

УДК: 519.876.5, 004.852

Перспективы использования космоснимков для прогнозирования загрязнения воздуха тяжелыми металлами

А. В. Ужинский^{1,а}, Г. А. Ососков¹, П. В. Гончаров², М. В. Фронтасьева³

¹ Лаборатория информационных технологий, Объединенный институт ядерных исследований,
Россия, 141980, Московская обл., г. Дубна, ул. Жолио-Кюри, д. 6

² Гомельский государственный технический университет имени П. О. Сухого,
Республика Беларусь, 246746, г. Гомель, пр-т Октября, д. 48

³ Лаборатория нейтронной физики, Объединенный институт ядерных исследований,
Россия, 141980, Московская обл., г. Дубна, ул. Жолио-Кюри, д. 6

E-mail: ^аauzhinskiy@jinr.ru

Получено 28.03.2018, после доработки — 07.05.2018.

Принято к публикации 10.05.2018.

Контроль за загрязнением воздуха имеет большое значение для стран Европы и Азии. В рамках Конвенции ООН по дальнему трансграничному переносу воздушных загрязнений (CLRTAP) реализуется программа UNECE ICP Vegetation, направленная на определение наиболее неблагоприятных областей, создание региональных карт и улучшение понимания природы долгосрочных трансграничных загрязнений. В Объединенном институте ядерных исследований была разработана облачная платформа, предоставляющая участникам программы ICP Vegetation удобные инструменты для сбора, анализа и обработки данных мониторинга. В настоящее время в системе содержится информация о более чем 6000 точках пробоотбора в 40 регионах различных стран Европы и Азии.

Важным этапом контроля является моделирование загрязнений в местах, где частота исследований или плотность покрытия сети сбора образцов недостаточны. Одним из подходов к прогнозированию загрязнений является использование специализированных статистических моделей и методов машинного обучения совместно с различными количественными показателями точек сбора образцов и информацией о концентрациях элементов. Наиболее перспективным источником количественных показателей для обучения моделей являются космические снимки в различных спектрах. Обученная должным образом модель позволит получать прогноз по концентрациям элементов, используя исключительно космоснимки. Специализированная платформа Google Earth Engine предоставляет широкие возможности для анализа и обработки данных от более чем 100 различных проектов дистанционного зондирования земли, удобный интерфейс разработчика на JavaScript и программный интерфейс на Python для использования в сторонних приложениях.

В работе рассматривается возможность использования статистических показателей космоснимков, полученных от платформы Google Earth Engine, совместно с данными мониторинга состояния окружающей среды проекта ICP Vegetation для обучения моделей, способных прогнозировать концентрацию тяжелых металлов в определенных регионах.

Ключевые слова: прогнозирование, экологический мониторинг, космоснимки, машинное обучение

UDC: 519.876.5, 004.852

Perspectives of using a satellite imagery data for prediction of heavy metals contamination

A. V. Uzhinskiy^{1,a}, G. A. Ososkov¹, P. V. Goncharov², M. V. Frontasyeva³

¹ Joint institute for nuclear researches, Laboratory of Information Technologies,
6 Joliot-Curie st., Moscow reg., Dubna, 141980, Russia

² Sukhoi State Technical University of Gomel,
48 Prospect Octiabria, Gomel, 246746, Republic of Belarus

³ Joint institute for nuclear researches, Frank Laboratory of Neutron Physics,
6 Joliot-Curie st., Moscow reg., Dubna, 141980, Russia

E-mail: ^aauzhinskiy@jinr.ru

Received 28.03.2018, after completion — 07.05.2018.

Accepted for publication 10.05.2018.

Air pollution has a significant impact on the European and Asian countries. The aim of the UNECE International Cooperative Program (ICP) Vegetation in the framework of the United Nations Convention on Long-Range Transboundary Air Pollution (CLRTAP) is to identify the main polluted areas of Europe, produce regional maps and further develop the understanding of the long-range transboundary pollution. Specialists of the Joint Institute of Nuclear Research (JINR) developed cloud platform (ICP Vegetation Data Management System, DMS) consists of a set of interconnected services. The platform intended to provide ICP Vegetation participants with modern unified system of collecting, analyzing and processing of biological monitoring data. More than 6000 sampling sites from 40 regions of different countries presented at the DMS now.

