

引用格式:郭晨龙,仇振安,孙瑞彬.基于增量学习的合成孔径雷达目标识别算法[J].电光与控制,2019,26(1):31-33,103. GUO C L, QIU Z A, SUN R B. Synthetic aperture radar target recognition based on incremental learning algorithm[J]. Electronics Optics & Control, 2019, 26(1):31-33, 103.

基于增量学习的合成孔径雷达目标识别算法

郭晨龙^{1,2}, 仇振安³, 孙瑞彬⁴

(1. 光电控制技术重点实验室, 河南 洛阳 471000;
2. 中国航空工业集团公司洛阳光电设备研究所, 河南 洛阳 471000;
3. 陆航驻洛阳地区军事代表机构, 河南 洛阳 471000; 4. 山东科技大学, 济南 250031)

摘要:传统的合成孔径雷达(SAR)目标识别往往采用批量学习的方法,但是在现实应用中,系统的训练数据并不能一次性全部获得,当有新的训练样本到来时,采用批量学习方法需要重新训练整个系统。为解决这个问题,将增量学习算法——正则在线序贯式极限学习机(ROSELM)应用到SAR目标识别中,并且采用粒子群算法优化ROSELM的初始权值以提高其稳定性和识别率。实验结果表明,该算法在新的SAR目标样本获得时只需要通过更新输出权值即可完成系统的更新,无需重新训练,且速度极快、识别率高,可以作为SAR目标识别系统在线更新的良好选择。

关键词:合成孔径雷达; 目标识别; 极限学习机; 增量学习

中图分类号: TP391.41 文献标志码: A doi:10.3969/j.issn.1671-637X.2019.01.007

Synthetic Aperture Radar Target Recognition Based on Incremental Learning Algorithm

GUO Chen-long^{1,2}, QIU Zhen-an³, SUN Rui-bin⁴

(1. Science and Technology on Electro-Optic Control Laboratory, Luoyang 471000, China; 2. Luoyang Institute of Electro-Optical Equipment, AVIC, Luoyang 471000, China; 3. Military Representative Office of Army Aviation in Luoyang, Luoyang 471000, China; 4. Shandong University of Science and Technology, Ji'nan 250031, China)

Abstract: Target recognition of conventional Synthetic Aperture Radar (SAR) usually adopts the batch learning method. However, in practical application, the training data of the system can't be obtained all at one time. When new training sample arrives, the whole system needs to be retrained when using the method of batch learning. In order to solve this problem, ROSELM, an incremental learning algorithm, is applied to SAR target recognition, and Particle Swarm Optimization (PSO) algorithm is used to optimize the initial weight of ROSELM to improve its stability and recognition rate. The experimental results show that: 1) When new SAR target samples are obtained, the system updating can be implemented simply by updating the output weights without re-training; 2) The algorithm is very fast and has a high recognition rate, which is a good choice for online updating of SAR target recognition system.

Key words: synthetic aperture radar; target recognition; extreme learning machine; incremental learning

0 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)能够全天时、全天候进行侦察,同时还能够对地表形成一定的穿透力,由于这些优点SAR已经成为现代战场侦察的重要手段^[1]。近年来,基于SAR的目标识别技术

也已经成为学者们研究的热点^[2-5]。

传统的基于机器学习的SAR目标识别训练思路是:离线采集海量的目标样本进行标签标定、特征提取和分类器训练,获得的分类模型再对未知样本进行识别。然而在现实应用中,不可能一次性就获得全部的目标训练样本,所以需要有一个庞大的数据库来保存样本,更新分类模型则需要对分类器进行重新训练,计算量巨大且需要消耗大量的存储设备来保存历史数据。针对这个问题,本文提出了一种采用在线序贯极限学习机^[6]的SAR目标识别算法,该方法在不损失极限学习机性能

收稿日期:2018-02-01 修回日期:2018-11-13

基金项目:国家自然科学基金(60974005)

