一种端到端的日冕物质现象检测新方法

姚海¹, 尹建芹^{1,2*}, 林佳本³, 张玲¹, 王晓帆³

1. 济南大学信息科学与工程学院, 山东省网络环境智能计算技术重点实验室, 济南 250022;

2. 北京邮电大学自动化学院, 北京 100876;

3. 中国科学院太阳活动重点实验室, 北京 100012

* 联系人, E-mail: ise_yinq@ujn.edu.cn

2016-03-23 收稿, 2016-05-10 修回, 2016-05-10 接受, 2017-03-02 网络版发表

国家自然科学基金(61203341, 61375084)和中国科学院太阳活动重点实验室开放课题(TQT1302)资助

摘要 日冕物质抛射与日冕活动、空间天气以及许多行星际的扰动有着密切的联系, 其检测对于空间天气防灾减灾具有重要意义. 现有方法通过人为定义特征或利用简单阈值的方法进行CME检测, 对弱CME或暗CME的检测效果差. 为了解决这一问题, 本文提出了一种端到端的日冕物质抛射检测方法: 通过引入卷积神经网络, 自动提取适应于描述日冕物质抛射检测的图像特征, 并基于这些自动提取的特征建立日冕物质抛射检测模型. 该过程不需要人为参与特征的选择及分类规则的设定, 可以方便地实现数据到结果的端到端的映射. 实验结果表明, 在本文构建的测试数据集上可以得到98.05%的准确率, 并以2007年5月的观测数据为例, 检测了26个普通CME事件中的24个事件, 得到了优于当前常用日志的效果. 因此, 本文方法可以有效地进行日冕物质抛射检测.

关键词 日冕物质抛射检测, 太阳活动, 卷积神经网络

日冕物质抛射(coronal mass ejections, CME)^[1]是太阳大气中一种频繁发生的太阳爆发活动现象, 其表现为在几分钟至几小时时间内日冕结构发生明显变化并伴有可观测的物质抛射. CME现象与许多行星际扰动都有着密切的关系, 如果抛射物质对着地球方向传播, 则会对地球的高能粒子环境和地磁环境造成强烈扰动, 从而会影响卫星运行、航空安全等. 因此, CME的检测对太阳物理、空间天文学科本身具有重要意义, 而且对空间环境的预报和防灾、减灾具有一定的实用价值.

CME的检测随着20世纪90年代升空的SOHO(solar and heliospheric observatory), Wind(spacecraft, launched 1994)和STEREO(solar terrestrial relations observatory, launched 2006)等卫星上的仪器设备所获取的资料已经成为可能^[2]. SOHO卫星上搭载的大视

角分光日冕仪(the large angle spectrometric coronagraph, LASCO)可以观测到CME在整个发生过程中的影像资料, 通过分析这些影像资料, 可以描绘出CME的完整演化图像并得到CME演化过程中的数据. 以CME的演化数据作为三维磁流体数值模拟计算的输入, 通过计算可以估计它们将对地球产生的影响, 从而可以采取相应的措施以避免不必要的损失. 而在这一过程中, 确定CME的起始及结束时刻, 即对得到的视频资料进行CME的检测, 可以完成CME起止时间的判断, 为CME演化计算提供数据分析的起止点, 具有重要的意义. 另外, CME的检测可以为空间天气预报人员提供预警信号, 对于空间天气预报具有重要意义.

CME的检测在具有突变的高亮结构特征的图像数据集上取得了巨大的成功^[3-6], 但也面临着较多的

引用格式: 姚海, 尹建芹, 林佳本, 等. 一种端到端的日冕物质现象检测新方法. 科学通报, 2017, 62: 2680–2690

Yao H, Yin J Q, Lin J B, et al. An end-to-end method of Coronal Mass Ejections detection (in Chinese). Chin Sci Bull, 2017, 62: 2680–2690, doi: 10.1360/N972016-00382

困难和挑战: 首先, 在太阳活动过程中, CME现象发生初期和末期的高亮特征十分微弱, 进而会影响到我们检测的CME发生开始及结束时间; 其次, 图像中心的太阳挡板以及图像中彗星、行星运行及本身存在的噪声影响, 对检测这种微弱的CME图像造成了很大的干扰。

针对以上困难和挑战, 现有的处理方法有以下问题: (1) CME检测采用的方法大多都是人为地提取特征, 比如通过灰度、纹理等描述子; (2) 大多采用图像处理结合简单的阈值分割技术进行CME检测; (3) 当前的自动CME检测方法所得到的CME检测结果与人在仔细分析得到的结果差距较大。而随着近年来机器学习技术在图像处理与机器视觉领域获得的巨大成功, 引入机器学习技术改善简单的阈值分割技术有望提高CME检测效果; 而深度神经网络可以自动地根据任务提取良好的分类特征, 在语音识别、图像处理等各方面都取得了比传统机器学习方法好得多的性能。而决定深度学习性能的两个方面: 大数据和高性能计算设备, 在现阶段CME检测任务中都已经完全具备, 为深度学习在CME检测中的应用提供了保证。本文通过引入深度学习技术, 自动选择最适于CME检测的特征, 建立CME的检测模型, 从而提高CME的检测精度。

