

Research
Geodesy and Survey Engineering—Article

基于人工智能技术的无人机遥感探测具有感染松材线虫病特征的树木

Mutiara Syifa, Sung-Jae Park, Chang-Wook Lee*

Division of Science Education, Kangwon National University, Gangwon-do 24341, Republic of Korea

ARTICLE INFO

Article history:

Received 20 October 2018

Revised 4 March 2020

Accepted 30 June 2020

Available online 7 July 2020

关键词

松材线虫病
无人机遥感
人工神经网络
支持向量机
全球定位系统

摘要

最近, 松材线虫病 (PWD) 导致韩国大量的松树受损。鉴于松树对于韩国人的重要性, PWD 被视为一个严重的问题, 因此必须妥善处理。我们此前调查了 PWD 的发展历史, 发现其已扩散到韩国的一些地区, 我们将这些地区作为研究区域。对 PWD 进行早期检测是十分必要的。我们利用无人机遥感技术来探测具有与感染 PWD 的树木相似症状的树木。之所以使用无人机遥感, 是因为它能够生成高质量的图像, 并且可以很容易地到达松树的位置。为了区分健康的和感染了 PWD 的松树, 我们利用从 Anbi 和 Wonchang 两个村采集到的无人机图像制作了一份土地覆盖 (LC) 图, 并使用两种方法将它们分类, 即人工神经网络 (ANN) 和支持向量机 (SVM)。此外, 比较了使用无人机和手持设备采集的两类全球定位系统 (GPS) 数据的定位精度, 以确定感染 PWD 的树木的位置。随后, 我们将每个研究区域的无人机图像分成 6 个 LC 类, 发现 SVM 在区分是否感染 PWD 的树木时比 ANN 更准确。在 Anbi 村, SVM 的总体精度为 94.13%, 与 ANN 总体精度 87.43% 相比, 高出了 6.7%。在 Wonchang 村, 我们也得到了相似的结果, SVM 和 ANN 的精度分别为 86.59% 和 79.33%。在 GPS 数据方面, 我们使用了两种手持 GPS 设备。GPS 设备 1 参照两个位置的基准点进行校正, GPS 设备 2 为未校正设备, 仅使用 GPS 的默认设置。在 Wonchang 村, 手持 GPS 设备 1 采集的数据定位结果优于手持 GPS 设备 2。然而, 在 Anbi 村, GPS 设备 2 获得的定位结果优于 GPS 设备 1——GPS 设备 1 的定位误差为 7.08 m, 而 GPS 设备 2 的定位误差为 0.14 m。总的来说, 这两种分类器都能根据 LC 数据辨别健康树木和感染 PWD 的树木。LC 数据也可以用于其他类型的分类。这两个区域的手持 GPS 数据集和无人机 GPS 数据集存在一些差异。

© 2020 THE AUTHORS. Published by Elsevier LTD on behalf of Chinese Academy of Engineering and Higher Education Press Limited Company This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. 引言

无论是在文化还是精神方面, 松树对韩国都是至关重要的[1]。韩国有广阔的松树林 (*P. desiflora* 和 *P. thunbergii*), 总面积为 1 507 118 hm², 占森林总面积的 23.5% [2,3]。1980 年, 在韩国釜山首次出现了松材线虫病 (PWD)。PWD 造成了严重的损失, 并给韩国松树林带来严重威胁[1]。目前, 受灾地区面积达 7820 hm², 涉及韩国 60 多个城市[4]。PWD 是由一种线虫——松材线

虫——引起的, 通过名为松天牛 (墨天牛属) 的昆虫媒介传播。该病媒感染树木的时间为每年的 6 月初至 7 月下旬, 这是成年松天牛的成熟期[4,5]。

PWD 起源于北美洲[6–8], 首先传播到日本, 在那里造成了长达 100 年的严重问题[8–9], 然后在过去几十年里传到了中国[10]和韩国[1,4]。PWD 的传播与环境因素紧密相关, 如温度和土壤含水量[11]。松材线虫 (PWN) 攻击松树, 大多数树木会在感染后 3 个月内死亡[1,12,13]。由于烟熏、焚烧和砍伐树木是目前仅有的

* Corresponding author.

E-mail address: cwlee@kangwon.ac.kr (C.-W. Lee).

控制PWD蔓延的方法，因此需要妥善地处理这一问题，如早期检测[1,14]。

无人机遥感被认为有助于解决这个问题。其灵活度高，成本低，而且无人机平台可以配备高分辨率的遥感系统[15]。无人机或无人驾驶飞行器（UAV）图像被广泛应用于解决林业和农业[15–17]、城市植被[18]，甚至地震[19,20]、滑坡[21–23]、火山爆发[24,25]等灾害中的问题。在对PWD进行早期检测时，叶子在秋天前变为褐色的松树被归为PWD表征树。由于松树通常在山上，在野外研究中很难识别受感染的松树，因此无人机遥感是非常适用的。森林的地形特征也使得直接进入森林非常具有挑战性。此外，由于是从下方观测，因此肉眼并不总能识别出感染了PWD的松树。

在获得无人机图像后，我们使用监督分类法来确定感染PWD的树木的位置。人工神经网络（ANN）和支持向量机（SVM）是两类应用广泛的分类器，其分类精度已有研究验证[26,27]。在本研究中，我们用ANN和SVM分类器来识别具有感染PWD特征的树木。

下一步是基于ANN和SVM的分类结果，使用误差矩阵来评估其精度。确定分类器的精度非常重要，以便于我们评估其针对特定目标的有效性。这可以使投保人、评估者和其他利益相关者，在林业研究人员证明这些树木确实感染了PWD线虫后，能够容易地识别和处理这些树木。