Modeling of areas where sampling carried out rarely or where dimension of the sampling grid is rather big is an important stage of the environmental monitoring. Using of the special statistical models and machine learning technics together with different parameters and information about concentrations from the sampling sites is one of the perspective approaches for prediction. The most perspective source of the additional parameters for the models is satellite imaginaries done in different specters. Specially trained model taking into account also parameters from the satellite images can predict concentration. Google Earth Engine platform is an innovating tool for search and processing GIS-data from different sources. There are more than 100 satellite programs and modeled datasets. Google Earth Engine has JavaScript online editor to create and verify code and python API to communicate with users applications.

Possibilities to predict a heavy metals concentration by a special statistical models and machine learning algorithms are considered. Sources for model training are satellite imagery from Google Earth Engine platform and sampling data from DMS for ICP Vegetation program.

Keywords: prediction, ecological monitoring, satellite images, machine learning

Citation: *Computer Research and Modeling*, 2018, vol. 10, no. 4, pp. 535–544 (Russian).

Введение

Современное общество сталкивается с множеством угроз, одной из которых являются долгосрочные трансграничные загрязнения тяжелыми металлами. Негативное влияние на здоровье человека и значительные экономические потери — это далеко не все риски, связанные с данной проблемой. Экологический мониторинг позволяет определить неблагополучные области, их состав и тенденции развития. Для получения данных мониторинга производится сбор и анализ образцов мхов-биомониторов. Частота и плотность покрытия размерной сети исследований по естественным причинам не могут быть очень высокими, поэтому участникам экологических программ приходится использовать различные статистические методы для восполнения пробелов или оперировать только данными с точек сбора образцов, что, естественно, сильно ограничивает их возможности. В большинстве случаев для прогнозирования используются геостатистический кригинг и другие интерполяционные методы [Nickel et al., 2014], а также более общие подходы, например нейросетевые модели [Alijagić, 2013].

Вопросы контроля загрязнения окружающей среды в Европе и Азии курируются специальной Комиссией ООН. В ее рамках реализуется программа по контролю за загрязнением воздуха — UNECE ICP Vegetation [UNECE ICP Vegetation]. Изучение атмосферных выпадений тяжелых металлов, азота, стойких органических соединений и радионуклидов в UNECE ICP Vegetation базируется на анализе мхов-биомониторов, собираемых каждые пять лет в 39 странах Европы и Азии [Harmens, Mills, 2014]. В Объединенном институте ядерных исследований была разработана платформа (moss.jinr.ru (DMS)), представляющая собой набор взаимосвязанных облачных сервисов и средств для управления и обработки данных биомониторинга. Платформа позволяет упростить и автоматизировать этапы мониторинга, начиная с выбора мест для сбора образцов и заканчивая генерацией карт распределения загрязнений [Ужинский и др., 2017]. В настоящее время в системе содержится информация о более чем 6000 точках пробоотбора в 40 регионах различных стран Европы и Азии. Эти данные могут быть использованы для обучения различных моделей для последующего прогнозирования концентрации тяжелых металлов.

Наиболее доступным источником дополнительных количественных показателей для моделей являются космические снимки, выполненные в различных спектрах, так как существует достаточно много специализированных программ, которые предоставляют бесплатный доступ к своим данным. Обычной практикой при реализации такого класса задач является использование общедоступных снимков из проектов типа Landsat или MODIS с их последующей обработкой в пакетах ENVI или ERDAS. Поиск данных осуществляется непосредственно в базах проектов или в специализированных системах, предоставляющих определенные средства автоматизации. В большинстве случаев подобные системы ориентированы на работу со снимками только одной программы, что в нашем случае серьезно ограничивало возможности исследований. Наиболее подходящей альтернативой на данном этапе стало использование специализированной платформы Google Earth Engine (GEE). Этот продукт предоставляет широкие возможности для анализа и обработки данных, удобный интерфейс разработчика на JavaScript и программный интерфейс на Python для использования в своих приложениях. В состав платформы GEE включена обширная база геоинформационных данных различных космических проектов и моделей за многие годы, в которой представлены как исходные данные, так и статически обработанные показатели снимков, сделанных в различных диапазонах спектра отражения. Существуют удобные инструменты для поиска, фильтрации и обработки данных, необходимые для выполнения поставленной задачи.