深度学习中的卷积神经网络通过组合低层特征形成更加抽象的高层表示属性类别或特征, 以发现数据的分布式特征表示, 利用空间相对关系能够自主有效地学习到图像的特征信息。因此, 本文提出了一种新的CME检测方法, 用卷积神经网络(CNN)自主提取CME现象的特征并完成对CME图像的识别, 由于该方法只需要数据就可以生成我们需要的检测模型, 因此, 将其称之为端到端的CME检测方法。

1 常用的CME检测方法

CME通常表现为一个明亮的、纹理复杂的增强结构, 尾随着一个亮度不足的暗区域^[1]。现有的自动CME检测集中于以下两类。

(1) 基于传统的空间域图像处理方法的CME检测, 包括霍夫变换^[3]、数学形态学^[4]等。Berghmans等人^[3]通过霍夫变换对来自LASCO的CME数据进行判别, 并完成了对CME的特征如位置角度、展开角度、速度等基本参量进行定量化描述; Robbrecht等人^[4]在Berghmans的工作基础上改进了CME识别的算法, 能

够通过LASCO C2和C3数据的整合, 对间隔20 min左右的数据进行CME的计算和判别, 在霍夫变换之后加入了聚类形态学方法来标记不同的CME, 提高了系统的识别准确率, 其对于CME爆发的时间和张角确定获得了较好的结果。Boursier等人^[5,6]完成了利用LASCO C2的数据综合图, 通过自适应滤波和阈值分割方法对CME事件检测, 自动识别瞬态事件和Marseille Inventory。Qu等人^[7]完成了一套CME自动CME检测系统, 该系统同时采用了LASCO C2和C3的数据, 利用图像增强、图像分割以及形态学方法对CME进行了检测, 该方法能够对来自LASCO的20 min间隔数据进行实时判别。Olmedo等人^[8]完成了一套对LASCO C2数据序列进行分析, 自动识别CME数据、获取其基本参数然后对其进行分类的系统: 该系统采用的方法流程是数据预处理、识别、跟踪、分类, 采用1维和2维投影法进行识别, 利用阈值分割法获取CME的前导边缘, 该系统计算的CME基本参数是位置角度、展开角度、速度、高度、平均亮度和速度等, 但其无法处理多重CME的情况。Pulkkinen等人^[9]采用中值滤波器和阈值进行CME分割。该方法采用传统的数字图像处理技术, 尽管具有不需要训练的优点, 但难以区分噪声及CME区域, 难以得到好的CME检测效果。

(2) 基于频域变换的图像处理方法。Gonzalez-Gomez等人^[10]采用小波分析的方法对CME进行了分类研究, 分析的结果是从形态上把CME分成两类: 一类是低流量、小尺度的活动现象, 但未涉及CME检测问题; 另一类则是高流量大尺度的活动现象。Gallagher等人^[11]认为CME是一种多尺度特征, 而小波分析在增强典型CME前端曲线的可观性时效果欠佳, 他们采用更高阶的脊小波和curvelet来进行分类和监测。Goussies等人^[12]提出了“事件的纹理(texture of the event)”这一概念, 利用灰度共生矩阵来描述纹理, 并利用有监督的分割算法来提取感兴趣区域, 进行CME的检测, 并提出了CME跟踪的概念。曾昭宪等人^[13]提出了基于频谱突变分析的日冕物质抛射识别方法, 该方法主要是通过预处理去除原始CME观测图像中的各种噪声, 基于CME的视觉统计特性, 利用频谱突变分析从预处理后的观测图像中准确分离CME现象发生区域, 基于区域协方差分析提取出角宽度、速度等CME定量化描述参数。该方法希望在频率域得到更好的刻画CME的特征, 但

本质上是利用了CME的纹理特性, 尽管可以得到相较于空间域图像更好的效果^[12], 但CME外观表征的复杂性及多样性使得现有的频域变换方法难以得到有效的CME检测方法。

综上所述, 现阶段关于CME检测的工作基本基于简单阈值进行, 并人为指定特征进行CME建模, 而由于CME复杂多变, 在形状、纹理及灰度等方面变化差异较大, 因此, 基于人为选择特征的方法不一定能得到好的检测效果; 同时, 简单的阈值分析难以保证好的检测模型。而卷积神经网络可以自动地抽取适应当前任务的特征, 并在图像处理中的较多领域取得了最好的结果, 因此, 本文基于卷积神经网络建立CME检测模型。

2 基于卷积神经网络的CME检测

2.1 卷积神经网络(Convolutional Neural Networks, CNN)

神经网络的提出源于生物脑神经的研究, 通过模拟类似人脑的工作机理, 试图使机器具有类似于人的学习能力^[14]。而卷积神经网络是神经网络发展中的一大进步与创新, 它是一种模拟人脑的深度网络结构, 近年来在大规模图像分类, 语音识别等应用得到了成功的应用, 并在多个领域得到了性能最优的结果^[15-17]。

卷积神经网络采用的是有监督的学习方式, 使用大量的带有标签的数据样本, 结合反向传播算法来更新权值, 最终训练出一个具有分类能力的网络模型。

卷积神经网络中有3个最基本的网络层, 即卷积层、下采样层和全连接层。卷积层是一个特征提取层, 通过不同的卷积核提取输入数据不同的特征, 得到的输出特征映射图作为下一层的输入; 每个卷积核在输入图像上的每个局部区域(该局部区域大小为该卷积核大小)卷积后得到的输出只对应下一层的一个神经元, 这就是卷积神经网络的局部感受野的特点; 由一个卷积核卷积所得到的特征映射图中的每一个神经元都共享该卷积核中的权值, 这体现了CNN的权值共享特征。下采样层是一个降维层, 由于输入都是二维数据, 如果不采取降维操作, 会导致全连接层特征维数较大, 容易造成过拟合, 因此, 通过下采样层在一定区域内进行聚合操作(常用的有均值池化和

