

КЛАССИФИКАЦИЯ ПИХТЫ, ПОВРЕЖДЕННОЙ УССУРИЙСКИМ ПОЛИГРАФОМ, ПО СНИМКАМ С БПЛА С ИСПОЛЬЗОВАНИЕМ НЕЙРОННОЙ СЕТИ U-NET

К.А. Маслов

Научный руководитель: О.С. Токарева, к.т.н., доцент
Томский политехнический университет
E-mail: orpheus.const@outlook.com

Введение

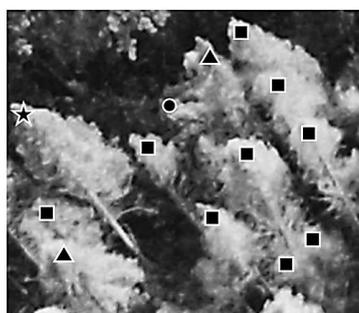
Уссурийский полиграф, завезённый на территорию Южной Сибири дальневосточный эндемичный вид, является в настоящее время наиболее агрессивным из всех известных видов короедов в сибирских пихтовых лесах и одним из основных в комплексе факторов их усыхания. Инвазия данного вида имеет значительные экономические и экологические последствия [1].

Один из современных трендов в области дистанционного зондирования Земли – использование данных высокого пространственного разрешения, полученных с использованием беспилотных летательных аппаратов (БПЛА), имеющих большой потенциал при решении задач управления лесными ресурсами, позволяющих оценивать параметры отдельных деревьев. При этом при решении задач автоматической интерпретации данных мониторинга БПЛА активно используются искусственные нейронные сети (ИНС) различных архитектур [2, 3].

Целью данной работы является разработка подхода к классификации деревьев пихты, поврежденной уссурийским полиграфом, по снимкам БПЛА с использованием сверточных ИНС.

Исходные данные

В качестве исходных данных использовались снимок поврежденного пихтового древостоя, полученный с БПЛА, и соответствующая разметка отдельных деревьев по классам в виде маркеров (рисунок 1).



- Живые
- ★ Отмирающие
- Сухостой прошлых лет
- ▲ Свежий сухостой

Рис. 1. Исходные данные (фрагмент)

Подготовка данных

Для обучения ИНС исходные данные были размечены с использованием ПО GIMP путем заливки областей, соответствующих кронам деревьев. Для формирования обучающей выборки была предусмотрена следующая процедура аугментации:

1. исходное изображение и соответствующая эталонная карта классификации нарезаются на соответствующие друг другу фрагменты размером 256*256 с шагом 128 пикселей;

2. исходное изображение и эталонная карта поворачиваются на 30 градусов по часовой стрелке;

3. процедура повторяется, пока угол поворота не составит 360 градусов.

Таким образом удалось сформировать выборку объемом из 846 пар изображений для обучения, примеры приведены на рисунке 2.

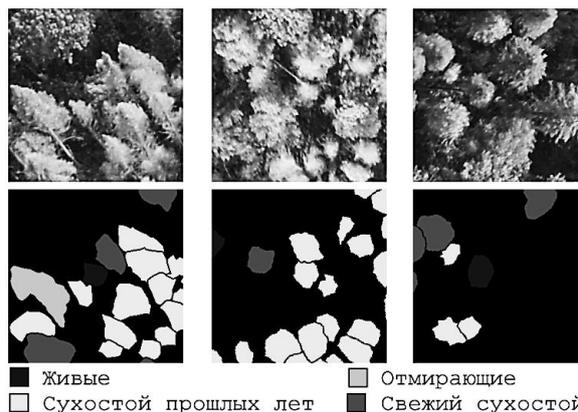


Рис. 2. Примеры из сформированной выборки (сверху представлены фрагменты для подачи на вход ИНС, снизу представлены соответствующие ожидаемые выходные данные)

Архитектура нейронной сети

В данной работе использовалась оригинальная архитектура U-Net [4] со следующими модификациями:

– в качестве входного сигнала ИНС служит тензор 256*256*3;

– сверточные слои не уменьшают размерность изображений;

– последняя свертка двумя фильтрами 1*1 заменена на свертку четырьмя фильтрами 1*1, что позволяет получить на выходе ИНС тензор 256*256*4, где каждая составляющая вдоль третьей оси отвечает за результат детектирования каждого класса в отдельности.

Для программной реализации, описанной нейросетевой модели и ее обучения, были использованы язык программирования python и фреймворк глубокого обучения keras.