作者简介:郭晨龙(1988—),男,河南洛阳人,硕士,工程师,研究方向为图像处理与模式识别。

的情况下,通过递推的方式使之成为一种有效的增量学习算法,当有样本添加时,只需通过对极限学习机的输出权值进行递推更新即可完成模型的更新,该算法训练速度快,节省了大量内存,且识别率与批量算法持平,在 SAR 目标识别上有很大的应用价值。

1 基于增量学习的 SAR 目标识别模型

1.1 增量极限学习机的原理

HUANG 等^[7]提出了极限学习机算法(ELM),该算法指出前馈神经网络的输入层连接权值无需进行训练,可以随机设置,当给定了网络的隐层节点数目和输入层的连接权值以后,前馈神经网络的隐层输出矩阵 \mathbf{H} 就变成了一个已知的矩阵,只要求出输出权值 $\boldsymbol{\beta}$ 的正则化最小二乘解就可以完成对网络的训练。

给定一批训练样本 $S_0 = \{(x_i, y_i) \mid x_i \in \mathbf{R}^n, y_i \in \mathbf{R}^m\}_{i=1}^N$, 极限学习机的求解算式为

$$\boldsymbol{\beta}_0 = \left(\mathbf{H}_0^T \mathbf{H}_0 + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{H}_0^T \mathbf{T}_0 \quad (1)$$

式中: $\boldsymbol{\beta}_0$ 为网络的输出权值矩阵; \mathbf{H}_0 为网络的隐层输出矩阵; \mathbf{I} 为单位矩阵; C 为惩罚因子; \mathbf{T}_0 为样本的标签矩阵。

极限学习机具有速度极快、泛化性良好、参数选择简单的特点,相对 BP 网络,支持向量机等算法具有很多优势,已经取得很多应用^[8-9]。

但是普通的极限学习机是一个批量训练算法,当新的训练数据加入时,还需要重新进行系统训练,既浪费内存,又消耗时间,为了解决这个问题,本文将 ELM 算法推导为增量更新的形式(ROSELM)。

在一批含有 M 个训练样本的新数据 $S_1 = \{(x_i, y_i) \mid x_i \in \mathbf{R}^n, y_i \in \mathbf{R}^m\}_{i=1}^M$ 需要加入到模型中时,网络的新的隐含层输出矩阵 \mathbf{H} 和输出矩阵 \mathbf{T} 可分别写成

$$\begin{cases} \mathbf{H} = \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix} \\ \mathbf{T} = \begin{bmatrix} \mathbf{T}_0 \\ \mathbf{T}_1 \end{bmatrix} \end{cases} \quad (2)$$

式中: \mathbf{H}_1 为新入训练样本的隐含层输出矩阵; \mathbf{T}_1 为新样本的类别标签矩阵。于是新的输出权值 $\boldsymbol{\beta}$ 可以表示为

$$\boldsymbol{\beta} = \left(\mathbf{H}^T \mathbf{H} + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{H}^T \mathbf{T} = \left(\mathbf{H}_0^T \mathbf{H}_0 + \mathbf{H}_1^T \mathbf{H}_1 + \frac{\mathbf{I}}{C} \right)^{-1} (\mathbf{H}_0^T \mathbf{T}_0 + \mathbf{H}_1^T \mathbf{T}_1) \quad (3)$$

令

$$\begin{cases} \mathbf{P}_1 = \left(\mathbf{H}_0^T \mathbf{H}_0 + \mathbf{H}_1^T \mathbf{H}_1 + \frac{\mathbf{I}}{C} \right)^{-1} \\ \mathbf{P}_0 = \left(\mathbf{H}_0^T \mathbf{T}_0 + \frac{\mathbf{I}}{C} \right)^{-1} \end{cases} \quad (4)$$

于是有

$$\mathbf{P}_1 = (\mathbf{P}_0^{-1} + \mathbf{H}_1^T \mathbf{H}_1)^{-1} \quad (5)$$

根据 Sherman-Morrison 矩阵求逆的引理,可以对式(5)进行递推得到

$$\mathbf{P}_1 = \mathbf{P}_0 - \frac{\mathbf{P}_0 \mathbf{H}_1^T \mathbf{H}_1 \mathbf{P}_0}{1 + \mathbf{H}_1 \mathbf{P}_0 \mathbf{H}_1^T} \quad (6)$$