Целью данной работы являлось изучение возможности использования данных, полученных путем обработки космоснимков, совместно с различными статистическими моделями и методами машинного обучения для прогнозирования концентрации тяжелых металлов. Возможность дистанционного обнаружения некоторых тяжелых металлов подтверждается результатами зарубежных [Rees, 2001] и отечественных [Андреева и др., 2007] исследований. Суть

подхода заключалась в том, что при использовании информации о концентрациях в определенных точках пробоотбора, полученной из DMS, а также различных количественных показателей, полученных из космоснимков в этих точках, обучалась специализированная модель. Затем при использовании только дополнительных количественных показателей, передаваемых в модель, вычислялись значения концентраций для сетки региона нужной размерности.

Взаимосвязь статистических данных космоснимков с концентрацией тяжелых металлов

Для платформы DMS был разработан специализированный модуль, позволяющий получить количественные показатели из снимков различных спектров и оценить их корреляцию с концентрациями элементов в точках сбора образцов. Были изучены статистические показатели различных по площади областей проектов (MODIS, LandSat, Sentinel 2, PROBA-V и т. д.) для Польши, Швеции, Румынии, Словении, Норвегии и ряда других стран и регионов.

Степень взаимосвязи концентраций тяжелых металлов (ТМ) со статистическими величинами, получаемыми из космоснимков, в большинстве случаев оказалась недостаточна для обучения модели. Только для некоторых проектов удалось обнаружить корреляционную зависимость больше 0.5 для ряда химических элементов.

В таблице 1 представлены результаты расчета коэффициентов корреляции концентраций различных ТМ во Франции и Исландии с индексами европейской спутниковой программы PROBA-V [PROBA-V 333m resolution] и американской спутниковой программы Landsat 7 [Landsat 7]. Для получения индексов производилось вычисление статистических показателей и их суммирование на площади порядка 8 км². В таблице по горизонтали представлены элементы, а по вертикали — наименование спектральных каналов, в которых производилась съемка.

Таблица 1. Связь концентраций ТМ во Франции с данными программы PROBA-V (слева).
Связь концентраций ТМ в Норвегии с данными программы Landsat 7 (справа)

	Al	Sb	V	Zn	Fe		As	Fe	Pb	Sb	V
BLUE	-0.44	0.32	-0.44	0.32	-0.33	B1	0.09	-0.32	0.08	0.04	-0.33
NDVI	0.54	-0.29	0.53	-0.3	0.42	B2	0.11	-0.32	0.08	0.08	-0.32
NIR	-0.36	0.23	-0.39	0.17	-0.25	B3	0.1	-0.32	0.08	0.1	-0.33
RED	-0.39	0.33	-0.38	0.3	-0.29	B4	-0.03	-0.59	0.09	0.1	-0.59
SAA	-0.49	0.44	-0.4	0.33	-0.34	B5	-0.06	-0.37	0.09	0.14	-0.38
SWIR	-0.16	0.07	-0.12	0.09	-0.08	B6_VC_1	0.24	-0.29	0.1	0.52	-0.28
SWIRVZA	-0.07	0.01	-0.06	0.01	-0.06	B6_VC_2	0.24	-0.28	0.1	0.51	-0.26
SZA	-0.55	0.45	-0.44	0.34	-0.39	B7	0.03	-0.26	0.11	0.27	-0.27
NIRVZA	-0.06	-0.02	-0.04	0.04	-0.07	B8	0.13	-0.29	0.03	0.04	-0.29

После первичного анализа дальнейшие исследования были сконцентрированы на поиске дополнительных параметров для прогнозирования содержания сурьмы, корреляция которой со статистическими показателями некоторых программ была больше 0.6.

В базе данных платформы DMS имелась информация о 228 точках отбора проб загрязнения сурьмой на территории Норвегии (см. карту на рис. 1). Значения наблюдаемых концентраций варьировались от 0.0065 до 0.376, и прогноз в этих условиях представлялся достаточно интересной задачей. Следовало проанализировать данные различных источников и варианты их обработки для определения наиболее перспективных дополнительных параметров для обучения моделей.