另外，除了使用无人机全球定位系统（GPS）的数据外，我们还使用了两种手持GPS设备来采集实地数据，并分析了使用无人机和手持GPS设备获得的结果的差异。即便数据是从同一地点采集，结果还是有差别。为了了解误差的大致情况，就必须了解手持GPS设备和无人机GPS设备得到的结果之间的差异。综上所述，本研究的目的是找出最有效的分类器来检测PWD表征树，并阐明从手持GPS设备和无人机GPS设备采集的结果之间的差异。

2. 材料与方法

2.1. 材料

高清晰度无人机图像（大疆精灵4 V 1.0，中国大疆）和两个手持GPS设备（佳明Oregon 750 T，瑞士佳明）的GPS数据被用来采集研究区域的数据。我们主要关注两个区域，即位于韩国江原道省春川市的Anbi村和Wonchang村，这两个区域分别处于 $37^{\circ} 50'16.08''N$ 、

$127^{\circ} 34'59.88''E$ 和 $37^{\circ} 48'21.24''N$ 、 $127^{\circ} 46'30.36''E$ 。选择这两个地方是因为它们以前有过PWD的记录，所以我们假设仍然存在一些PWN，即使专家已经根除了这些地区的PWN疾病。Wonchang村和Anbi村的研究区域如图1（a）所示。

Anbi村和Wonchang村的无人机图像分别采集于2018年9月16日和2018年9月23日。这两个地区的GPS数据采集于2018年10月5日。在识别PWD表征树之前，通过Wonchang村的一个基准点可以校准GPS设备1的结果[图1（b）和（c）]。基准点又称测绘标志，是一个在地球表面进行关键测量并显示海拔高度的定点对象。GPS设备2采用默认设置，被称为未校正的GPS。Anbi村只有一棵PWD表征树，而Wonchang村有两棵。在本研究中，我们使用Agisoft Photoscan Professional软件对无人机图像进行处理，使用BaseCamp 4.7.0版对GPS数

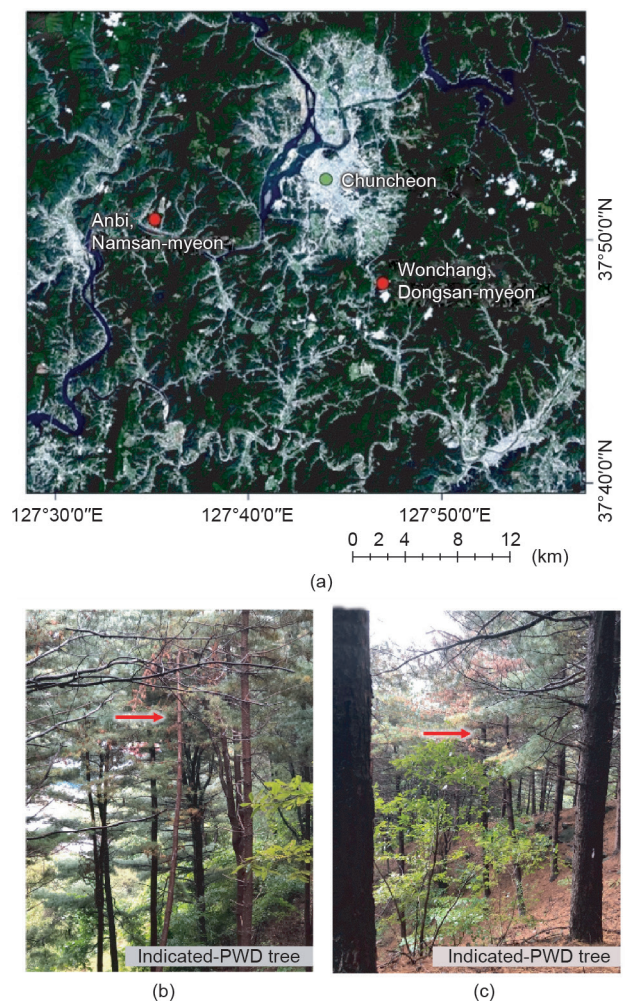


图1. (a) 研究区域，即位于韩国春川市的Wonchang村和Anbi村，如地球资源卫星8号图像所示；在Wonchang村有两棵PWD表征树，本图展示了第一棵PWD表征树（b）和第二棵PWD表征树（c）。

表1 Wonchang村和Anbi村的LC分类及定义

Class number	Class name in Wonchang	Class name in Anbi	Class definition
1	PWD-indicated tree	PWD-indicated tree	Pine tree assumed to be infected by PWD
2	Normal pine tree	Normal pine tree	Pine tree that looks green and healthy
3	Grass and trees	Grass and trees	Grass and other trees species (not pine tree)
4	Road	Road	Road areas
5	Shadow	Shadow	Shadowed areas
6	Bare land	—	Area/land that is not covered by anything
7	—	Building	Houses or building areas

据进行处理, 以及使用ArcMap 10.4和ENVI Classic 5.3对分类器进行分类和精度评估。为了对图像进行分类, 我们将Anbi村分为13个土地覆盖(LC)类, Wonchang村分为9个LC类, 以便将PWD表征树与其他类型的LC(如普通松树、草地、其他树种、裸地、道路和建筑物)区分开来。然而, 某些类型的LC, 如裸地, 由于颜色相似而被归类为PWD。因此, 对研究区域内的无人机图像进行分析是一项具有挑战性的工作。Wonchang村和Anbi村的分类方案和类别定义见表1。

2.2. 方法

在对研究区域的PWD表征树绘图时, 我们使用了两种人工智能(AI)技术: ANN和SVM分类器。Yuan等[16]利用ANN和SVM对大豆植株的叶面积指数(LAI)进行了高精度的估计。因此, 我们使用误差矩阵法计算了这两个分类器的精度, 并评估了ANN和SVM的分类结果。误差矩阵法评估了总体精度、kappa系数、生产者精度和用户精度。除了评估这两种分类器的精度, 我们还比较了来自两个研究地区的无人机GPS结果和手持GPS结果。为了评估这些差异, 我们将使用无人机识别的每个PWD表征树的中心点与来自手持GPS设备的结果进行了比较。我们将研究方法分为4个阶段: 无人机图像采集、图像分类、精度评估以及分类结果与GPS结果的比较, 如图2所示。