由式(6)可以看出, \mathbf{P}_1 可由 \mathbf{P}_0 递推求解得出。

同时有

$$\boldsymbol{\beta}_0 = \left(\mathbf{H}_0^T \mathbf{H}_0 + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{H}_0^T \mathbf{T}_0 = \mathbf{P}_0 \mathbf{H}_0^T \mathbf{T}_0 \quad (7)$$

那么可以推导式(3)有

$$\begin{aligned} \boldsymbol{\beta} &= \left(\mathbf{H}_0^T \mathbf{H}_0 + \mathbf{H}_1^T \mathbf{H}_1 + \frac{\mathbf{I}}{C} \right)^{-1} (\mathbf{H}_0^T \mathbf{T}_0 + \mathbf{H}_1^T \mathbf{T}_1) = \\ &= \boldsymbol{\beta}_0 + \mathbf{P}_1 \mathbf{H}_1^T (\mathbf{T}_1 - \mathbf{H}_1 \boldsymbol{\beta}_0) \end{aligned} \quad (8)$$

式(8)中, $\boldsymbol{\beta}_0, \mathbf{H}_1, \mathbf{T}_1$ 都是已知矩阵, \mathbf{P}_1 也可以在 \mathbf{P}_0 的基础上递推获得。可以看出,新的 $\boldsymbol{\beta}$ 可以在旧的模型下递推得到,而不需要重新训练,以此类推有

$$\boldsymbol{\beta}_{k+1} = \boldsymbol{\beta}_k + \mathbf{P}_{k+1} \mathbf{H}_{k+1}^T (\mathbf{T}_{k+1} - \mathbf{H}_{k+1} \boldsymbol{\beta}_k) \quad (9)$$

可知,当有新的数据到来时, $\boldsymbol{\beta}_{k+1}$ 在 $\boldsymbol{\beta}_k$ 的基础上递推得来,而不需要全部重新训练。

1.2 ROS-ELM 的权值优化

从 1.1 节可以看出,ROSELM 可以分为初始化批量学习和增量式更新两种形式。然而在批量学习阶段,ROSELM 的输入层连接权值是随机给定的,这就造成了算法的不稳定,针对此问题,本文采用粒子算法优化序贯极限学习机的初始化权值(PSO-ROSELM),然后再继续计算输出权值,算法步骤如下所述。

1) 以训练数据的 10 折交叉验证分类准确率为适应度函数;

2) 以输入权值为粒子群算法的优化目标,采用构建的适应度函数进行优化获得最佳的权值;

3) 采用式(1)进行初始数据批量学习;

4) 采用式(9)进行模型的增量更新。

1.3 SAR 目标识别的增量模型

一个完整的 SAR 目标识别系统包括预处理、特征提取、分类器训练 3 个部分。

由于 SAR 成像往往具有较高的相干斑噪声,对目标识别影响较大^[10],所以采用非局部均值滤波算法^[11]对图像进行预处理操作。

随后采用 2D-gabor 变换提取图像 5 个中心频率,8 个方向的 gabor 特征,gabor 变换算式为

$$\begin{cases} g(\mathbf{x}) = \frac{\|\mathbf{k}_j\|^2}{\sigma^2} \times \exp\left(-\frac{\|\mathbf{k}_j\|^2 \|\mathbf{x}\|}{2\sigma^2}\right) \times \\ \quad \left[\exp(i\mathbf{k}_j \cdot \mathbf{x}) - \exp\left(-\frac{\sigma^2}{2}\right) \right] \\ \mathbf{k}_j = \begin{bmatrix} k_{jx} \\ k_{jy} \end{bmatrix} = \begin{bmatrix} k_x \cos \phi_u \\ k_x \sin \phi_u \end{bmatrix} \end{cases} \quad (10)$$