最大池化两种方法)达到降维的目的。通过一系列的“卷积层+下采样层”的组合, 最后把提取出来的特征输出到全连接层, 形成特征向量, 以此来训练分类器完成学习任务。

CME现象通常表现为一个明亮的、纹理复杂的增强结构, 并尾随一个亮度不足的暗区域。虽然CME现象都是太阳由中心沿径向发射产生, 但是CME现象发生的方向却不尽相同, 而且每个方向上CME现象发生的区域大小以及形状都是不确定的。因此, CME的位置信息对于CME的检测来说是十分有价值的。而CNN的稀疏连接方式以逐层级联的形式从图像局部到图像整体进行特征提取, 从而把图像从高维空间映射到低维空间, 这种方式有效地编码了图像的位置信息。因此, 基于CNN建立CME检测模型是可行的。针对本文的CME图像与非CME图像的分类任务, 设计了如图1所示的网络结构。

2.2 基于CNN的CME检测

2.2.1 基于CNN的CME检测模型

为了自动发现有利于CME检测的特征, 我们采用了图1所示的网络结构。网络结构共有6层, 由4个卷积层、1个全连接层以及1个输出层所构成。每个卷积层后都跟随一个下采样层, 卷积层的输出通过ReLU激活函数传递到下采样层, 本文中的下采样层采用最大池化的方法; 全连接层后是一个softmax多元分类器; 由于本文的分类任务是针对CME图像与非CME图像的二分类, 因此输出层的神经元数目为2, 对应分类的类别数。

(i) 输入图像预处理。本文采用CME差分图像作为卷积神经网络的输入, 由于实验设备的原因, 并且考虑到模型的训练和测试效率以及最大程度保持原数据的完整性等因素, 我们把原差分图像以双线性插值的方式缩放成大小为128×128的图像。

双线性插值^[18]是一种目前在图像缩放方面被广泛使用的算法, 其优势在于缩放以后的图像质量较好。算法思想为: 目标图像中的坐标像素值为对应原图像中的坐标像素值的2×2邻域内的加权平均像素值。具体算法介绍如下。

假设原图像 O 大小为 $W \times H$, 目标图像(缩放以后的图像)记为 T , 缩放比例为 $scale$ (此处只考虑等比例缩放的情况):

Step 1 计算原图像 O 与目标图像 T 的对应比例:

图1 (网络版彩色) CME检测所用网络结构

Figure 1 (Color online) Network structure for CME detection

$$F_w = \frac{W-1}{W \times \text{scale}-1}, F_h = \frac{H-1}{H \times \text{scale}-1}.$$

Step 2 计算目标图像中的 $T(x', y')$ 对应原图像中的坐标点 $O(x, y)$

$$x = x' \times F_w, y = y' \times F_h.$$

Step 3 由Step 1, Step 2可知, 所得 x, y 为 $x_u + x_v$ 和 $y_u + y_v$ 的形式, 其中 x_u, y_u 分别为 x, y 的整数部分, x_v, y_v 分别为 x, y 的小数部分, 因此, 可得其 2×2 邻域的4个坐标点像素值为

$$O(x_u, y_u), O(x_u + 1, y_u), O(x_u, y_u + 1), O(x_u + 1, y_u + 1).$$

Step 4 以距离越近、权值越大的标准, 计算邻域4个坐标点像素值的权重:

$$\mu(x_u, y_u) = x_v \times y_v,$$

$$\mu(x_u + 1, y_u) = (1 - x_v) \times y_v,$$

$$\mu(x_u, y_u + 1) = x_v \times (1 - y_v),$$

$$\mu(x_u + 1, y_u + 1) = (1 - x_v) \times (1 - y_v).$$

Step 5 最后得到目标图像中的 $T(x', y')$ 的像素值:

$$T(x', y') = \mu(x_u, y_u) \times O(x_u, y_u) + \mu(x_u + 1, y_u) \times O(x_u + 1, y_u) + \mu(x_u, y_u + 1) \times O(x_u, y_u + 1) + \mu(x_u + 1, y_u + 1) \times O(x_u + 1, y_u + 1).$$

(ii) 卷积与池化. 图像预处理后, 对图像进行卷积, 示意图如图2.