2.2.1. 人工神经网络

ANN是一种数学框架, 旨在通过一个加强输入和输出数据之间联系的并行过程来模拟人类的学习过程[28,29]。神经网络最常见的实现方式之一是前馈网络(FFN), 这也是我们在本研究中使用的。这是一个非参数非线性模型, 由输入层、隐含层和输出层[30]组成。所有的ANN都有特定数量的节点, 这些节点在后面的层级中以特定的权重和偏差相互连接。FFN可定义为:

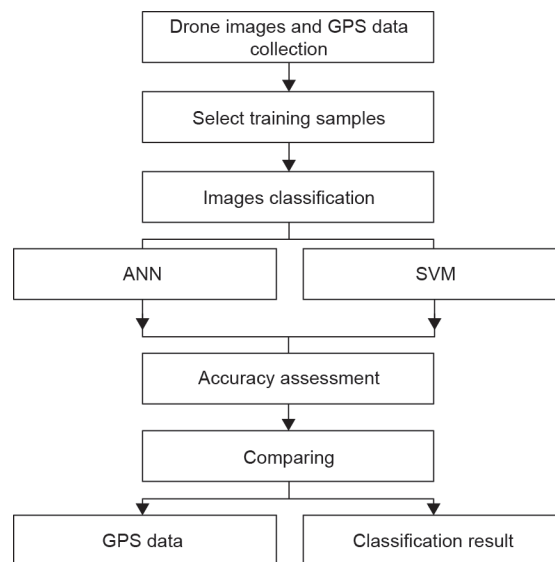


图2. 本研究中用于确定ANN和SVM分类器精度的方法流程图, 并比较无人机全球定位系统(GPS)数据和两个手持GPS设备的数据。

$$x_j = f\left(\sum_{i=1}^n w_{ij}x_i + b_j\right)$$

式中, 下标*i*和*j*分别表示上一层和当前层; *x*为节点值; *b*和*w*分别为偏差值和权重值; *n*是上一层的节点数; *f*表示当前层的转移函数。输出层为线性函数, 隐含层为S型对数函数。这种组合被认为可以有效增强ANN的外推能力[29,31]。为了使输入和输出数据之间的误差最小化, 我们使用了一种反向传播算法(BPA)来训练ANN。

因此, 输入和输出通过网络被反复地馈送, 并且误差从输出层传至输入层[32]。ANN模型中最关键的参数是神经元的数量; 使用更多的神经元可以获得更高的学习精度, 但会削弱ANN[28]的普适性。在本研究中, 我们的工作以Kavzoglu的网络架构和训练模式[33]为基础。我们使用ENVI Classic 5.3来训练ANN。采用logistic激励函数, 将训练阈值贡献和动量设置为0.9, 将速率场、均方根(RMS)退出阈值和训练迭代次数分别设

置为0.2、0.1和100。

2.2.2. 支持向量机

SVM是一种基于统计学理论的机器学习方法。SVM最初由Cortes和Vapnik [34]提出,是一种基于结构风险最小化(SRM)的非参数算法,而不是ANN采用的经验风险最小化(ERM)算法。ERM旨在最小化分类器使用的训练数据中的误差,而SRM旨在最大化待分类数据组之间的边距,从而最大化模型的普适性[35]。在实施SVM时,必须使用合适的、能够反映数据点之间相似性的核函数[36]。鉴于径向基函数(RBF)核在非线性分类算法中的优良性能,因此我们采用了该核函数[37,38]。在本研究中,为了生成尽可能精确的模型,我们将惩罚参数和 γ 分别设为100和0.5。

3. 结果

利用ENVI Classic 5.3中实现的ANN和SVM分类器对从两个研究区域采集的无人机图像进行分类。除了无人机图像数据外,我们还采集了GPS数据,以便能够评估从无人机和手持GPS设备采集的GPS数据之间的差异。Wonchang村的图像被分为6类:感染PWD的树木、正常的松树、草木、道路、阴影和裸地。而在Anbi村,我们使用了以下类别:感染PWD的树木、正常的松树、草木、建筑物、道路和阴影。采用逐像素分层抽样的方法对分类精度进行评估。从无人机图像中随机选择每类中的像素点并将其作为参考点,然后将这些参考点与SVM和ANN分类器在这两个区域的结果进行比较。

我们使用Microsoft Excel计算矩阵,并评估总体精度、kappa系数、生产者精度和用户精度,以便对两个参考误差矩阵进行比较。kappa系数是一种离散的多元技术,常用于测量精度[39]。将kappa系数理解为一种整体判断,在排除偶然性协议[40]后达成一致。因此,我们计算了从ANN和SVM分类结果中得到的每个误差矩阵的kappa统计量,以确定哪种分类器产生的结果最好。

3.1. Anbi 村的土地分类结果

从Anbi村采集的无人机图像是从13个基础类别中合并而来的,且被分为6类。这13个类别是根据图像中物体的不同颜色划分的,如有许多屋顶颜色的建筑物。因此,将图像划分为13类能够使算法更容易对图像进

行分类。在获得分类结果后,我们合并了几个代表同一对象的不同颜色的类。由此产生的6个类别如下:感染PWD的树木、正常的松树、草和其他树种、建筑物、道路和阴影,如图3所示。为了对图像进行分类,我们为每组训练了5个颜色相似的多边形。我们总共使用了65个样本来生成LC图。在这种情况下,与ANN [图3 (b)]相比,SVM [图3 (a)]能更好地辨别出感染PWD的树木。图3 (c)展示了图像的某些部分,显示了与感染PWD的树木颜色相似的建筑物和道路等项目。ANN分类器和SVM分类器都将这些项目分类为具有与感染PWD的树木相同的颜色,但SVM识别树木的效果更好。