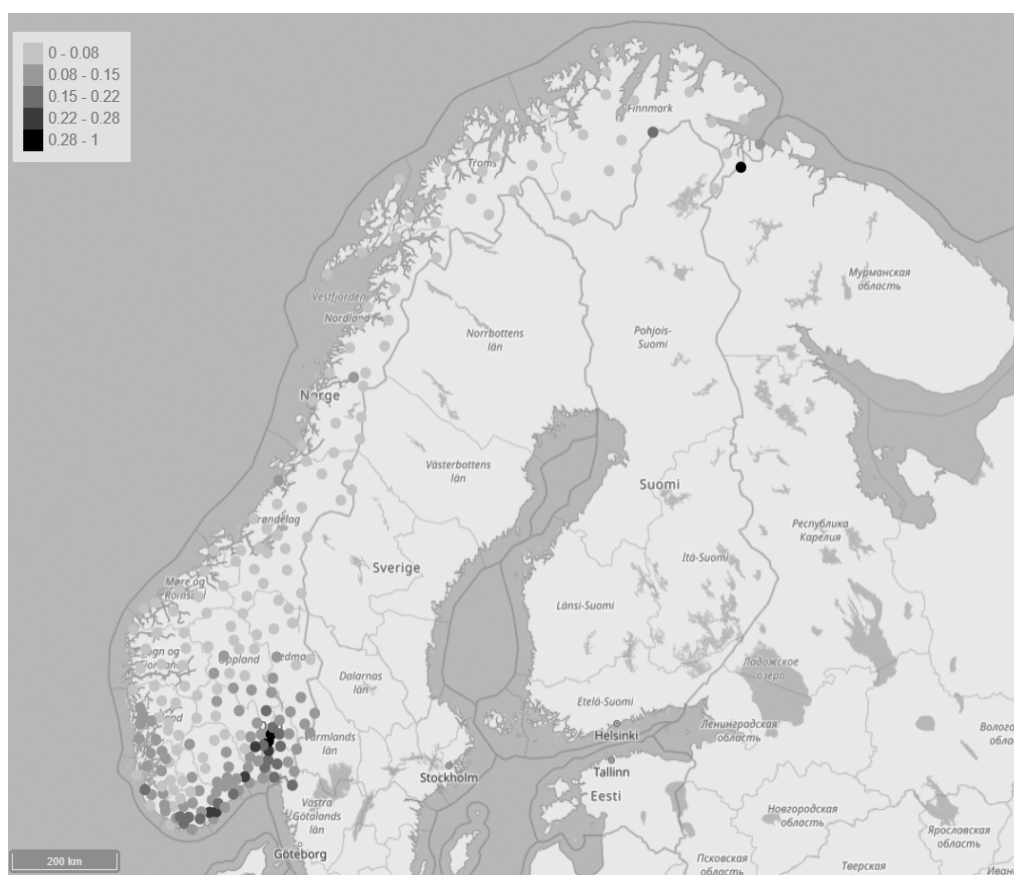


Рис. 1. Загрязнения сурьмой (Sb) в Норвегии. Концентрация представлена в мг/г

Наряду с индексами довольно известных программ типа Landsat, MODIS, Sentinel, PROBA-V неплохую связь с концентрациями показали и достаточно необычные, например, предоставляющие снимки, сделанные в ночное время (VIIRS Stray Light Corrected Nighttime Day/Night Band Version 1) или аккумулирующие данные о температуре поверхности (MOD11A2.006 Land Surface Temperature and Emissivity 8-Day Global 1km). Одним из основных источников загрязнения сурьмой является интенсивное автомобильное движение, так что связь между плотностью населения (отображаемой светимостью в ночное время) и концентрацией сурьмы вполне объяснима.

В результате анализа данных для обучения моделей были отобраны 8 параметров (таблица 2), полученных из снимков различных программ с использованием различных функций и площадей для анализа. Показателей, демонстрирующих неплохую корреляцию, было больше, однако следовало следить за связью между самими отобранными параметрами. Некоторые программы производят съемку в достаточно схожих или даже одинаковых спектрах, что исключает возможность их совместного использования для обучения. Среди отобранных параметров связанность варьировалась от 0.28 до 0.8.