如图2所示, 左上方为输入矩阵(图像), 右上方为一个卷积核, 右下方为卷积后的输出矩阵(图像). 卷积计算公式

$$\mathbf{X}_\beta^l = f\left(\sum_{\alpha \in M} \mathbf{X}_\alpha^{l-1} \times k_{\alpha\beta}^l + b_{\alpha\beta}^l\right), \quad (1)$$

其中, $\mathbf{X}$ 表示矩阵, 则 $\mathbf{X}_\beta^l$ 表示 l 层上的第 β 个卷积核所卷积得到的特征映射图; M 表示输入的特征映射图的集合, k 表示卷积核, b 表示每个输出所添加的偏置; f 表示ReLU(Rectified Linear Units)激活函数, 其表示

图2 (网络版彩色)卷积示意图

Figure 2 (Color online) Schematic diagram of convolution

形式

$$f(x) = \max(0, x) = f(x) = f(x) = \begin{cases} 0, & x \leq 0, \\ x, & x > 0. \end{cases} \quad (2)$$

卷积是卷积层中最重要的运算, 是一个特征提取的过程. 卷积操作能够增强原信号特征, 并且在一定程度上能够降低噪声, 这也是卷积神经网络的优势, 而CME检测过程中, 噪声是有较大程度上的影响的, 因此, 卷积对于CME图像的检测具有很大的优势.

卷积完成后, 对卷积后的输出进行池化, 示意图如图3, 池化矩阵大小为 2×2 , 左边为输入的矩阵(图像), 右边为输出的矩阵(图像), 其中灰色区域为其 2×2 邻域内灰度值最大的位置.

虽然卷积层中的稀疏连接方式很大程度上降低了训练参数的数量, 但是图像的维度仍然很大, 对于训练网络十分不便, 而且很容易造成过拟合, 因此, 用池化操作降低特征维度, 而由于CME图像较于非CME图像仍然具有较高的亮度, 所以本文采取的是最大池化的方法, 这样更能达到良好的降维作用, 还

图3 (网络版彩色)池化示意图

Figure 3 (Color online) Schematic diagram of max-pooling

能有效改善分类结果。

(iii) 全连接层. 卷积神经网络经过一系列的卷积层连接下采样层的结构, 最终得到高维的特征矩阵, 在本文所采用的网络结构中, 如图1所示, 就是pool4层中 $5 \times 5 \times 100$ 的矩阵. 全连接层则把该高维矩阵向量化, 用作训练分类器的输入. 用 I_{ij}^l 来表示该高维矩阵, 其大小为 $i \times j \times l$, 向量化表示形式

$$FC = \text{Vec}[I_{11}^1, I_{12}^1, \dots, I_{1j}^1, I_{21}^2, I_{22}^2, \dots, I_{2j}^2, \dots, I_{ij}^l]. \quad (3)$$

(iv) 输出. 本文卷积层中所用卷积核大小为 5×5 , 下采样层中所用最大池化矩阵大小为 2×2 . 输入图像经过第一个卷积层可获得20个特征映射图, 每个特征映射图的大小为 124×124 , 因为是以一个像素点为步长对整个输入图像进行卷积的, 因此得到的特征映射图大小为 $(128-5+1) \times (128-5+1) = 124 \times 124$. 然后通过下采样层的最大池化操作可得到20个大小为 62×62 的特征映射图, 由于最大池化矩阵之间是不重叠的, 所以得到的特征映射图大小为 $(124/2) \times (124/2) = 62 \times 62$. 上一层的输出作为下一层的输入, 比如, 卷积层输出的特征映射图作为下采样层的输入. 第二至第四个卷积层以及各自其后的下采样层都是按照上述方式计算输出的. 因此, 经过第四个卷积层及其下采样层后, 可得到100个大小为 5×5 的特征映射图, 经过全连接层后, 就会连接成一个 $100 \times 5 \times 5 = 2500$ 维的特征向量作为softmax分类器的输入.

上述的CME检测的网络模型所要训练的参数包括: (1) 卷积层中每个卷积核内的权值以及每个卷积核各自的偏置; (2) 全连接层中的权值以及偏置. 其中, (1)部分的参数个数为 $20 \times (5 \times 5 + 1) + 50 \times (5 \times 5 + 1) + 70 \times (5 \times 5 + 1) + 100 \times (5 \times 5 + 1) = 6240$ 个; (2)部分的参数个数为 $2500 \times (2 + 1) = 7500$ 个. 因此, 总共的训练参数有 $6240 + 7500 = 13740$ 个.

2.2.2 CME检测模型的求解

用提取出来的特征向量训练softmax分类器, 所需要优化的损失函数如

$$L(W) = -\frac{1}{N} \sum_{n=1}^N \sum_{k=1}^K \log(P(Y = k | X^{(n)}))^{g(Y^n, k)} + \frac{\lambda}{2} \sum_{i=1}^K \sum_{j=0}^M w_{ij}^2, \quad (4)$$

其中,

$$g(Y^n, k) = f(x) = \begin{cases} 1, & Y^n = k, \\ 0, & Y^n \neq k, \end{cases}$$

且 $P(Y = k | X^{(n)})$ 为第 n 个样本 X 属于第 k 类的概率. 为了

防止过拟合, 本文加入了权值衰减项 $\frac{\lambda}{2} \sum_{i=1}^K \sum_{j=0}^M w_{ij}^2$ 来规范参数 W , 其中 $\lambda > 0$, M 为参数个数.

权值初始化对于模型求解是一个很重要的过程, 如果初始化权值太大, 原信号经过每一层都会大幅度增强, 造成深层信号过大而难以收敛; 如果初始化权值太小, 信号经过每一层都会大量衰减, 造成深层信号丢失. 而Xavier算法^[19]根据输入输出的神经元数量来初始化权值, 能有效地把权值控制在一个合适的范围内, 因此, 本文采用Xavier算法进行权值初始化, 偏置都初始化为0.