3.2. Anbi 村分类的精度评估

在表2和表3中,我们总结了基于ANN和SVM算法的PWD分类结果的误差矩阵。这两种方法都是基于对358个像素,即来自感染PWD的树木的59个像素、正常的松树的60个像素、草木的60个像素、建筑物的60个像素、道路的59个像素和阴影的60个像素的分析。所有样本数据均基于多项式概率理论和分层随机抽样。SVM的总体精度为94.13%,而ANN的总体精度为87.43%。SVM分类器的精度更高,表明它比ANN更准确。这一结论得到了两种结果的kappa系数的支持:SVM的kappa系数为0.9296或92.96%,而ANN的kappa系数为0.8492或84.92%。

3.3. Wonchang 村的土地分类结果

最初,我们根据一些具有不同颜色的对象将从Wonchang村采集的无人机图像分为9类,然后通过合并相同对象的类,将结果简化为6类。如图4 (a)和 (b)所示,使用SVM和ANN生成的Wonchang村的土地分类图有6个类别。而图4 (c)显示的无人机图像中的类是根据其相似性划分的,其中植被有许多不同的类型和颜色,包括可以被分成一类的灌木、草和树种。然而,为了使分类器能够快速区分各个类别,我们使用SVM和ANN对9个类别进行了分类。

与Anbi村的情况一样,我们根据这些类的相似性将SVM和ANN的类别进行合并。例如,草、灌木和树木被合并成一个类。总的来说,这两种分类器产生的分类结果都可以区分感染PWD的树木,但如图4 (a)和 (b)所示,SVM分类器的结果优于ANN分类器。在Wonchang村,SVM在对一些区域进行划分的时候出现

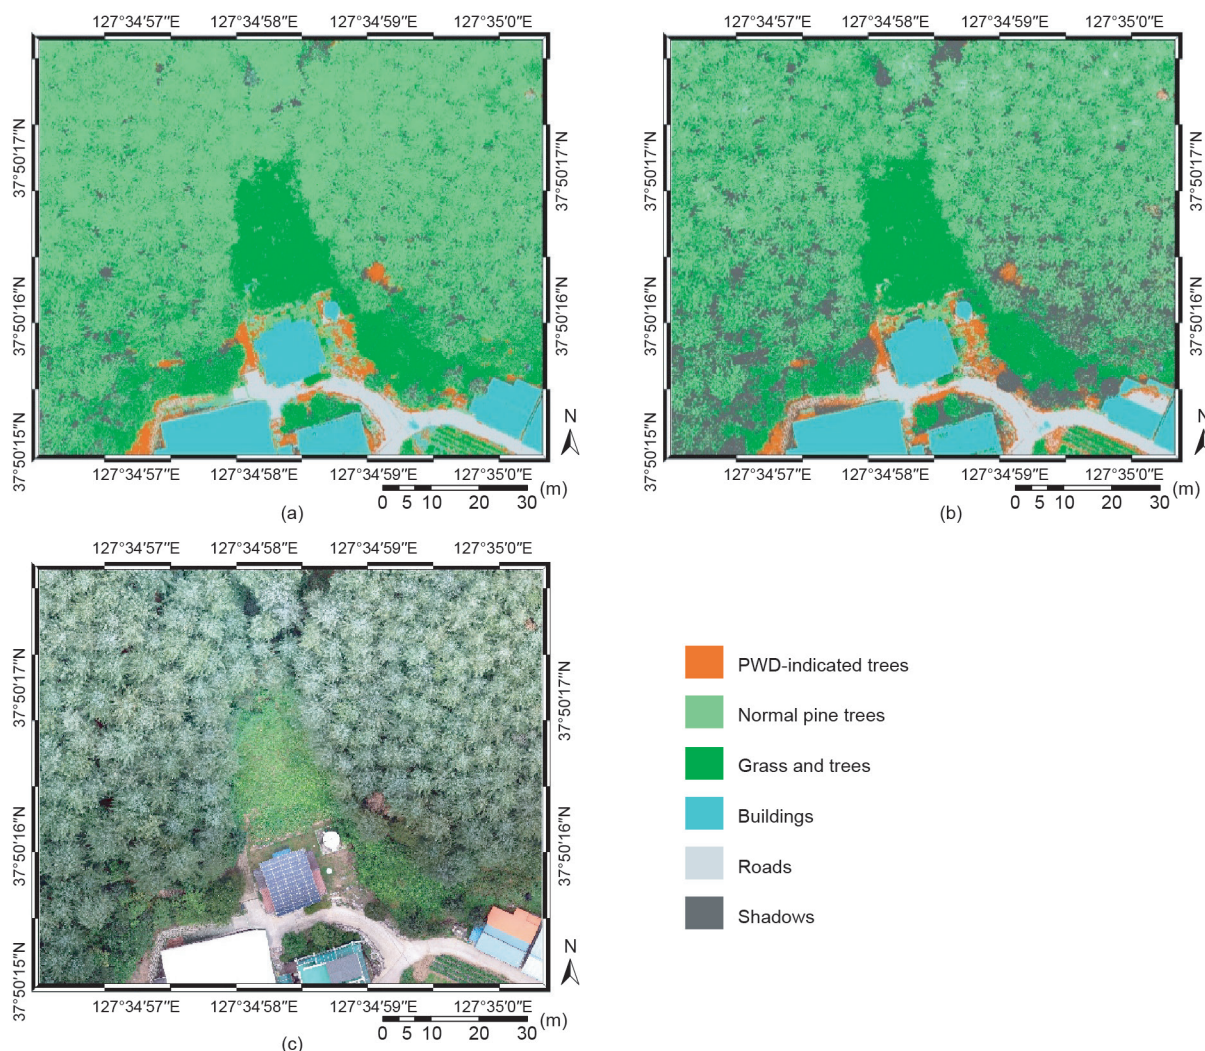


图3. 使用SVM分类器(a)和ANN分类器(b)从无人机图像数据(c)中生成的Anbi村的土地分类图。图像中的元素可分为6类：感染PWD的树木(橙色)、正常的松树(浅绿色)、草木(绿色)、建筑物(蓝色)、道路(浅灰色)和阴影(灰色)。