Используемые статистические методы и алгоритмы

Для прогнозирования значений концентраций загрязнения было использовано 2 типа моделей: регрессии и классификации. Каждый из них, в зависимости от подхода, дополнительно делился на нейросетевую модель и древовидную. К древовидным относятся такие алгоритмы, как градиентный бустинг, решающие деревья, случайный лес и бэггинг [Hastie, 2003]. Нейросетевой подход заключался в использовании многослойного персептрона, имеющего 2 скрытых слоя.

Таблица 2. Параметры, отобранные для обучения моделей

Название программы	Индекс	Анализируе- мая площадь	Корре- ляция
<i>PROBA-V C0 Level 3 Top Of Canopy Daily Synthesis at 100m resolution</i> [PROBA-V 100m resolution]	sum(NDVI)	~36 км ²	0.636
<i>MOD11A2.006 Land Surface Temperature and Emissivity 8-Day Global 1km</i> [MOD11A2.006]	median(LST_Day_1km)	~16 км ²	0.628
<i>PROBA-V C1 Level 3 Top Of Canopy Daily Synthesis at 333m resolution</i> [PROBA-V 333m resolution]	median(SZA)	~6.25 км ²	-0.605
<i>Sentinel-3 OLCI EFR: Ocean and Land Color Instrument Earth Observation Full Resolution</i> [Sentinel-3 OLCI EFR]	max(Oa03_radiance)	~25 км ²	-0.57
<i>VIIRS Nighttime Day/Night Band Composites Version 1</i> [VIIRS Nighttime]	max(avg_rad)	~16 км ²	0.587
<i>USGS Landsat 7 Raw Scenes</i> [Landsat 7]	max(B6_VCID_2)	~20.25 км ²	0.593
<i>ASTER L1T Radiance</i> [ASTER L1T Radiance]	max(B13)	~16 км ²	0.587
<i>MODIS Nadir BRDF-Adjusted Reflectance, daily 500m</i> [MCD43A4.006]	max(Nadir_Reflectance_Band5)	~49 км ²	-0.571

Задача регрессии состоит в том, чтобы получить на выходе одно значение — величину загрязнения, которая выражается дробным числом. Обучающая выборка содержит значения входных признаков и значения загрязнения. Одним из способов оценки точности регрессионной модели является среднеквадратичное отклонение. У нейросети-регрессора последний слой состоит из одного нейрона с линейной функцией активации.

Задача регрессии может быть сведена к классификации, так как зачастую не требуется предсказывать точное значение загрязнения в конкретной точке — достаточно определить градацию загрязнения для данной области. Для того чтобы перейти к задаче классификации, на данных столбца с загрязнениями был обучен алгоритм К-средних [Alsabti et al., 1998] для выделения N кластеров, каждый из которых соответствует определенному уровню загрязнения. После процедуры кластеризации значения концентраций были заменены на номера кластеров, к которым они относятся, эти данные подавались на вход алгоритмов при обучении. Выходной слой нейросети-классификатора имеет N нейронов, что соответствует числу кластеров. Функция активации (Softmax) этого слоя представляет на выходе нейросети-классификатора условное распределение вероятности по классам в зависимости от входных данных. В качестве минимизируемого функционала был использован метод перекрестной энтропии. Так как классификаторы обучены предсказывать номер класса, то на выходе, перед записью результатов в файл, номера классов заменялись на значения центров кластеров (среднее значение концентрации для определенного уровня загрязнения). Были проведены и эксперименты с указанием весов классов, однако значительных изменений в получаемых результатах это не дало.

Для поиска оптимальных параметров древовидных моделей была применена специализированная процедура перебора по сетке, которая из всех возможных комбинаций параметров выбирает ту, что обеспечивает наименьшую ошибку при перекрестной проверке. Данные перемешивались и делились на десять равных долей, девять из которых выступали в роли обучающей выборки, а десятое разбиение предназначалось для оценки адекватности модели; на каждой итерации обучения процедура повторялась 10 раз. В результате были определены лучшие древовидные модели регрессора и классификатора (см. таблицу 3).