Xavier算法按下式进行权值初始化:

$$W = \frac{2}{n_{in} + n_{out}}, \quad (5)$$

其中, n_{in} , n_{out} 分别为该层的输入、输出的神经元个数. 比如, 卷积层的输入是一幅大小为 28×28 的图像, 输出为6个 24×24 的特征映射图, 因此, $n_{in} = 28 \times 28 = 784$, $n_{out} = 6 \times 24 \times 24 = 3456$.

本文用随机梯度下降(stochastic gradient descent, SGD)算法^[20]来优化本文的损失函数 $L(W)$, 使得所学习到的参数 W 能最小化 $L(W)$, W 的参数更新公式

$$W_{t+1} = \gamma W_t - \alpha \frac{\partial}{\partial W} L(W), \quad (6)$$

其中, t 为迭代次数, γ 为动量项, α 为学习率且 $\alpha > 0$. 本文初始化学率 $\alpha = 0.0001$, 并设置动量项 $\gamma = 0.9$. 当测试集上的错误率达到一个平稳值以后, 我们将会人为地调整学习速率: $\alpha/10$, 然后继续训练.

3 数据设置

3.1 数据获取

本文所使用的图像数据均来源于NASA, 训练数

据来源包括2007年01月份和03月份、2013年08月份到12月份以及2014年01月份到03月份的差分图像视频文件。从日冕物质抛射(CME)的差分图像视频文件中逐帧提取图像,形成CME图像数据,总共采集了25247幅图像样本,这些图像通过灰度化处理成为可供本文训练阶段以及测试阶段使用的CME图像数据集。

为保证训练数据的完备性和多样性,本文在采集数据的时候,采用了如下方案:(1)对上述获取到的数据集(记为 T)进行标记,即标记1和0分别表示CME图像和非CME图像;(2)从已标记的数据集中人工筛选一小部分的数据样本组成一个正负样本大致均等的小数据集,记为 S ,并统计每个数据样本的灰度直方图;(3)从剩余的数据样本中,统计每个样本的灰度直方图,逐个与 S 中对应类别的数据集进行相似度测量,若相似度小,则该样本加入数据集 S ,否则直接舍弃。

本文使用KL距离来衡量数据相似度

$$D(P \parallel Q) = \sum_{x \in X} P(x) \log \frac{P(x)}{Q(x)}, \quad (7)$$

P, Q 分别表示数据集 S 和剩余数据集($T-S$)中的每一个样本概率, X 表示灰度值0~255的集合。

然而,灰度直方图特性对图像来说具有旋转不变性,对于CME现象发生区域大小相似但方向不同的CME图像来说,灰度直方图的相似度仍然很大,用上述方案则会被舍弃掉。因此,在上述方案的基础上,本文对采集到的数据集进行了旋转操作,最后,总共得到了20340个训练样本。

3.2 数据集的设置

实验分两个阶段进行:训练阶段和Finetune阶段,训练阶段相当于是一个参数预训练的过程,使用Xavier算法初始化训练参数,通过训练获得较好的参数来适应本文的分类任务;而Finetune阶段是在训练阶段的模型的基础上进行参数微调,也就是用训练阶段的模型参数初始化Finetune阶段的训练参数,以便模型能够学到一个更好的参数设置。

为了适应训练阶段与Finetune阶段各自的学习任务,本文也有针对性的设置了两个数据集。其中,训练阶段使用数据集一,而Finetune阶段使用数据集二。

数据集一中的数据集有16816个图像样本,其中,训练集样本大小为15950,其余的866个样本作为训练阶段的测试数据集,该数据集以CME现象明显的

图像数据为主。

数据集二中的数据集有3524个图像样本,其中,训练集的样本大小为3264,所用测试集大小为260,该数据集以微弱的CME图像为主。

强CME指的是太阳活动剧烈时期由日冕层抛出大量物质,在CME图像上的表现形式一般为:在太阳挡板附近,高亮区域较大,且扩散距离较长,具有很明显的日冕物质抛射现象的特征;而弱CME一般指的是在某次太阳活动事件的前期和末期所发生的CME现象,由太阳日冕层抛射出的物质相对较少,且高亮区域不明显,一般呈现微亮的细条状或是小范围的暗团状。因此,对于强CME图像,具有明显的特征,易于完成分类检测的任务。所以,网络着重于对弱CME图像的分类,再加之弱CME图像与非CME图像之间的区别非常小,因此,对于非CME图像数据的选取显得尤为重要。

为了在训练过程中网络能够学习到较好的参数,正负样本的数量应该尽量均衡。再考虑到非CME图像都十分相似,而CME图像多样性很大,于是,本文采取如下策略:对于CME图像,选取部分图像逆时针方向分别进行90°,180°,270°的翻转,以此来增加数据集的多样性;而对于非CME图像,全部逆时针方向分别进行90°,180°,270°的翻转,以此来扩充负样本的多样性。

4 实验结果与分析

4.1 实验设置

本文实验采用主频为2.40 GHz、内存为4.00 GB以及64位的Windows 7操作系统的Lenovo电脑上完成的,网络模型在单块Geforce 940 M的GPU上训练完成。

训练阶段采用数据集一,Finetune阶段采用数据集二。这样设置的原因是:强CME图像与非CME图像之间的区别较大,有利于网络模型在训练阶段学习到较好的参数来适应本文CME检测的分类任务;以此良好的参数为基础,在Finetune阶段用弱CME图像进行参数调优,由此训练出来的网络模型能达到更好的分类效果。

