

文献阅读报告 4 (应用层)

一、文献信息

1、论文题目:

Make Thunderbolts Less Frightening — Predicting Extreme Weather Using Deep Learning

2、作者:

Christian Schön

Big Data Analytics Group Saarland Informatics Campus bigdata.uni-saarland.de

Jens Dittrich

Big Data Analytics Group Saarland Informatics Campus bigdata.uni-saarland.de

3、发表途径:

NeurIPS 2019 Workshop Tackling Climate Change with Machine Learning

https://www.climatechange.ai/NeurIPS2019_workshop.html

4、发表时间:

2019 年 12 月

二、问题意义

1、论文研究的问题

由于大量数据和基础物理的复杂性,预测恶劣的天气条件仍然是一项非常具有挑战性和计算成本高昂的任务。然而,近年来,机器学习方法尤其是深度学习在处理大型数据集的许多研究领域都显示出巨大的改进。在这篇文章中作者处理一个了特定的天气预报的子问题,即雷暴和闪电的预报。

2、研究背景

气候变化将在许多方面影响人类。在航空等领域,如果飞机没有得到及时的警告和绕行,雷雨可能会对安全构成真正的威胁。因此,预测如此恶劣的天气状况是气象部门的核心任务。然而,即使是最先进的系统,如由德国气象局运行的 NowCastMIX 系统,仍然难以达到较高的虚警率,特别是当预报期增加到一小时或更长的時候。目前运行模式下的大多数天气模型都是基于数值天气预报(NWP)的,并通过应用物理规律的转换来估计大气状态。然而,机器学习算法最近在许多领域取得了成功,特别是那些为训练提供大数据集的计算。地球静止卫星、闪电探测网络的可用性等数据来源鼓励研究人员研究机器学习在恶劣天气预测中的应用。

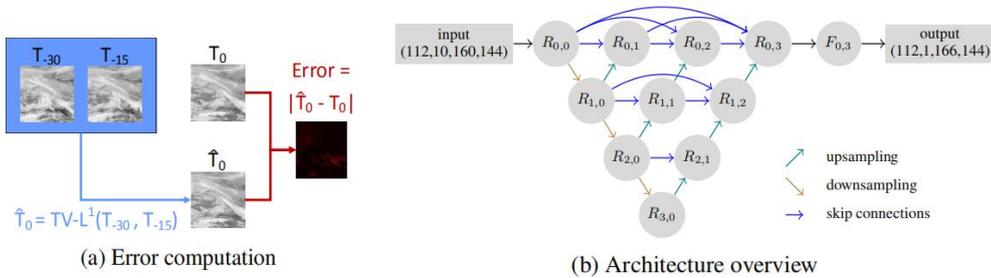
3、研究意义

提出了一种基于 UNet++和 ResNet 的卷积神经网络结构,将雷暴作为一个基于过去记录的卫星图像和闪电记录的二元分类问题进行预测。在接下来的 15 分钟内,实现了超过 94% 的闪电探测概率,同时与以前的方法相比,最大限度地降低了虚警率。

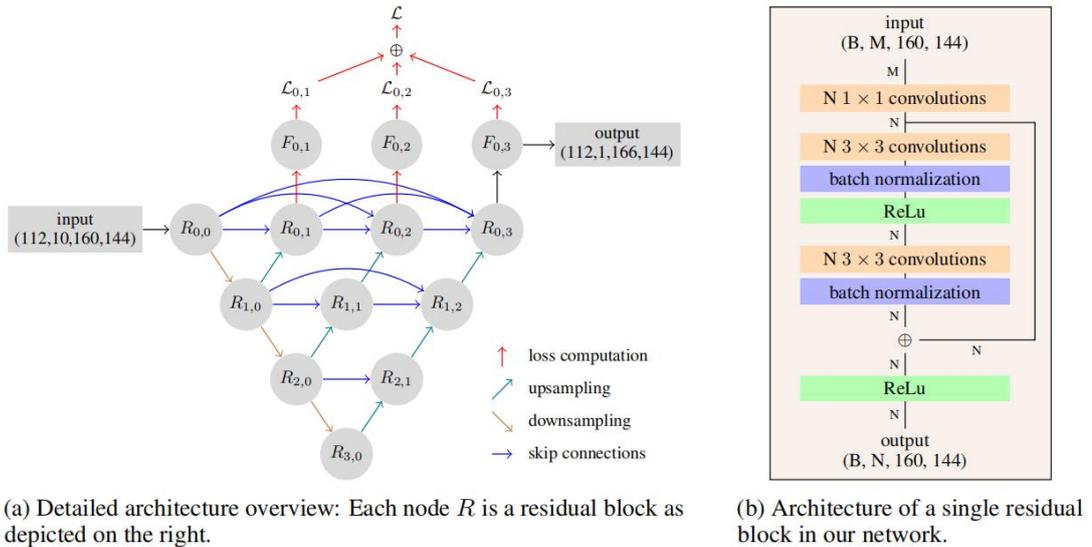
三、思路方法

由于这篇文章的主要方法是基于卫星图像,所以让卷积神经网络成为了网络的自然选择,它能够更好地区分图像,该项研究的目的是试图区分受雷暴影响的区域和没有受雷暴影响的区域,是一个与图像分割的思想密切相关的工作。思考过去提出的各种各种架构,全卷积网络(FCN)和 UNet 是引入连接思想的最成功的和最有影响力的网络之一。本文也是对于基础网络进行了启发扩展,在 UNet 中引入了残差学习的思想,并且有自己的细节。文章采