Поиск параметров для нейросетевых моделей невозможно осуществить с помощью полного перебора ввиду слишком медленной работы, поэтому использовался алгоритм направленного поиска — Tree-structured Parzen Estimator Approach (TPE). TPE позволяет сделать меньшее число итераций, чем при полном переборе, при этом результаты работы лучше, чем при слу-

чайном поиске [Bergstra et al., 2011]. Всего было сделано 500 итераций, где каждая итерация включала десять разбиений данных для получения наиболее объективного результата. В результате были определены лучшие нейросетевые модели регрессора и классификатора (см. таблицу 4).

Величина среднеквадратичного отклонения для лучших алгоритмов-регрессоров, измеренная на тестовой выборке, — около 0.0035 (± 0.0015).

Следующим этапом исследований стало использование наиболее перспективных моделей для прогнозирования концентраций в определенном регионе Норвегии.

Таблица 3. Лучшие древовидные модели регрессора и классификатора и их параметры

Параметр	Значения параметров регрессора	Значения параметров классификатора
Выбранный алгоритм	Градиентный бустинг	Градиентный бустинг
Метод нормализации	MinMax	Нет
Альфа-квантиль функции потерь	0.9	—
Критерий для измерения качества разделения	Среднеквадратичное отклонение	Среднеквадратичное отклонение
Минимизируемый функционал	Функция потерь Хьюбера [Friedman, 2001]	deviance
Скорость обучения	0.01	0.01
Число линейных моделей в ансамбле	400	100
Максимальная глубина дерева	3	6
Максимальное число признаков	30 % от исходного	Корень от исходного

Таблица 4. Лучшие нейросетевые модели регрессора и классификатора и их параметры

Параметр	Значения параметров сети-регрессора	Значения параметров сети-классификатора
Метод нормализации	MinMax	MinMax
Минимизируемый функционал	Среднее абсолютное отклонение	Перекрестная энтропия
Число эпох обучения	100	250
Количество нейронов первого скрытого слоя	15	10
Нейронов второго скрытого слоя	10	25
Функция активации на скрытых слоях	ReLU [Nair, Hinton, 2010]	ReLU
Величина dropout [Srivastava, 2014]	0.35	0
Метод оптимизации	Стохастический градиентный спуск с моментом, значения синаптических весов были выбраны из равномерного распределения	RMSProp [Tieleman, Hinton, 2012], для инициализации был использован метод нормализованной инициализации [Glorot, Bengio, 2010]

Результаты прогнозирования

Для апробации модели была выбрана область в южной части Норвегии, для которой были получены данные из космоснимков для 1198 точек. Эти данные использовались для получения прогноза от отобранных моделей. В результате исследований была определена модель, выдающая наиболее корректный прогноз по загрязнению, — регрессор градиентный бустинг. Результаты прогноза от наиболее адекватной модели представлены на рис. 2. Слева отображены реальные данные, справа — прогноз.