4.2 实验结果及分析

(i) 实验结果。在训练过程中,进行了全库迭

代训练17次以后得到深度网络模型,在Finetune过程中,进行了全库迭代40次以后得到深度网络模型.为了对算法进行评测,本文从准确率(Accuracy)、召回率(Recall)及精度(Precision)3个方面进行了评价.在数据集一和数据集二中的测试数据集上得到的结果如图4(a)和(b).由图4可见,在训练阶段,在数据集一和数据集二中的测试数据集上得到的识别准确率为0.9977和0.8346,但在Finetune之后,其识别准确率则分别为1和0.9154.说明Finetune阶段可以有效提升模型对于CME特别是弱CME(数据集二)的识别效果.

(ii) 实验分析. 通过图4(b),我们能看出Finetune以后的模型对于数据集二的识别结果要优于训练得到的模型,而数据集二中有很多的弱CME图像,因此,Finetune以后的模型对于弱CME图像有较大的识别能力,然而,从召回率指标来看,也可以看出Finetune以后的模型在数据集二上对于非CME图像的识别能力下降了一点,但是,从总体上的识别效

果来看,Finetune以后的模型参数显然更加适合CME图像的检测分类任务.

由图4(a)可以看出,在强CME图像居多的数据集一中,Finetune以后的模型参数不比训练以后的模型参数差,甚至略优于训练以后的模型.因此,Finetune以后的模型在提升了对于弱CME图像的识别分类能力的同时,并未降低对于强CME图像的识别分类能力.

综上,Finetune以后的模型在CME图像的检测分类任务中要优于训练以后的模型,所以,在最终的分类测试任务中,本文采用Finetune以后的模型.

4.3 噪声分析

在CME图像视频或者图像拍摄时,有很多的噪声干扰,比如,黑色或者白色的点、明亮的直线段以及行星干扰等.通过本文所训练出来的网络模型,基本可以排除黑色或者白色的点所带来的噪声影响,

图4 (网络版彩色)不同数据集上的测试结果. (a) 在数据集一上的测试结果; (b) 在数据集二上的测试结果

Figure 4 (Color online) Test results on different datasets. (a) Test results on dataset 1; (b) test results on the dataset 2

然而,对于明亮的直线段以及行星的干扰并不能完全排除.图5(a)展示了一些带噪声的正确检测结果,图5(b)展示了部分带噪声的错误检测结果.

4.4 实验结果的比较

本文从两个方面对算法进行评价:执行效率和结果可信度.在CME检测分类任务中,执行效率反映在识别CME图像所需的时间,结果的可信度反映在CME检测的准确率上.因此本文将从CME图像的检测效率和CME检测的准确率两个方面来与其他的CME检测实验结果进行比较.

在CME图像检测效率方面,如表1所示,本文的深度网络模型在一台2.40 GHz的主频和4.00 GB内存大小的Lenovo电脑上,使用CPU处理一幅CME图像大约需要0.6 s,而使用GeForce 940M型号的GPU处

理一幅CME图像大约需要0.06 s;而Qu等人^[7]的实验在一台主频为2.8 GHz、内存为512 MB的DELL Dimension 4600型号的个人电脑上处理3幅LASCO图像大约需要5 s;Berghmans等人^[3]的实验处理一个月的CME图像(大约6400幅图像)需要几个小时.虽然在不同的设备上处理CME图像的时间没有可比性,但是至少仍能说明本文的深度网络模型在处理CME图像的时候是有效的,并且在GPU模式下处理图像的效率更是远远优于其他算法.

在CME检测的准确率方面,由于目前并没有公开的测试标准,所以本文把我们的方法与已经存在的3个CME日志进行比较.3个已经存在的CME日志分别为LASCO、CACTUS以及SEEDS.其中,LASCO的CME日志是人为标记的,而CACTUS和SEEDS的CME日志都是自动检测的结果,因此,本文把LASCO

图5 CME检测结果.(a) 部分带噪声的正确检测结果;(b) 部分带噪声的错误检测结果

Figure 5 Results of CME detection. (a) Some correct results on the images with noises; (b) some wrong results on the images with noises

表1 CME检测效率比较

Table 1 Comparison of CME detection efficiency

	每幅图像处理时间(s)	所用设备
Qu的实验	约1.67	主频为2.8 GHz、内存为512 MB的DELL Dimension 4600
Berghmans的实验	约1.125 (按2 h计算)	
本文算法	约0.6 (CPU处理)	2.40 GHz的主频、4.00 GB内存大小的Lenovo E431
	约0.06 (GPU处理)	

的CME日志作为比较结果的评判标准. 然而, 由于LASCO的CME日志是人为标记的, 所以也是存在一些错标或者是漏标的CME. 因此, 本文只是把LASCO的CME日志作为一个参考的评判标准, 从而能够更好地比较我们与CACTUS, SEEDS的CME日志. 本文采用的CME日志为2007年05月份的检测结果, 以此CME日志与CACTUS, SEEDS进行比较.