用了卫星图像当前预报出产生的误差作为基于随机森林算法的闪电预测特征，进行了预处理的工作，如下图 a：将光流算法应用于两个连续的卫星图像 T-30 和 T-15，并取 T0 时的原始图像的绝对差，计算误差。闪电的数据以相同的时间和分辨率积累在地图上。这个系统的输入时图像，因此也就省略了将数据分割成单个分块并应用手动卷积的步骤。特别注意的是，本文中的一个特点是将上次的闪电观测作为之前的研究者没有考虑的特征加进去，这样就生成了下图 b 所示的十个特征通道。



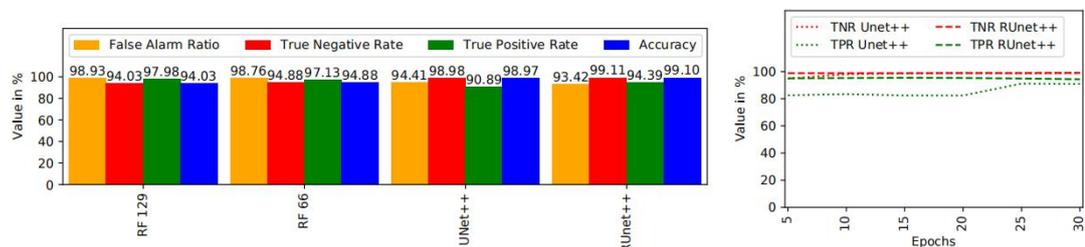
在收集数据的时候每幅 1114*956 大小的原始图像被分割成 56 个 160*144 大小的样本，而且在交叉验证实验中，为了避免与训练数据的交叉相关效应，将整个数据范围分成了四个测试集。在上图 b 中，每个节点都是单个残差块，其多个输入的张量可以直接连接起来。其（本文设计的 UNet）内部架构与原始的 UNet 很相似，不同的是使用了包括本地跳过连接的残差块作为网络的基本构建块，如下图：



其中主要的参数是 (B, C, W, H)，B 表示批量大小，C 表示特征通道数，W 和 H 分别是图像的宽度和高度。整个系统的输入从第一节点 R0, 0 进入，并从 F0, 3 输出。图中每个向下的箭头表示一个降采样步骤，将图像的宽度和高度分成两半，同时将残差块的宽度加倍，向上的箭头表示相反的操作，也就是双线性上采样。深度为零的残差块如 R0, 0 到 R0, 3，他们的宽度是 16，随着深度增加，R3, 0 的宽度为 128，如果一个残差块有两条输入边，我们只需要在图 b 的第一层之前将其连接到一块即可，网络的最后一层也就是 F0, 1 到 F0, 3 是一个卷积层，它可以返回一个单一特征映射，再经过 sigmoid 函数之后与我们期望的目标值进行比较。上面的 L 节点则是监督节点，用于总结损失。

通过上述网络架构的训练之后主要的评价指标是真阳性率 (TPR)、真阴性率 (TNR)、准确度和虚警率 (FAR)，结果表明与随机林相比，UNet++和 RUNet++总体上获得了相似的

性能。然而，在直接比较中，它们倾向于更好地预测负类，从而导致更低的远距，这在很大程度上取决于在这样一个极不平衡的数据集中假阳性的数量。在不牺牲太多 TPR 的情况下减少 FAR 对于操作使用是至关重要的。将标准的 UNet++体系结构与我们修改的 RUNet++版本进行比较，可以得出我们的模型在 TPR 方面比标准体系结构的性能提高了 3.5%。而且 RUNet++ 的收敛速度要快很多，可以以进行更快的训练。



(a) False Alarm Ratio, True Negative Rate, True Positive Rate and Accuracy per model (b) True Positive Rate and True Negative Rate per epoch

四、实验结论

与以往的闪电预报工作相比，文中的方法有很好的效果，在准确率和虚警率方面，由于底层数据集的原因比较困难，但是也没有使用计算昂贵的 NWP 模型，并且可以得出与前面的研究者类似的结果，这也只是一个初步研究，今后在残差块的损失计算中，也可以通过增加负数类的权重，将较高的虚警率降到最低，从而导致较少的误报，但也会导致对闪电的检测更差。

五、启发思考

首先是本文采用卫星图像分析，将两个连续的卫星图像采用光流法计算，利用图像序列中像素在时间域上的变化以及相邻帧之间的相关性来找到上一帧跟当前帧之间存在的对应关系，从而计算出相邻帧之间物体的运动信息，我认为这能够动态地捕捉到图像的特征，抓住了判断的依据。然后作者选取了卷积神经网络，而不是直接用前面研究者使用的随机森林，这样就消除了额外预处理的步骤，因为卷积神经网络具有直接处理图像切片而不是单个像素值的优点。将整个图像整体化，使得图像之间的联系更加丰富。进一步，作者在传统标准的 UNet++架构中采用了残差块且修改了一些部分，使得收敛速度快了很多，可以进行更快地训练，并且其性能也得到了提高，让 UNet++体系更好地为所研究的课题服务。最后，采用了四种不同的指标评估文中采用的方法，也体现了科学严谨性。