky 等(2000)提出了基于 SSM/I 辐射计亮温资料的多参数神经网络算法, 此算法除了反演风速, 还同时反演水汽含量、云中液态水和海面温度。Stogryn 等(1994)和 Krasnopolsky 等(2000)提出的神经网络都没有去除风向信息对微波辐射亮温的影响, 因而在反演得到的风速中含有由风向信息引起的误差。

本文中作者发展了一个新型的将高风速和中、低风速状态和天气状态分类的 BP 神经网络方法。此方法不仅减小了由风向信息引起的误差, 而且较好地去除了由于不同的风速和天气状态下样本数据的差异对训练神经网络产生的影响, 从而改善了海面风速反演的效果。

* 国家 863 计划资助项目, 2001AA633060 号和国家自然科学基金资助项目, 40276050 号。孟雷, E-mail: mengleiml@163.com
通讯作者, E-mail: heyj@ms.qdio.ac.cn

收稿日期: 2007-06-04, 收修改稿日期: 2008-05-08

1 数据准备

本文中作者使用 SSM/I 亮温数据和浮标风速的匹配资料作为训练神经网络和计算反演风速误差的数据。实测数据使用 NDBC 浮标(71 个)和 TAO 浮标(58 个), 浮标的位置远离海岸线至少 30km 以上, 以便去除大陆径流污染对海面亮温的影响以及减少陆地对海面风速的影响。浮标测量的参数除了风速, 还有风向、海面温度和海表面气温, 采样时间间隔为 1h。

卫星数据使用 DMSP F14 卫星上的 SSM/I 亮温资料, 时间跨度为 1997—2002 年。在进行浮标与卫星观测象元的匹配时, 作者采取严格的控制标准以确保卫星观测时间、采样区域和浮标的测量时间、位置的一致性。在空间匹配上, 浮标中心的地理坐标与卫星观测象元中心点的距离小于 10km。在时间匹配上, 浮标采样记录时间与卫星对相应象元的扫描时间的间隔小于 30min。这样得到匹配数据 36894 条, 见表 1。表 1 中的训练样本和检验样本指神经网络在训练和检验时使用的样本数目。训练样本和检验样本均为从总样本数据中随机选取的等量样本。

表 1 不同天气状态下的样本数量

Tab.1 The SSM/I overpasses of buoys in clear and cloudy conditions

天气状态	训练样本(个)	检验样本(个)	总共(个)
晴天	17155	17155	34310
云天	1292	1292	2584
混合天气	18447	18447	36894

由于训练数据里的中、低风速样本数据(0—15m/s)占绝大多数(约占总数的 98.7%), 因此使用全部风速数据(包括高风速和中、低风速)训练的神经网络, 在反演海面风速时对中、低风速信号敏感, 反演的精度较高。而高风速信号由于受到中、低风速信号覆盖, 使得神经网络对其反应迟钝, 反演精度也较低。但是在高风速和中、低风速下分别对神经网络进行训练可以得到较高的反演精度。因此, 考虑通过对风速分类进行反演的方法以提高反演精度。同时, 由于不同的天气状态下神经网络反演具有不同的表现, 因此也区分晴天和有云天两种天气状态分别进行试验。

在下面的讨论中, 将分三种类型对神经网络进行分析。第一种类型将风速分为高风速和中、低风速两类, 在训练网络和反演风速的时候根据风速大小分别使用对应的神经网络。第二种类型将天气状态分

为晴天和有云天, 在训练网络和反演风速的时候也根据天气情况分别使用相对应的神经网络。第三种类型将前面的两类结合起来, 考虑晴天高风速, 晴天中、低风速, 有云天高风速和有云天中、低风速四种状况分别使用不同的神经网络进行训练和反演风速。本文中将要用到的各种神经网络均为前向型 BP 神经网络。