表2 利用ANN对Anbi村进行分类得到的误差矩阵

Class	PWD	Normal pine trees	Grass and trees	Buildings	Roads	Shadows	Class total
PWD-indicated trees	51	0	0	6	4	0	61
Normal pine trees	0	46	7	0	0	0	53
Grass and trees	0	9	51	0	0	1	61
Buildings	6	0	0	53	2	0	61
Roads	1	4	0	1	53	0	59
Shadows	1	1	2	0	0	59	63
References total	59	60	60	60	59	60	358

了错误，但数量要少于ANN。由于秋季的到来，一些裸地和其他树种的颜色与感染PWD的树木的颜色相似，使得ANN将别的区域也归类为感染了PWD的树木。

3.4. Wonchang 村分类的精度评估

我们使用358个样本像素，即来自感染PWD的树

木的59个像素、正常的松树的60个像素、草木的60个像素、道路的59个像素、阴影的60个像素和裸地的60个像素来评估Wonchang村的分类结果的精度。针对Wonchang村的ANN和SVM分类器的精度评估结果分别如表4和表5所示。SVM(86.59%)比ANN(79.33%)分类更精确，这意味着SVM在类别之间的区分能力，

表3 利用SVM对Anbi村进行分类得到的误差矩阵

Class	PWD	Normal pines	Grass and trees	Buildings	Roads	Shadows	Class total
PWD-indicated trees	58	0	0	4	2	0	64
Normal pines	0	60	6	0	0	3	69
Grass and trees	0	0	53	0	0	0	53
Buildings	1	0	0	56	4	0	61
Roads	0	0	0	0	53	0	53
Shadows	0	0	1	0	0	57	58
References total	59	60	60	60	59	60	358

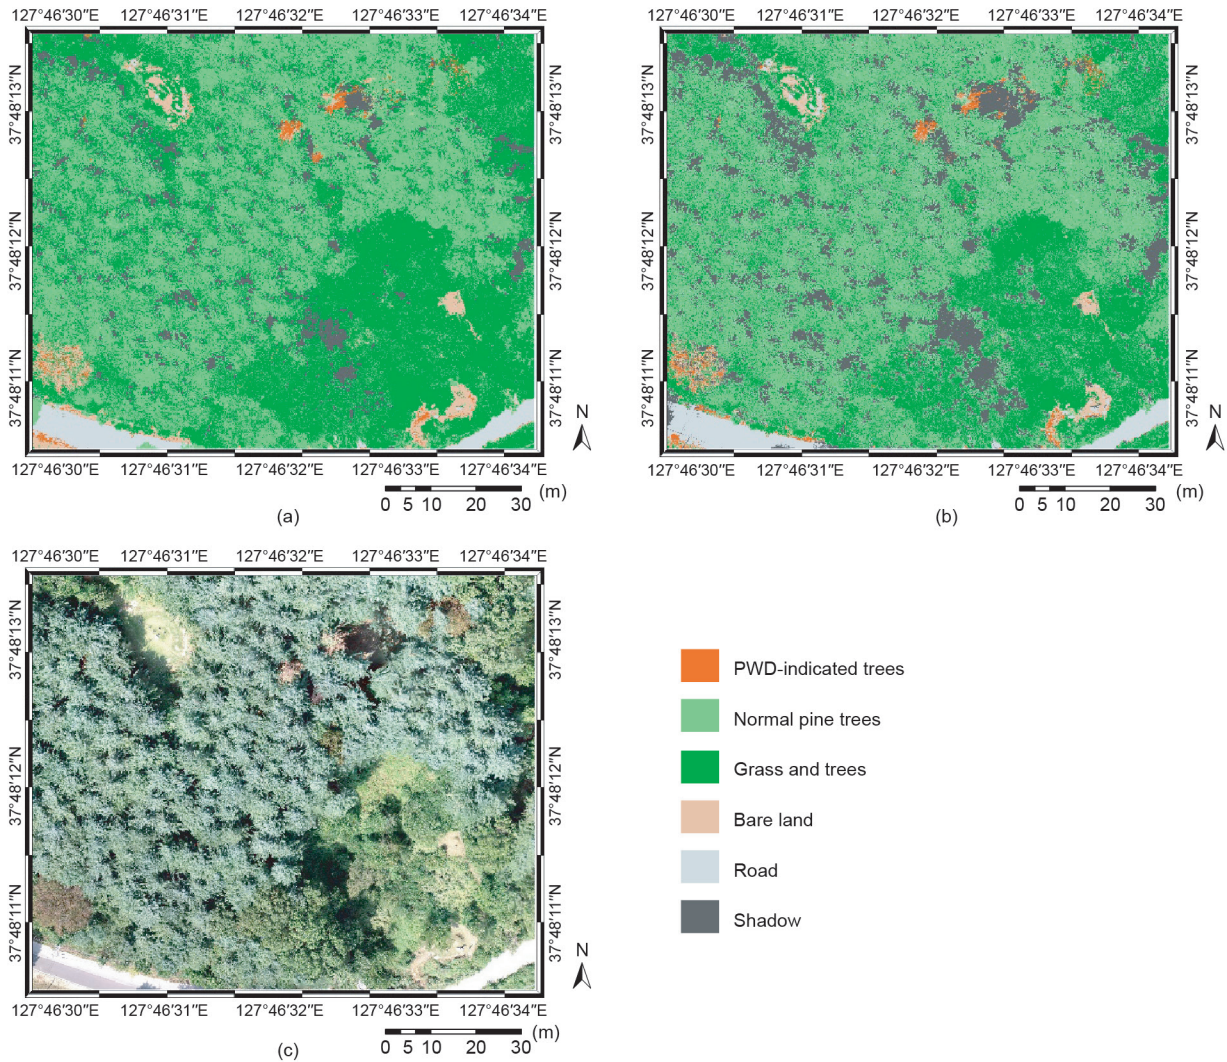


图4. 使用SVM分类器(a)和ANN分类器(b)从无人机图像(c)中生成的Wonchang村的土地分类图。图像中的元素可分为6类: 感染PWD的树木(橙色)、正常的松树(浅绿色)、草木(绿色)、建筑物(蓝色)、道路(浅灰色)和阴影(灰色)。