式中: x 为给定的图像的坐标; k_f 为设置的滤波器的中心频率; ϕ_s 为滤波器的方向选择性; k_s 对应纹理的波长; σ 为高斯窗口的大小。

由于经 gabor 滤波器处理后的图像数据特征维度较大,采用文献[12]所述带有增量更新能力的增量主成分分析(IPCA)对特征进行压缩处理。

最后,采用 1.2 节中带有增量更新能力的 PSO-ROSELM 算法进行模型训练,构成本文的 SAR 目标识别增量学习模型。该模型可以批量学习一批初始样本,在有新的样本加入时采用增量式学习对模型进行更新。

2 实验与分析

本文采用美国国防高等研究计划署(DARPA)支持的 MSTAR 计划所公布的实测 SAR 地面静止目标数据作为实验数据,该数据由高分辨率的聚束式合成孔径雷达采集获得,雷达的分辨率为 $0.3 \text{ m} \times 0.3 \text{ m}$,工作在 X 波段,采用 HH 的极化方式。

本文对其中的 BMP2, BTR70 和 T72 目标进行目标识别实验。

把本文的 PSO-ROSELM 增量算法和批量学习的粒子群优化极限学习机(PSO-ELM)算法进行对比,分别对比不同比例训练样本下两者的识别率(样本比例分别为 10%, 20%, ..., 100%),其中,PSO-ROSELM 选择 10% 的初始样本进行批量训练,剩下的样本作为新入样本进行增量式更新,两种算法的识别性能对比结果如图 1 所示。




图 1 极限学习机增量算法和批量算法识别率对比

Fig. 1 The recognition rate of incremental ELM and batch ELM

从图中可以看出,批量学习的 PSO-ELM 和增量学习的 PSO-ROSELM 取得了相近的识别性能,这也说明了 PSO-ROSELM 增量更新的有效性。

图 2 给出了 PSO-ELM 和 PSO-ROSELM 算法的计算时间消耗的对比如。从图中可以看出,随着样本的增多,批量学习的 ELM 算法需要重新训练,消耗的时间越来越多,而增量 ELM 只需对输出权值进行更新,因而计算量增加不大,消耗时间随着样本增加远低于批量训练的 ELM 算法。




图 2 ELM 增量算法和批量算法时间消耗对比

Fig. 2 The time consumption of incremental ELM and batch ELM

表 1 给出了本文增量学习方法与批量的粒子群优化极限学习机(PSO-ELM)算法、支持向量机(SVM)算法、BP 神经网络(BP)算法的性能对比,其中,SVM 采用 RBF 激励核函数,BP 神经网络算法采用 Sigmoid 激励函数。

表 1 几种算法性能对比

Table 1 The performance comparison of several algorithms

算法	识别率/	时间消耗/s
本文方法	0.926	3.8
PSO-ELM	0.928	23.3
SVM	0.87	75.5
BP	0.81	128.4

从表中可以看出,本文增量学习方法的识别率与批量的 PSO-ELM 算法的识别率相差无几且远高于 SVM 算法和 BP 神经网络算法,在计算时间消耗上本文方法远低于其他几种算法,这也证明了本文的增量学习方法的优越性。

3 结论

本文针对传统批量式合成孔径雷达图像目标识别系统训练效率低、计算量大、计算代价高的问题,提出了一套增量学习的方法,首先采用非局部均值滤波算法去除目标的相干斑噪声,随后采用 40 组 gabor 滤波器进行纹理特征处理,然后采用带有增量学习能力的 IPCA 进行特征压缩降维,最后采用本文提出的具有增量学习能力的 PSO-ROSELM 进行分类器训练。

实验结果表明,本文方法计算复杂度低,计算速度快,能够增量式更新,并且取得了与批量训练的 ELM 算法相差无几的识别性能,同时在分类精度上要高于传统的 BP 神经网络算法和支持向量机等算法,具有一定的优越性。

参考文献

- [1] 文贡坚,朱国强,殷红成,等. 基于三维电磁散射参数 (下转第 103 页)