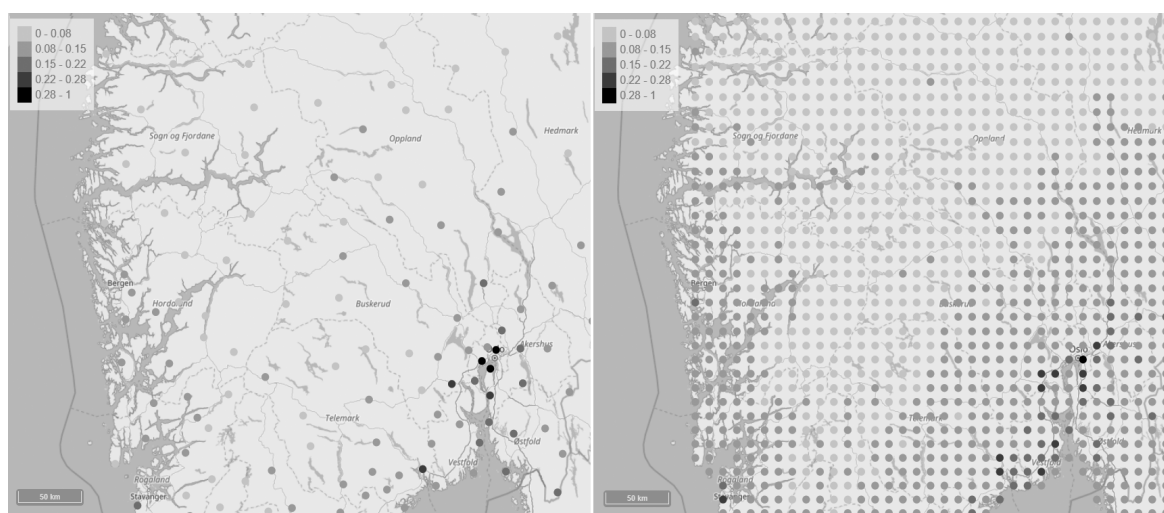


Рис. 2. Загрязнения сурьмой в Норвегии: слева — данные отбора проб, справа — прогноз модели

По изображению видно, что модель неплохо показывает общие тенденции. Существует возможность увеличить ее точность, если удастся подобрать индексы, у которых корреляция с загрязнением будет сильнее. Модель была апробирована и на северной части Норвегии. Данный регион интересен тем, что в нем промышленность (а не плотность населения) является ключевым фактором загрязнения сурьмой. В результате были получены схожие результаты: можно определить общие области загрязнения, но точность прогноза в конкретных точках невысокая.

Дальнейшие исследования будут направлены на апробацию подхода на других странах и элементах и разработку автоматизированных алгоритмов для поиска параметров с наибольшей связанностью. Кроме того, планируется использовать альтернативные источники космоснимков и извлечения из них статистических показателей для проверки точности данных, получаемых от Google Earth Engine.

Заключение

Существует принципиальная возможность прогнозирования концентраций тяжелых металлов на базе космоснимков, хотя набор элементов и областей, для которых возможно применение подобных методов, достаточно ограничен. Точность прогноза на данном этапе развития исследований недостаточно высока, но существуют предпосылки для ее увеличения. Реализация подобных инструментов значительно расширит возможности контроля загрязнения воздуха. Анализ состояния окружающей среды можно будет производить с высокой частотой и в некоторых случаях — не ограничиваясь границами отдельных стран и областей, что позволит своевременно обнаруживать новые источники загрязнений или отслеживать тенденции изменения в старых в периоды, когда отбор проб и анализ образцов не производятся.

Список литературы (References)

- Ужинский А., Ососков Г., Фронтасьева М. Управление данными мониторинга окружающей среды // Открытые системы. СУБД. — 2017. — № 4. — С. 42–43.
 Uzhinskiy A., Ososkov G., Frontasyeva M. Upravlenie dannymi monitoringa okruzhajushhej sredy [Environment monitoring data management] // Otkrytye sistemy, SUBD [Open System. DMS]. — 2017. — No. 4. — P. 42–43.
 Андреева А., Бузников А., Скрябин С., Тимофеев А., Алексеева-Попова Н., Беляева А. Исследование характера изменения оптических характеристик растительности под воздействием тяжелых металлов для разработки метода дистанционной диагностики загрязнения // Совре-