特别是对感染PWD的树木的识别效果, 要优于ANN。这一结论得到了kappa系数的支持: SVM的kappa系数为0.8391或83.91%, ANN的kappa系数为0.7520或75.20%。根据Landis和Koch(1997), 这表明了更强的一致性。

3.5. GPS 数据集之间的差异

手持GPS设备计算的坐标与无人机GPS设备计算的坐标存在一定差异, 如表6和表7所示。造成这些差异的原因有很多, 如GPS信号传播误差(电离层延迟)以及相对论效应的影响。这两种类型的GPS设备为Anbi村

和Wonchang村的感染PWD的树木提供了不同的坐标。其中, 对手持GPS设备1的坐标数据进行了实地校正, 而手持GPS设备2的数据则没有校正, 我们使用了GPS设备的默认设置。在Wonchang村, 无人机GPS设备的采集结果与手持GPS设备2的采集结果之间的差异(差异为7.37 m和7.25 m)大于无人机GPS设备的采集结果与手持GPS设备1的采集结果之间的差异(差异为9.75 m和1.22 m)。因此, 校正了坐标的GPS设备1的结果与无人机GPS设备结果更一致。然而, 在Anbi村, GPS设备2的采集结果与使用无人机GPS设备获得的结果更接近(差异为0.14 m和2.49 m)。因此, 在这种情况下, 来自设备的默认数据比GPS设备1提供的校正数据的结果更优(差异为7.08 m和3.37 m)。

4. 讨论

利用ANN和SVM两种分类器对无人机图像进行处

理后, 所生成的Wonchang村和Anbi村的分类结果、精度评估以及GPS数据集之间的差异都已经在结果部分提到。然而, 还有一些有待商榷的结论, 将在接下来一节中进行讨论。

4.1. 来自 Anbi 村的土地分类图

从Anbi村获得的SVM和ANN分类器的分类结果来看, 尽管两者在地图上看起来只是略有不同, 但它们的精度却存在较大差异。然而, 如果我们仔细查看这两种分类结果[图3 (a) 和 (b)], 分类结果确实有些不同。例如, 在SVM结果中显示的感染PWD的树木不像在ANN中那么多, 无论是对感染PWD的树木本身还是对错误分类区域都是如此。此外, 诸如道路、阴影和建筑物等其他类别在一些不应该被检测到的区域中被检测到了, 这在ANN分类结果中尤其明显。

混淆矩阵(误差矩阵)方法建立了分类结果与参考数据之间的对应关系, 因此即使LC地图看起来相似,

表4 Wonchang村的误差矩阵, 采用ANN进行分类

Class	PWD	Normal pines	Grass and trees	Roads	Shadows	Bare lands	Class Total
PWD-indicated trees	53	0	0	0	0	7	60
Normal pines	0	48	11	0	0	1	60
Grass and trees	0	10	45	0	0	2	57
Roads	0	1	2	59	2	0	64
Shadows	6	1	0	0	58	29	94
Bare lands	0	0	2	0	0	21	23
References total	59	60	60	59	60	60	358

表5 Wonchang村的误差矩阵, 采用SVM进行分类

Class	PWD	Normal pines	Grass and trees	Roads	Shadows	Bare lands	Class total
PWD-indicated trees	55	0	0	0	0	5	60
Normal pines	0	46	6	2	4	0	58
Grass and trees	0	13	52	1	0	1	67
Roads	0	0	2	56	0	0	58
Shadows	0	1	0	0	56	9	66
Bare lands	4	0	0	0	0	45	49
References total	59	60	60	59	60	60	358

表6 从Anbi村采集的3个GPS数据集的比较

Class	Drone GPS (m)	Hand-held GPS 1 (m)	Hand-held GPS 2 (m)
PWD-indicated trees	375 325.664	375 318.589	375 325.807
	4 188 772.272	4 188 768.904	4 188 769.782
Differences		7.08	0.14
		3.37	2.49

表7 从 Wonchang 村采集的3个GPS数据集的比较

Class	Drone GPS (m)	Hand-held GPS 1 (m)	Hand-held GPS 2 (m)
PWD-indicated tree 1	392 226.388	392 229.760	392 233.888
	4 184 732.877	4 184 742.630	4 184 740.248
Differences		16 904.10	16 908.22
		9.75	7.37
PWD-indicated tree 2	392 215.327	392 233.412	392 233.888
	4 184 726.705	4 184 725.484	4 184 719.452
Differences		18.085	18.56
		1.22	7.25

SVM和ANN在精度上也会存在差异。此外，无论是对总体精度还是对kappa系数，该方法利用像素数来确定精度。因此，即使感染PWD的树木的阴影相似，所显示的精度结果也适用于所有错误分类的类。

4.2. Anbi 村的精度评估

精度评估代表了生成的分类图的精度。在评估精度时，采用混淆矩阵计算像素数并进行比较。从表2和表3可以看出，SVM的总体精度和kappa系数比ANN得到的结果更优。从每个表中，我们可以看到各个类的用户精度，又称可靠性。表3中的一些类别显示出很高的百分比，如草木类以及阴影类，这意味着如果该地图的用户进行实地考察，这些类将经常出现在地面上。