Постобработка выхода ИНС

Имеющийся на выходе нейронной сети тензор 256*256*4 (рисунок 3, а) необходимо преобразовать в итоговую карту классификации, для этого для каждого канала производится пороговая фильтрация (рисунок 3, б), после чего каждому пикселю ставится в соответствие номер канала с максимальной интенсивностью (рисунок 3, в).

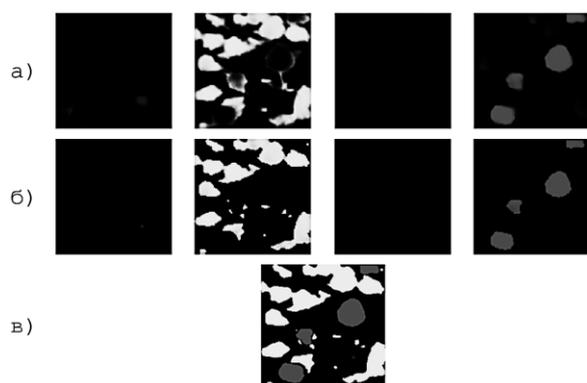


Рис. 3. Преобразование выхода ИНС в карту классификации: а) необработанный выход ИНС, б) выход ИНС после пороговой фильтрации, в) итоговая карта классификации

Оценка результатов классификации

Для оценки качества классификации был выбран тестовый участок (рисунок 4, а), к которому была применена обученная ИНС (рисунок 4, в).

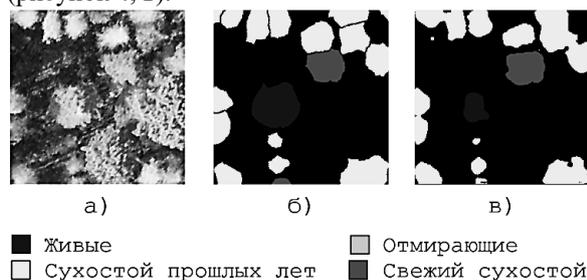


Рис. 4. Тестирование ИНС: а) тестовый участок, б) эталонная карта классификации, в) результат классификации

Качественный анализ результатов показал большую потенциальную способность предложенной архитектуры ИНС к классификации данных высокого пространственного разрешения, полученных с БПЛА. При этом наблюдается смещение результатов классификации в сторону класса «Сухостой прошлых лет», что в первую очередь следует связать с ограниченностью и несбалансированностью обучающей выборки.

Значения количественных метрик accuracy, precision и recall приведены в таблице.

Таблица. Метрики качества классификации

Класс	Accuracy	Precision	Recall
Фон	0,90	0,89	0,97
Живые	0,96	1,00	0,33
Сухостой прошлых лет	0,94	0,93	0,81
Свежий сухостой	0,99	0,86	0,86

Заключение

В данной работе был предложен нейросетевой подход к классификации поврежденных уссурийским полиграфом деревьев пихты по снимкам с БПЛА с использованием архитектуры U-Net и проведена его оценка. В перспективе появления большего количества данных мониторинга пихтовых насаждений ожидается повышение эффективности описанного подхода. Ожидается, что более интенсивная аугментация исходных данных позволит значительно расширить обучающую выборку. В дальнейшем предложенный подход может быть модифицирован путем внесения изменений в архитектуру используемой ИНС, алгоритм постобработки выхода ИНС и т. п.

Автор выражает особую благодарность старшему научному сотруднику лаборатории мониторинга лесных экосистем Института мониторинга климатических и экологических систем СО РАН к.б.н. И. А. Керчеву за предоставленные исходные данные.

Список использованных источников

1. Кривец С. А., Керчев И. А., Бисирова Э. М., Дебков Н. М. Современное распространение и прогноз расширения инвазионного ареала уссурийского полиграфа *Polygraphus proximus* Blandford, 1894 в Томской области (Западная Сибирь) // Евразийский энтомологический журнал, 2018. – Т. 17. – № 1. – С. 53–60
2. M. Onishi and T. Ise Automatic Classification of Trees Using a UAV Onboard Camera and Deep Learning [Электронный ресурс] // arXiv.org, 2015. – URL: <https://arxiv.org/abs/1804.10390> (дата обращения: 14.01.2020)
3. S. Natesan, C. Armenakis, and U. Vepakomma ResNet-based Tree Species Classification Using UAV Images // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2019. – Vol. XLII-2/W13. – pp. 475–481
4. O. Ronneberger, P. Fischer, and T. Brox U-Net: Convolutional Networks for Biomedical Image Segmentation [Электронный ресурс] // arXiv.org, 2015. – URL: <https://arxiv.org/abs/1505.04597> (дата обращения: 15.01.2020)