为了能够更加清晰地看到本文的比较结果, 本文从3个方面来进行比较: 第一, 不同强度的CME具有不同的影响力, 强度越大, 影响力越大. 根据LASCO的官方CME日志, CME事件大致被标注为弱CME事件、非常弱CME事件和没有标记的CME事件. 为了方便下文的叙述, 本文把LASCO官方CME日志中未标注的事件命名为普通CME事件. 由此可以看出, 普通CME事件的检测显得更为重要, 所以, 本文首先比较的是检测出的普通CME事件的数量; 第二, 比较检测出的正确的CME事件的数量; 第三, 检测出的总的CME数量, 由于该值能够直接反映太阳活动, 因此, 本文比较我们及其他3个已存在的CME日志中检测出来的总的CME事件的数量.

另外, 需要说明的是, 由于CME事件是一个连续的事件, 因此, 本文从CME事件开始时间以及持续帧两个因素来衡量我们的检测结果, 其中, 事件开始时间在LASCO的CME日志中给出的开始时间前后各一帧都被认为是正确的检测结果.

图6为比较的结果, 从中我们可以看出: 第一, LASCO的CME日志中总共标记出了26个普通CME事件, 我们的CME日志中检测出来了其中的24个, 而CACTUS和SEEDS的CME日志分别检测出了11个和16个; 第二, 在LASCO的CME日志中标记出来的所有CME事件中, 我们的模型检测出了105个, 而CACTUS和SEEDS分别检测出了12个和23个; 第三, LASCO, CACTUS和SEEDS的CME日志分别总共检测出了137, 30和59个CME事件, 而我们的CME日志中总共检测出了181个CME事件. 从前两个方面可以看出, 在以LASCO的CME日志为标准的时候, 本文的实验检测出来的普通CME事件和所有正确的CME事件都是最多的, 而在比较所有的CME日志检测出来的所有CME事件的数量时, 本文的实验仍然

图6 (网络版彩色)不同CME日志的比较

Figure 6 (Color online) Comparisons with different catalogs

具有相当的优势.

本文的CME日志被公开在http://blog.csdn.net/baidu_23114165/article/details/50939319, 其中详细描述了本文的CME日志, 有关细节可供参考.

5 结论及展望

为了克服传统的CME检测方法的缺陷: 人为地提取CME特征或是界定CME分割的阈值, 都难以找到合适的图像特征来描述CME现象. 因此, 本文提出了一种端到端的新的CME检测方法, 用卷积神经网络自主提取特征进行参数学习, 设计了由4个卷积层、1个全连接层和1个输出层的网络结构, 采用先在强CME图像数据集上学习参数、然后针对弱CME图像数据进行微调的调参策略, 训练出一个适合本文分类任务的深度神经网络模型, 并且在强CME图像数据集中取得了接近100%的分类正确率, 在弱CME图像数据集上取得了91.54%的分类准确率, 在所有数据集中的识别率达到了98.05%. 最后, 以2007年05月的真实数据为例, 进行了CME的检测, 以LASCO检测结果为基准, 检测结果表明, 本文方法可以得到很好的检测结果.

本文工作在两个方面具有重要的意义. 首先, 本方法由于采用端到端的处理方法, 自动选择特征, 得到了良好的检测效果, 其自动选择出的特征有可能揭示哪些特征对于CME的检测来说是重要的; 另外, CNN对于CME检测的成功应用说明CNN具有良好的CME描述能力, 因此, 基于CNN对于CME的量化描述同样有可能得到非常好的结果, 从而为CME的动态演化建模提供重要基础. 这也是我们在以后研究中将要重点研究的两个重要问题.