- менные проблемы дистанционного зондирования Земли из космоса. — 2007. — Вып. 4, Т. 2. — С. 175–182.
- Andreeva A., Buznikov A., Skryabin S., Timofeev A., Alekseeva-Popova N., Belyakova A.* Issledovanie haraktera izmeneniya opticheskikh harakteristik rastitel'nosti pod vozdeystviem tyazhelykh metallov dlya razrabotki metoda distancionnoj diagnostiki zagryazneniya [Research of nature of vegetation optical characteristics change under the influence of heavy metals for development of a remote contamination diagnostics method] // *Sovremennye problemy distancionnogo zondirovaniya Zemli iz kosmosa* [Current problems in remote sensing of the earth from space]. — 2007. — Iss. 4, Vol. 2. — P. 175–182.
- Alsabti K., Ranka S., Singh V.* An efficient k-means clustering algorithm // *Electrical Engineering and Computer Science*. — 1997. — Vol. 43.
- Alijagić J.* Application of multivariate statistical methods and artificial neural network for separation natural background and influence of mining and metallurgy activities on distribution of chemical elements in the Stavnja valley (Bosnia and Herzegovina) // PhD thesis. University of Nova Gorica. — 2013.
- Bergstra J. S., Rémi B., Yoshua B., Balázs K.* Algorithms for hyper-parameter optimization // *Advances in neural information processing systems*. — 2011. — P. 2546–2554.
- Friedman J. H.* Greedy function approximation: a gradient boosting machine // *Annals of statistics*. — 2001. — P. 1189–1232.
- Glorot X., Bengio X.* Understanding the difficulty of training deep feedforward neural networks // *Aistats*. — 2010. — Vol. 9. — P. 249–256.
- Harmens H., Mills G.* (eds.) Air Pollution: Deposition to and impacts on vegetation in (South-East Europe, Caucasus, Central Asia (EECCA/SEE) and South-East Asia // Report prepared by ICP Vegetation, March 2014. ICP Vegetation Programme Coordination Centre, Centre for Ecology and Hydrology, Bangor. UK. — 2014.
- Hastie T.* Trees Bagging Random Forests and Boosting. — Stanford University, 2003.
- Nair V., Hinton G.*, Rectified Linear Units Improve Restricted Boltzmann Machines // Proc. 27 th Int. Conference on Machine Learning, Eds J. Furnkranz and Th. Joachims, Haifa, Israel. — 2010. — P. 807–814.
- Nickel S., Hertel A., Pesch R., Schröder W., Steinnes E., Thelle Uggerud H.* Modelling and mapping spatio-temporal trends of heavy metal accumulation in moss and natural surface soil monitored 1990–2010 throughout Norway by multivariate generalized linear models and geostatistics. *Atmospheric Environment*. December 2014. — Vol. 99. — P. 85–93.
- Rees W. G.* Physical Principles of Remote Sensing. — Cambridge, UK: Cambridge University Press, 2001.
- Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R.* Dropout: A Simple Way to Prevent Neural Networks from Overfitting // *Journal of Machine Learning Research* 15. — 2014. — P. 1929–1958.
- Tieleman T., Hinton G.* Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude // COURSE: Neural networks for machine learning. — 2012. — Vol. 4, No. 2. — P. 26–31.
- ASTER L1T Radiance [Electronic resource]: https://explorer.earthengine.google.com/#detail/ASTER%2FAST_L1T_003 (accessed: 23.04.2018).
- Landsat 7 Collection 1 Tier 1 and Real-Time data Raw Scenes [Electronic resource]: https://explorer.earthengine.google.com/#detail/LANDSAT%2FLE07%2FC01%2FT1_RT (accessed: 23.04.2018).
- MCD43A4.006 MODIS Nadir BRDF-Adjusted Reflectance Daily 500m [Electronic resource]: <https://explorer.earthengine.google.com/#detail/MODIS%2F006%2FMCD43A4> (accessed: 23.04.2018).

- MOD11A2.006 Terra Land Surface Temperature and Emissivity 8-Day Global 1km [Electronic resource]: <https://explorer.earthengine.google.com/#detail/MODIS%2F006%2FMOD11A2> (accessed: 23.04.2018).
- PROBA-V C1 Top Of Canopy Daily Synthesis 333m [Electronic resource]: https://explorer.earthengine.google.com/#detail/VITO%2FPROBAV%2FC1%2FS1_TOC_333M (accessed: 23.04.2018).
- PROBA-V C0 Top Of Canopy Daily Synthesis at 100m resolution [Electronic resource]: https://explorer.earthengine.google.com/#detail/VITO%2FPROBAV%2FS1_TOC_100M (accessed: 23.04.2018).
- Sentinel-3 OLCI EFR Ocean and Land Color Instrument Earth Observation Full Resolution [Electronic resource]: <https://explorer.earthengine.google.com/#detail/COPERNICUS%2FS3%2FOLCI> (accessed: 23.04.2018).
- United Nations Economic Commission for Europe International Cooperative Programme on Effects of Air Pollution on Natural Vegetation and Crops [Electronic resource]: <http://icpvegetation.ceh.ac.uk/> (accessed: 23.04.2018).
- VIIRS Nighttime Day/Night Band Composites Version 1 [Electronic resource]: https://explorer.earthengine.google.com/#detail/NOAA%2FVIIRS%2FDNB%2FMONTHLY_V1%2FVCMCFG (accessed: 23.04.2018).