4.3. 来自 Wonchang 村的土地分类图

与Anbi村的结果一样，Wonchang村的分类结果略有不同，但精度却相差甚远。由于采用同样的方法来计算精度，并采用像素数来确定总体精度和kappa系数，因此可以解释分类结果和精度结果之间的矛盾之处。仔细观察图4(a)和(b)就会发现，ANN中错误分类的面积大于SVM，特别是感染了PWD的树木类。此外，裸地和一些棕色的草也被检测为感染了PWD的树木，这使得在Wonchang村的结果中，ANN的总体精度低于SVM。

4.4. Wonchang 村的精度评估

与Anbi村相似，Wonchang村的精度评估也采用了同样的方法。我们采用误差矩阵方法生成了总体精度和kappa系数。如表4和表5所示，SVM的总体精度高于ANN，kappa系数的检测结果也是如此。该精度百分数受分类结果和每个类别的精度影响。相较于其他类，裸地类的生产者精度较低，这意味着只有35%的裸地能

正确地显示在分类地图上，或者说，在地图上划分裸地的概率只有35%。相反，这一类别的用户精度高达91.30%，因此，尽管其生产者精度较低，分类结果地图中的裸地类仍是可靠的。然而，由于每个类别的精度都会影响总体精度和kappa精度，因此这个例子可以解释为什么SVM比ANN更优。

4.5. GPS 数据集之间的差异

手持GPS设备1和GPS设备2的不同之处仅来自其坐标数据。手持GPS设备1通过将GPS记录到Wonchang村和Anbi村附近的基准点上校正。而手持GPS设备2未校正到基准点。如结果部分所述，这种差异可能是由于GPS信号传播误差和相对论效应等技术原因造成的，处理数据和现场技术方面的工作流程也可能对本研究产生影响。

5. 结论

我们使用ANN和SVM算法对Anbi村和Wonchang村的图像进行分类，并成功地将感染PWD的树木与无人机图像中观察到的其他类型的覆盖物区分开来。我们从SVM分类器中得到了更好的结果，其总体精度（Anbi村为94.13%，Wonchang村为86.59%）高于ANN分类器（Anbi村为87.43%，Wonchang村为79.33%）。与ANN分类器相比，SVM分类器的kappa系数表现出更强的一致性（Anbi村为0.9296，Wonchang村为0.8391）。这表明，在对具有与感染PWD的树木相似特征的覆盖物或特定树木的类型进行分类这一方面，SVM分类器优于ANN分类器。

3种设备所采集的GPS数据集存在一些差异。校正后的手持GPS设备在Wonchang村获得的结果更精确，但在Anbi村，提供原始数据的手持GPS设备的结果更接

近无人机GPS设备的结果。总的来说，这两种算法成功地区分了感染PWD的树木和无人机图像中显示的其他类型的覆盖物。这些算法可供专家、政府及其他保险客户使用，以促进对感染PWD的树木的早期检测，并将帮助他们找到解决这一问题的最佳方案。林业研究人员或专家需要进行后续观察，以确认感染PWD的树木是否确实受到PWD的感染。

Acknowledgments

This research was supported by a grant from the National Research Foundation of Korea, provided by the Korean government (No. 2017R1A2B4003258, 2018).

Compliance with ethics guidelines

Mutiara Syifa, Sung-Jae Park and Chang-Wook Lee declare that they have no conflict of interest or financial conflicts to disclose.