参考文献

- 1 Hundhausen A J. Sizes and locations of coronal mass ejections: SMM observations from 1980 and 1984-1989. *J Geophys Res Space Phys*, 1993, 98:13177-13200
- 2 Robbrecht E, Berghmans D. A broad perspective on automated CME tracking: Towards higher level space weather forecasting. *AGU Geophys Monogr Ser*, 2006, 165: 33-41
- 3 Berghmans D, Foing B H, Fleck B. Automated detection of CMEs in LASCO data. In: *Proceedings of The SOHO-11 Workshop, From Solar Min to Max: Half a Solar Cycle with SOHO*. Noordwijk: ESA Publications, 2002. 437-440
- 4 Robbrecht E, Berghmans D. Automated recognition of coronal mass ejections (CMEs) in near-real-time data. *Astron Astrophys*, 2004, 425: 1097-1106
- 5 Boursier Y, Lamy P, Llebaria A, et al. The ARTEMIS catalog of LASCO coronal mass ejections Automatic recognition of transient events and Marseille inventory from synoptic maps. *Solar Phys*, 2009, 257: 125-147
- 6 Floyd O, Lamy P, Boursier Y, et al. ARTEMIS II: A second generation catalog of LASCO coronal mass ejections including mass and kinetic energy. *Solar Phys*, 2013, 288: 269-289
- 7 Qu M, Frank Y S. Automatic detection and classification of coronal mass ejections. *Solar Phys*, 2006, 237: 419-431
- 8 Olmedo O, Zhang J, Wechsler H, et al. Automatic detection and tracking of coronal mass ejections in coronagraph time series. *Solar Phys*, 2008, 248: 485-499
- 9 Pulkkinen A, Oates T, Taktakishvili A. Automatic determination of the conic coronal mass ejection model parameters. *Solar Phys*, 2010, 261: 115-126
- 10 Gonzalez-Gomez D, Blanco-Cano X, Raga A C. CME classification based on wavelet spectra. *Solar Phys*, 2010, 266: 337-347
- 11 Gallagher P T, Young C A, Byrne J P, et al. Coronal mass ejection detection using wavelets, curvelets and ridgelets: Applications for space weather monitoring. *Adv Space Res*, 2011, 47: 2118-2126
- 12 Goussies N, Stenborg G, Vourlidis A, et al. Tracking of coronal white-light events by texture. *Solar Phys*, 2010, 262: 481-494
- 13 Zeng Z X, Liu Y, Wei Y L. Detecting coronal mass ejection method by analyzing spectrum change (in Chinese). *J Huazhong Univ Sci Technol (Nat Sci Ed)*, 2012, 40: 379-383 [曾昭宪, 刘毅, 魏雅利. 基于频谱突变分析的日冕物质抛射识别方法. *华中科技大学学报 (自然科学版)*, 2012, 40: 379-383]
- 14 Hagan M T, Demuth H B, Beale M. *Neural Network Design*. Beijing: China Machine Press, 2002. 357
- 15 Ouyang W, Wang X, Zeng X, et al. DeepID-Net: Deformable deep convolutional neural networks for object detection. *Dev Med Child Neurol*, 2015, 46: 358-360.
- 16 Kim Y, Kim Y. Convolutional neural networks for sentence classification. 2014, arXiv: 1408.5882
- 17 Karpathy A, Toderici G, Shetty S, et al. Large-scale video classification with convolutional neural networks. In: *Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. New York: IEEE, 2014. 1725-1732
- 18 Feng H J, Tao S J, Li L. Double linear inserting algorithm based image zooming and its realization (in Chinese). *Comput Appl Softw*, 2004, 21: 117-119 [冯慧君, 陶素娟, 李隆. 基于双线性插值算法的图像放缩技术与实现. *计算机应用与软件*, 2004, 21: 117-119]
- 19 Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks. *J Mach Learn Res*, 2015, 9: 249-256
- 20 Qian N. On the momentum term in gradient descent learning algorithms. *Neural Net*, 1999, 12: 145-151

Summary for “一种端到端的日冕物质现象检测新方法”

An end-to-end method of Coronal Mass Ejections detection

YAO Hai¹, YIN JianQin^{1,2*}, LIN JiaBen³, ZHANG Ling¹ & WANG XiaoFan³

¹ Shandong Provincial Key Laboratory of Network Based Intelligent Computing, School of Information Science and Engineering, University of Jinan, Jinan 250022, China;

² School of Automation, Beijing University of Posts and Telecommunications, Beijing 100876, China;

³ Key Laboratory of Solar Activity, Chinese Academy of Sciences, Beijing 100012, China

* Corresponding author, E-mail: ise_yinq@ujn.edu.cn

Coronal Mass Ejections (CMEs) impact heavily on coronal activity, space weather and many interplanetary disturbance, so the detection of CMEs are important for space weather disaster prevention and reduction. The traditional methods use man-made features or predefined threshold to solve this problem. Despite the great progress in the detection of CMEs, it is still a challenging problem due to the following three aspects: Firstly, the early and late stage of the CMEs phenomenon is very weak, and the traditional image processing based method can not detect this weak CMEs well. Secondly, the noises from comet, planets and other stars can affect the detection of CMEs. Thirdly, the CMEs are complex and amorphous, and they are different in shapes, textures, grayscales, scales and so on. Because of these difficulties, it is difficult to detect CMEs well by the traditional image processing method without modeling the CMEs. With the development of convolutional neural networks (CNNs), it is possible to develop deep neural networks based CMEs detection models to better solve this problem. For realizing this, this paper presents an end-to-end detection method of Coronal Mass Ejections detection: We design a deep neural network with 4 convolution layers, 1 full connection layer and 1 output layer. This deep neural network can automatically extract the image features that are suitable to describe the Coronal Mass Ejections, and can establish the CMEs detection model based on the extracted features. In order to achieve good performance, we construct two datasets, one is mainly made up of strong CMEs, and the other is made up of weak or dark CMEs. Training is first done on the strong CMEs to obtain the initial CMEs detection model. Based on the initial model established on the strong CMEs, finetuning is used on the weak CMEs to acquire the final CMEs detection model. By using this scheme, training efficiency and good performance can be guaranteed. In addition, the process is able to achieve selection of features and setting of classification rules, which can realize conveniently the end-to-end detection from data to results. The experimental results show that this method can effectively detect CMEs. The accuracy of our method is 100% on the strong CME dataset, and 91.54% on the weak CME dataset. The overall accuracy on our dataset is 98.05%. Finally, we test our method with the real data on May 2007 using LASCO catalog as the groundtruth. Experimental results show that our method achieves state-of-the-art performance comparing with the usually used catalog, SEEDS, CACTUS. The significance of our work is two-fold. On one hand, our method is end-to-end method which can select optimal features for the detection task. According to the theory of deep neural networks, the selected features are usually those that the human vision uses. Therefore, the obtained features can depicts CMEs well and can be used by other methods. On the other hand, the good performance of our method proves the depiction ability of the CNN for CME. So it is natural that CNN based description for the CME can also have good performance for the study of the modeling of the evolution of the CMEs.

CMEs detection, solar activity, convolutional neural network

doi: 10.1360/N972016-00382