2 高风速和中、低风速分类的神经网络方法

首先建立单参数神经网络模型 SANN 和复合多参数神经网络模型 CMANN-1、CMANN-2。单参数神经网络 SANN 用于初步判断风速范围, 复合多参数神经网络 CMANN-1、CMANN-2 分别用于反演分类后的高风速和中、低风速。单参数神经网络 SANN 的结构见图 1a。SANN 有个输入层、一个隐含层和一个输出层。输入层为 7 个节点, 对应 SSM/I 的 7 个亮温输入项; 隐含层 30 个节点; 输出层一个节点, 对应输出项风速(孟雷, 2005)。

由于 SSM/I 亮温资料里面含有相对风向的信息(Wick *et al*, 2000), 而且这种风向信息随着风速的增加而增大(Bates *et al*, 2000)。使用 SSM/I 亮温值进行海面风速的反演时, 会受到相对风向的影响(Wentz, 1992; Wentz, 1997), 因此加入相对风向的信息能够改善风速反演的精度。考虑到相对风向信息对风速反演精度的提高, 作者建立复合神经网络模型(CMANN-1 或 CMANN-2)用于分别反演高风速和中、低风速, 流程结构见图 1b。前一个网络(cmann-a)用于计算相对风向, 见图 1c; 后一个网络(cmann-b)用于计算风速, 见图 1d。复合多参数神经网络 cmann-a 和 cmann-b 也有一个输入层、一个隐含层和一个输出层。复合多参数神经网络 cmann-a 的输入层和隐含层同单参数神经网络 SANN 的一样, 输出层有 3 个节点, 对应 3 个输出项: 相对风向、海面温度和海面气温。复合多参数神经网络 cmann-b 的输入项有 8 个节点, 除了 7 个 SSM/I 亮温外, 还增加了相对风向作为输入项。输出项为风速、海面温度和海面气温。

然后使用高风速数据, 中、低风速数据和混合数据分别对复合多参数神经网络 CMANN-1、CMANN-2 和单参数神经网络 SANN 进行训练。训练完成后使用训练过的神经网络进行海面风速的反演。将 SSM/I 亮温输入到单参数神经网络 SANN 中, 输出的风速经过判断分为高风速和中、低风速两类。再将高风速值对应的 SSM/I 亮温值输入到使用高风速数据训练