- (ICRA), IEEE, 2013:1736-1741.
- [5] SHEN C, BAI Z, CAO H, et al. Optical flow sensor/INS/magnetometer integrated navigation system for MAV in GPS-denied environment [J]. *Journal of Sensors*, 2016, 6105803:1-10.
- [6] WEISS S, BROCKERS R, MATTHIES L. 4DoF drift free navigation using inertial cues and optical flow[C]//IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), IEEE, 2013:4180-4186.
- [7] 黄赞,张宪民. 改进的基于光流的鲁棒多尺度运动估计算法[J]. *华南理工大学学报:自然科学版*, 2009, 37(11):118-122.
- [8] 朱平,甄子洋,覃海群,等. 基于立体视觉和光流的无人机避障算法研究[J]. *电光与控制*, 2017, 24(12):31-35.
- [9] 高扉扉,陈念年,范勇,等. 一种旋翼式无人机的视觉着陆位姿估计方法[J]. *电光与控制*, 2017, 24(2):35-38.
- [10] LUCAS B D, KANADE T. An iterative image registration technique with an application to stereo vision[C]//Proceedings of Imaging Understanding Workshop, 1981:121-130.
- [11] FLEET D J, JEPSON A D. Computation of component image velocity from local phase information [J]. *International Journal of Computer Vision*, 1990, 5(1):77-104.
- [12] HUANG L, SONG J M, CHEN P H, et al. Visual navigation for UAV using optical flow estimation[C]//Proceedings of the 33rd Chinese Control Conference, IEEE, 2014:816-821.
- [13] HERISSÉ B, HAMEL T, MAHONY R, et al. Landing a VTOL unmanned aerial vehicle on a moving platform using optical flow [J]. *IEEE Transactions on Robotics*, 2012, 28(1):77-89.
- [14] SONG Q. On the weight convergence of Elman networks [J]. *IEEE Transactions on Neural Networks*, 2010, 21(3):463-480.
- (上接第33页)
- 化模型的 SAR 目标识别方法[J]. *雷达学报*, 2017, 6(2):115-135.
- [2] 雷磊,杨秋,李开明. 基于多尺度稀疏字典的 SAR 图像目标识别方法[J]. *火力与指挥控制*, 2017, 42(4):10-13.
- [3] 耿杰,范剑超,初佳兰,等. 基于深度协同稀疏编码网络的海洋浮筏 SAR 图像目标识别[J]. *自动化学报*, 2016, 42(4):593-604.
- [4] 丁军,刘宏伟,陈渤,等. 相似性约束的深度置信网络在 SAR 图像目标识别的应用[J]. *电子与信息学报*, 2016, 38(1):97-103.
- [5] 丁军,刘宏伟,王英华. 基于非负稀疏表示的 SAR 图像目标识别方法[J]. *电子与信息学报*, 2014, 36(9):2194-2200.
- [6] LIANG N Y, HUANG G B, SARATCHANDRAN P, et al. A fast and accurate online sequential learning algorithm for feed forward networks[J]. *IEEE Transactions on Networks*, 2006, 17(6):1411-1423.
- [7] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. *Neurocomputing*, 2006, 70(1-3):489-501.
- [8] 许学斌,管晓宏,邓万宇,等. 基于多分类投影极速学习机的快速人脸识别方法[J]. *微电子学与计算机*, 2012, 29(7):13-17.
- [9] ZONG W W, HUANG G B. Face recognition based on extreme learning machine [J]. *Neurocomputing*, 2011, 74(16):2541-2551.
- [10] 易子麟,尹东,胡安洲,等. 基于非局部均值滤波的 SAR 图像去噪[J]. *电子与信息学报*, 2012, 34(4):950-955.
- [11] BUADES A, COLL B, MOREL J M. A non-local algorithm for image denoising[C]//CVPR IEEE Computer Society Conference on Computer Vision and Pattern Recognition, IEEE, 2005:60-65.
- [12] 王通,高宪文,蔺雪,等. SWE-IPCA 方法在传感器故障诊断中的应用[J]. *仪器仪表学报*, 2013, 34(8):1841-1846.