References

- [1] Shin SC. Pine wilt disease in Korea. In: Zhao BG, Futai K, Sutherland JR, Takeuchi Y, editors. Pine wilt disease. Tokyo: Springer; 2008. p. 26–32.
- [2] Kwon SD. Changes in Korean pine forests. *Monthly Inf For Sci* 2006;181:16–7. Korean
- [3] Kwon TS, Shin JH, Lim JH, Kim YK, Lee EJ. Management of pine wilt disease in Korea through preventative silvicultural control. *For Ecol Manage* 2011;261(3):562–9.
- [4] Han H, Chung YJ, Shin SC. First report of pine wilt disease on *Pinus koraiensis* in Korea. *Plant Dis* 2008;92(8):1251.
- [5] Mamiya Y. History of pine wilt disease in Japan. *J Nematol* 1988;20(2):219–26.
- [6] Mota MM, Vieira P, editors. Pine wilt disease: a worldwide threat to forest ecosystems. Dordrecht: Springer; 2008. p. 405.
- [7] Webster J, Mota M. Pine wilt disease: global issues, trade and economic impact. In: Mota MM, Vieira PR, editors. Pine wilt disease: a worldwide threat to forest ecosystems. Dordrecht: Springer; 2008.
- [8] Ikegami M, Jenkins TAR. Estimate global risks of a forest disease under current and future climates using species distribution model and simple thermal model—pine wilt disease as a model case. *For Ecol Manage* 2018;409:343–52.
- [9] Futai K. Pine wilt in Japan: from first incidence to the present. In: Zhao BG, Futai K, Sutherland JR, Takeuchi Y, editors. Pine wilt disease. Tokyo: Springer; 2008. p. 5–12.
- [10] Zhao BG. Pine wilt disease in China. In: Zhao BG, Futai K, Sutherland JR, Takeuchi Y, editors. Pine wilt disease. Tokyo: Springer; 2008. p. 18–25.
- [11] Mamiya Y. Pathology of the pine wilt disease caused by *Bursaphelenchus xylophilus*. *Annu Rev Phytopathol* 1983;21(1):201–20.
- [12] Kim JB, Jo MH, Oh JS, Lee KJ, Park SJ, Um HH. Temporal and spatial correlation analysis of *Bursaphelenchus xylophilus* damage area. In: Proceedings of the Korean Society of Agricultural and Forest Meteorology 2001 Spring Conference; 2001 Jun; Seoul, Korea; 2001. p. 49–52.
- [13] Kim SR, Lee WK, Lim CH, Kim M, Kafatos MC, Lee SH, et al. Hyperspectral analysis of pine wilt disease to determine an optimal detection index. *Forests* 2018;9(3):115.
- [14] Kim MI, Lee WK, Kwon TH, Kwak DA, Kim YS, Lee SH. Early detecting damaged trees by pine wilt disease using DI (detection index) from portable near infrared camera. *J Korean Soc For Sci* 2011;100(3):374–81.
- [15] Tang L, Shao G. Drone remote sensing for forestry research and practices. *J For Res* 2015;26(4):791–7.
- [16] Yuan H, Yang G, Li C, Wang Y, Liu J, Yu H, et al. Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: analysis of RF, ANN, and SVM regression models. *Remote Sens* 2017;9(4):309.
- [17] Aasen H, Burkart A, Bolten A, Bareth G. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: from camera calibration to quality assurance. *ISPRS J Photogramm Remote Sens* 2015;108:245–59.
- [18] Feng Q, Liu J, Gong J. UAV remote sensing for urban vegetation mapping using random forest and texture analysis. *Remote Sens* 2015;7(1):1074–94.
- [19] Lei T, Zhang Y, Lu J, Pang Z, Fu J, Kan G, et al. The application of UAV remote sensing in mapping of damaged buildings after earthquakes. In: Proceedings of the 10th International Conference on Digital Image Processing; 2018 May 11–14; Shanghai, China; 2018. p. 1080651.
- [20] Yamazaki F, Liu W. Remote sensing technologies for post-earthquake damage assessment: a case study on the 2016 Kumamoto earthquake. In: Proceedings of the 6th Asia Conference on Earthquake Engineering; 2016 Sept 22–24; At Cebu City, Philippines; 2016. p. 8.
- [21] Niethammer U, James MR, Rothmund S, Travelletti J, Joswig M. UAV-based remote sensing of the Super-Sauze landslide: evaluation and results. *Eng Geol* 2012;128:2–11.
- [22] Giordan D, Manconi A, Tannant DD, Allasia P. UAV: low-cost remote sensing for high-resolution investigation of landslides. In: Proceedings of the 2015 IEEE International Geoscience and Remote Sensing Symposium; 2015 Jul 26–31; Milan, Italy; 2015. p. 5344–7.
- [23] Casagli N, Frodella W, Morelli S, Tofani V, Ciampalini A, Intrieri E, et al. Spaceborne, UAV and ground-based remote sensing techniques for landslide mapping, monitoring and early warning. *Geoenviron Disasters* 2017;4(1):9.
- [24] Favalli M, Fornaciai A, Nannipieri L, Harris A, Calvari S, Lormand C. UAV-based remote sensing surveys of lava flow fields: a case study from Etna's 1974 channel-fed lava flows. *Bull Volcanol* 2018;80(3):29.
- [25] Rüdiger J, Lukas T, Bobrowski N, Gutmann A, Liotta M, de Moor M, et al. Compositional variation in aging volcanic plumes—analysis of gaseous SO₂, CO₂ and halogen species in volcanic emissions using an unmanned aerial vehicle (UAV). In: Proceedings of the EGU General Assembly Conference; 2017 Apr 23–28; Vienna, Austria; 2017. p. 892.
- [26] Xiong Y, Zhang Z, Chen F. Comparison of artificial neural network and support vector machine methods for urban land use/cover classifications from remote sensing images a case study of Guangzhou, South China. In: Proceedings of the 2010 International Conference on Computer Application and System Modeling; 2010 Oct 22–24; Taiyuan, China; 2010. p. V13–52.
- [27] Liang D, Guan Q, Huang W, Huang L, Yang G. Remote sensing inversion of leaf area index based on support vector machine regression in winter wheat. *Nongye Gongcheng Xuebao (Beijing)* 2013;29(7):117–23.
- [28] Yoon H, Kim Y, Ha K, Lee SH, Kim GP. Comparative evaluation of ANN- and SVM-time series models for predicting freshwater-saltwater interface fluctuations. *Water* 2017;9(5):323.
- [29] Murmu S, Biswas S. Application of fuzzy logic and neural network in crop classification: a review. *Aquat Procedia* 2015;4:1203–10.
- [30] Yuan H, van Der Wiele CF, Khorrarn S. An automated artificial neural network system for land use/land cover classification from Landsat TM imagery. *Remote Sens* 2009;1(3):243–65.
- [31] Maier HR, Dandy GC. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environ Modell Software* 2000;15(1):101–24.
- [32] Kadavi PR, Lee CW. Land cover classification analysis of volcanic island in Aleutian Arc using an artificial neural network (ANN) and a support vector machine (SVM) from Landsat imagery. *Geosci J* 2018;22(4):653–65.
- [33] Kavzoglu T, Colkesen I. A kernel functions analysis for support vector machines for land cover classification. *Int J Appl Earth Obs Geoinf* 2009;11(5):352–9.
- [34] Cortes C, Vapnik V. Support-vector networks. *Mach Learn* 1995;20(3):273–97.
- [35] Lu D, Batistella M, Li G, Moran E, Hetrick S, Freitas CDC, et al. Land use/cover classification in the Brazilian Amazon using satellite images. *Pesqui Agropecu Bras* 2012;47(9):1185–208.
- [36] Verrelst J, Muñoz J, Alonso L, Delegido J, Rivera JP, Camps-Valls G, et al. Machine learning regression algorithms for biophysical parameter retrieval: opportunities for Sentinel-2 and -3. *Remote Sens Environ* 2012;118:127–39.
- [37] Liaw A, Wiener M. Classification and regression by randomForest. *R News* 2002;2(3):18–22.
- [38] Zhai S, Jiang T. A novel particle swarm optimization trained support vector machine for automatic sense-through-foilage target recognition system. *Knowl Based Syst* 2014;65:50–9.
- [39] Congalton RG. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens Environ* 1991;37(1):35–46.
- [40] Cohen J. A coefficient of agreement for nominal scales. *Educ Psychol Meas* 1960;20(1):37–46.