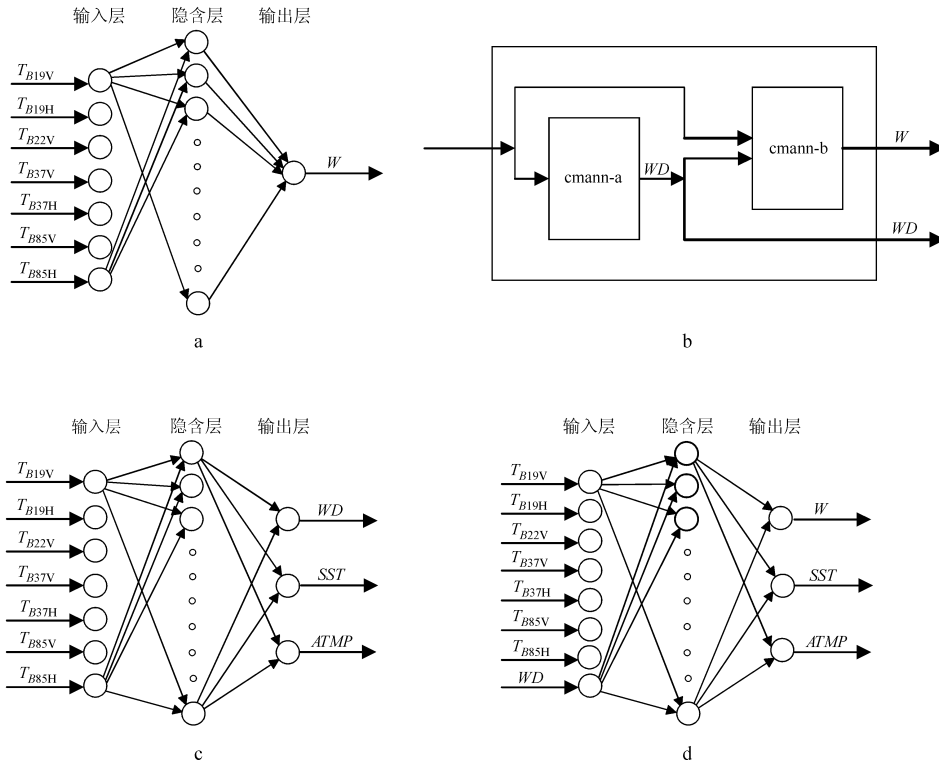


图 1 神经网络结构和流程图

Fig.1 The topological configuration of the neural network and the flow chart

a. 单参数神经网络(SANN)结构图; b. 复合多参数神经网络(CMANN-1/ CMANN-2)流程图; c. 复合多参数神经网络 cmann-a 的结构图; d. 复合多参数神经网络 cmann-b 的结构图 (W 为风速; WD 为相对风向; SST 为海面温度; $ATMP$ 为海面气温)

过的复合多参数神经网络 CMANN-1 中, 作进一步计算, 再次输出风速, 将此风速作为网络的最终输出风速(高风速)。同理, 当将中、低风速值对应的 SSM/I 亮温值输入到使用中、低风速数据训练过的复合多参数神经网络 CMANN-2 中, 将其输出的风速作为网络的最终输出风速(中、低风速)。

图 2 为风速分类方法反演的风速与浮标风速比较图, 图中反演风速值在风速为 15m/s 的地方明显地分为上下两个部分。上面的部分为反演风速大于 15m/s 的点, 下面的部分为反演风速小于或等于 15m/s 的点。两块散点之间的空隙是由于使用单参数神经网络判断高风速和中、低风速时产生的误差。为了降低这种误差(约为 1—2m/s), 在对 CMANN-1 和 CMANN-2 进行训练的时候, 使用风速值大于 14m/s 的数据作为高风速数据, 风速值小于或等于 16m/s 的数据作为中、低风速数据对两个网络分别训练。

考虑到风速判断时产生的误差, 而且为了增加高风速数据的相对数量, 使用 12m/s 作为高风速和中、低风速的分界值。训练时使用风速值大于 11m/s 的数据作为高风速数据, 风速值小于或等于 13m/s 的

数据作为中、低风速数据对两个网络分别进行训练(图 3)。图中的高风速点不仅被校正到浮标风速值处, 而且与中、低风速点之间的间隙变得更小。




图 2 风速分类(15m/s)神经网络方法反演风速与浮标风速比较图

Fig.2 SSM/I-buoy comparison in surface wind speed at 15 m/s




图 3 风速分类(12 m/s)神经网络方法反演风速与浮标风速比较图

Fig.3 SSM/I-buoy comparison in surface wind speed at 12 m/s

3 天气分类的神经网络方法

将天气分类的进行风速反演的神经网络方法与风速分类的神经网络方法类似, 不同的是在判断天气时可以直接使用 SSM/I 亮温数据进行。

天气状态的判断标准如下(Thiria *et al.*, 1993):

$$T_{B37V} - T_{B37H} > 50K \quad \text{晴天状态} \quad (1)$$

$$T_{B37V} - T_{B37H} \leq 50K$$

$$T_{B19H} \leq 185K$$

$$T_{B37H} \leq 210K$$

$$T_{B19V} < T_{B37V} \quad \text{云天状态} \quad (2)$$

T_{B37V} 和 T_{B37H} 分别表示 SSM/I 的 37GHz 通道垂直和水平极化亮温值, T_{B19V} 和 T_{B19H} 分别表示 SSM/I 的 19GHz 通道垂直和水平极化亮温值。分别使用晴天和有云天的数据对复合多参数神经网络 CMANN-3 和 CMANN-4 进行训练。复合多参数神经网络 CMANN-3 和 CMANN-4 与前面讨论的复合多参数神经网络 CMANN-3 和 CMANN-4 的结构一样。在进行反演时, 首先根据公式(1)和公式(2)判断天气状态, 然后根据不同的天气状态使用在不同天气状态下训练的神经网络(CMANN-3 和 CMANN-4)反演海面风速。图 4a 和 b 分别为神经网络反演的晴天和有云天条件下的风速与浮标风速散点图, 图 4c 为天气分类方法反演风速与浮标风速比较图, 其效果为前两者的叠加。

4 考虑四种状况的分类神经网络方法

综合考虑前面两种分类方法, 分四种情况使用

神经网络对风速进行反演。使用晴天高风速, 晴天中、低风速, 有云天高风速和有云天中、低风速四种状况下的数据对四个复合多参数神经网络模型 CMANN-1、CMANN-2、CMANN-3 和 CMANN-4 进行训练。使用晴天和有云天的数据分别对单参数神经网络模型 SANN-1 和 SANN-2 进行训练。单参数神经网络模型和复合多参数神经网络模型的结构同前面的讨论一样。




图 4 晴天和云天神经网络方法反演风速与浮标风速散点图

Fig.4 SSM/I-buoy comparison in surface wind speed in clear and cloudy conditions

在反演风速的时候, 首先将 SSM/I 亮温数据代入公式(1)和公式(2)判断天气状态。晴天状态下的数据输入到单参数神经网络 SANN-1 中判断高风速和中、低风速(以 12m/s 为分界风速值), 然后将高风速和中、低风速状态下的亮温数据分别输入到复合多参数神经网络模型 CMANN-2 和 CMANN-1 中, 计算得到风速值。有云天气状态下的数据则输入到单参数神经网络 SANN-2 中判断高风速和中、低风速(同样以 12m/s 为分界风速值), 然后将高风速和中、低风速状态下的亮温数据分别输入到复合多参数神经网络模型 CMANN-4 和 CMANN-3 中, 计算得到风速值。

考虑到 SANN-1 判断风速时产生的误差, 当风速值大于 10m/s 而小于 14m/s, 使用 CMANN-1 和 CMANN-2 反演风速的均值作为晴天状态下的反演风速值。同样, 当 SANN-2 判断得到的风速值介于 10m/s 和 14m/s 之间时, 使用 CMANN-3 和 CMANN-4 反演风速的均值作为有云天状态下的反演风速值。

图 5a—d 分别为晴天中、低风速, 云天中、低风速, 晴天高风速和云天高风速四种状态下的神经网络反演的风速于浮标风速散点图。从图 5 中可以看出, 无论是中、低风速段还是高风速段, 晴天的样本点要

多于有云天的样本点。而且, 在云天天气条件下, 小于 2m/s 的中、低风速数据极少(图 5b)。图 6a 为四种状态下的分类神经网络方法反演风速与浮标风速的对比图, 图 6b 为没有使用分类神经网络方法而直接使用单参数神经网络方法反演风速与浮标风速的对比图, 反演风速与浮标实测风速之间的均方根误差为 1.61m/s(孟雷, 2005)。图 6a 等价于图 5a—d 的叠加效果。此种分类神经网络方法反演风速的相关系数达到 0.87, 与浮标实测风速之间的均方根误差为 1.60m/s。这个风速精度比没有分类而直接使用神经网络进行反演得到反演风速精度略有提高, 特别是在高风速(>15m/s)状态下反演风速值比实际风速偏低的情况有了改进, 反演的高风速值被校正到了正常位置(图中实线附近)。由于在分界风速附近的点采用数据融合的方法(两个网络求平均), 在判断高风速和中、低风速时候产生的误差被进一步降低, 类似于图 2 和图 3 中产生的高风速和中、低风速之间的间隔几乎消失。

5 结语

本文中作者探讨了三种分类神经网络反演海面




图 5 四种状态下神经网络反演风速与浮标风速散点图

Fig.5 SSM/I-buoy comparison in surface wind speed in four weather conditions




图 6 神经网络反演风速与浮标风速散点图

Fig.6 SSM/I-buoy comparison in surface wind speed

风速的方法。三种方法反演风速效果较好,精度达到了较高值。特别是第三种分类方法,由于采用了数据融合等方法,使得反演效果有了进一步的提高,神经网络反演海面风速的值与浮标实测风速值之间的均方根误差达到 1.60m/s。此方法较好地去除了由于高风速状态和云天天气状态下训练样本数据缺少所产生的误差,改进了在高风速状态下反演风速值比实际风速偏低的情况。这种新型的方法为进一步发展神经网络方法反演风速提供了一个很好的思路,而且还有改进的空间。本文中使用的检验样本高风速样本所占比例仅为 1%,因此高风速反演被校正对整体风速反演精度的提高并不是很明显,反演风速精度仅有略微提高。通过增加高风速训练样本和改变高风速和中、低风速神经网络训练使用的风速范围,可以降低判断风速产生的误差,从而进一步降低风速反演的误差。

致谢 本文中使用的 TAO 和 NDBC 浮标数据分别来自 Pacific Marine Environmental Laboratory 和 National Data Buoy Center 的官方网站 www.pmel.noaa.gov 和 www.ndbc.noaa.gov, SSM/I 数据来自 Global Hydrology Resource Center 的官方网站 ghrc.msfc.nasa.gov。另外,作者对申辉、丘仲锋、李海艳和张彪等对本论文的工作给予帮助,谨致谢忱。

参 考 文 献

孟雷,何宜军,伍玉梅,2006. 基于 SSM/I 数据的神经网络方法反演海面风速. 高技术通讯, 16(7): 763—771

- Bates J J, Wick G A, Gottschall C C, 2000. Passive microwave remote sensing of wind direction using SSM/I data. *IEEE Trans Geosci Remote Sensing*, 38:823—837
- Goodberlet M A, Swift M A, Wilkson J C, 1989. Remote sensing of ocean surface winds with the special sensor microwave/imager. *Journal of Geophysics Research*, 94:14547—14555
- Goodberlet M A, Swift M A, 1992. Improved retrievals from the DMSP wind speed algorithm under adverse weather conditions. *IEEE Trans Geosci Remote Sensing*, 30: 1076—1077
- Krasnopolsky V, Gemmill W H, Breaker L C, 2000. A neural network multiparameter algorithm for SSM/I ocean retrievals: comparisons and validations. *Remote Sensing of Environment*, 73: 133—142
- Stogryn A P, Butler C T, Bartolac T J, 1994. Ocean surface wind retrievals from special sensor microwave imager data with neural networks. *Journal of Geophysics Research*, 99:981—984
- Thiria S C Mejia, Badran F, Crepon M, 1993. A neural network approach for modeling nonlinear transfer function: application for wind retrieval from spaceborn scatterometer data. *J Geophys Res*, 88: 22827—22841
- Wentz F J, 1992. Measurement of oceanic wind vector using satellite microwave radiometers. *IEEE Trans Geosci Remote Sensing*, 30: 960—972
- Wentz F J, 1997. A well calibrated ocean algorithm for SSM/I. *J Geophys Res*, 102: 8703—8708
- Wick G A, Bates J J, Gottschall C C, 2000. Observational evidence of a wind direction signal in SSM/I passive microwave data. *IEEE Trans Geosci Remote Sensing*, 38(2): 823—837

AN IMPROVED ALGORITHM FOR SEA SURFACE WIND SPEED RETRIEVAL OF A CLASSIFIED NEURAL NETWORK

MENG Lei^{1,2}, HE Yi-Jun¹, WU Yu-Mei^{1,2}

(1. *Institute of Oceanology, Chinese Academy of Sciences, Qingdao, 266071;*

2. *Graduate School of Chinese Academy of Sciences, Beijing, 100049*)

Abstract A new neural network algorithm is developed to improve the retrieval precision of the global sea surface wind speed from the SSM/I brightness data. At first, the data in different conditions, such as high-speed and low-speed winds, and clear and cloudy weather, are used to train different neural networks. Then these neural networks are used independently to retrieve the sea surface wind speed. Compared with the buoy wind, the RMS (root mean square) error of the retrieving is about 1.60m/s. This method reduces the bias resulted from the lack of quality data in high-speed wind, and cloudy weather on the neural network algorithm.

Key words Neural network, SSM/I data, Sea surface wind speed