



Глубокое обучение в задачах дистанционного
зондирования атмосферы
с примерами детектирования
мезомасштабных конвективных систем

Михаил Криницкий

Лаборатория машинного обучения в науках о Земле МФТИ

Михаил Криницкий

К.Т.Н.


Лаборатория машинного обучения в науках о Земле МФТИ

Что мы делаем:


Разрабатываем, адаптируем, анализируем поведение алгоритмов машинного обучения и глубокого обучения в прикладных и фундаментальных задачах наук о Земле

krinitsky.ma@phystech.edu


<https://t.me/mkrinitskiy>



Фундаментальные исследования




Прикладные исследования




ИИ для обнаружения феноменов

Обнаружение мезомасштабных конвективных систем
в данных дистанционного зондирования Земли из космоса


$ch9$ ($10.8 \mu m$)



$ch5$ ($6.25 \mu m$)



$ch5 - ch9$





Meteosat (MSG4) data,
European territory of Russia

ИИ для обнаружения феноменов


АНОНС

Обнаружение мезомасштабных конвективных систем
в данных дистанционного зондирования Земли из космоса

$ch9$ ($10.8 \mu m$)




Глубокое обучение vs. машинное обучение



Глубокое обучение vs. машинное обучение

-  Порождение признаков – забота исследователя
-  Сложно применять «классические» методы МО на не- векторных данных
-  Сложно создать разметку в постановках задач для векторных данных

Глубокое обучение vs. машинное обучение



Глубокое обучение vs. машинное обучение



Модель выучивает признаки самостоятельно



Легко применять на не- векторных данных




**Существуют проработанные подходы
(архитектуры, методы обучения)
для пространственно распределенных данных**



Легче создавать разметку: интуитивно, удобно


Особенности атмосферных данных

- Данные скоррелированы во времени и пространстве
- Феномены – редкие события, высокое соотношение background/foreground
- Количество каналов обычно не 3
- Распределение признаков отличается от ImageNet




Нейросети для обнаружения феноменов?

- Правило: если человек видит/находит, то сможет и нейросеть, нужно только...
 - много данных 🤔
 - много разметки 😓
- Феномены – «выразительные» объекты, легко определяемые по форме и сочетанию характеристик 😊





Общая постановка задачи

- Признаки: $X(ch, lat, lon, t)$
- Цель: найти области, которые:
 - связны в пространстве
 - устойчивы во времени
 - физически осмысленны (отражают явление)



Семантическая сегментация

- Цель: каждому пикселю на карте присвоить класс принадлежности **области явления** / **фону**
- Для каждого пикселя решается задача классификации с использованием пространственного (+временного) контекста
- Архитектуры нейросетей:
U-Net, U-Net++, DeepLabv3(+), PSPNet
- Функции потерь:
cross-entropy, Dice loss, IoU loss...



Семантическая сегментация



😊 (при удачном решении) точные границы явления

😊 можно посчитать площади явлений, площади перекрытия на последовательных кадрах

😊 можно строить климатологию

😓 трудно обучать для тонких, вытянутых структур
😓 подбор функции потерь – искусство, сложно автоматизируется

😓 очень трудозатратная разметка



Обнаружение визуальных объектов (VOD)

- Цель: определить положение и размеры объектов, оценить вероятность быть явлением (x, y, w, h, p)


- порождается заранее избыточное количество меток; для каждой решается задача регрессии для (x, y, w, h) и классификации

- Архитектуры нейросетей:

RetinaNet, семейство YOLO, SSD, Faster R-CNN

- Функции потерь:

cross-entropy, focal loss | Smooth L1, IoU-based loss



Обнаружение визуальных объектов (VOD)



нет точных границ явлений



bbox не вполне отражает структуру явления – это компромисс



разметка интуитивная, быстрая, эргономичная




результаты можно использовать для анализа условий возникновения / эволюции



можно строить климатологию




подходит для построения траекторий




Другие постановки задачи

- **Сегментация различных экземпляров (Instance segmentation):** Mask R-CNN, YOLACT, *etc.*
- **Регрессия положения ключевых точек** (точек оси, точек графа скелета, *etc.*)
- **Обнаружение аномалий (патчей):** VAE, xGAN, *etc.*
- **Выучивание и кластеризация эмбеддингов патчей** (self-supervised learning): MoCo, SimCLR, *etc.*




Особенности ГО в задачах обнаружения

- Supervised- постановки требуют большого количества размеченных данных
 - разметку проводит эксперт, экспертов мало
 - разметка трудозатратна, данные – новое золото
- для Supervised- постановок: сильный дисбаланс классов фон/явления – существенная проблема



Оценка качества обнаружения явлений


- Метрики обнаружения:
Precision, Recall, F1-score, mAP,
FAR (false alarm ratio), TPR (true positive rate), IoU
- Метрики чувствительны
 - к выбору порогового значения по p
 - к виду явлений
 - к сезону...




*Нейросеть не обнаруживает явления точно,
не дает «истинный ответ»
Результаты следует обрабатывать статистически,
строить выводы на большом количестве примеров
с учетом уровня ошибок*

ПРИМЕР: MCS в данных METEOSAT



$ch9$ ($10.8 \mu m$) – T_{top}




$ch5$ ($6.25 \mu m$) - WV






$ch5 - ch9$



- **Мезомасштабные конвективные системы (МКС)** — крупные области организованной конвекции размером сотни километров и продолжительностью до суток
- В данных *Meteosat* проявляются как обширные **холодные облачные вершины** и характерные структуры.
- По своим пространственным и радиационным признакам хорошо поддаются автоматическому обнаружению методами глубокого обучения.



Разметка: GeoAnnotateAssisted



- Клиент–серверное приложение для аннотации спутниковых данных **GeoAnnotateAssisted**
- Преобразование и подготовка визуализации и данных на серверной стороне
- Разметка эллипсами осесимметричных MCS и ведение трекв в базе данных
- Интеграция экспертной разметки и (опционально) нейросетевых подсказок (предварительно обученной нейросети)


Разметка: база данных DaMesCoS-ETR

- DaMesCoS-ETR — Dataset of Mesoscale Convective Systems over the European Territory of Russia
- 205 треков, 2800 меток MCS, размеченных экспертами на снимках Meteosat
- Охват: 2012-2020 (летние месяцы)
- Различные типы MCS (МСС, суперячейки, кластеры)




Подготовка данных для нейросети

- Нормирование каналов ch5 и ch9 -> [0, 1] с инверсией шкалы (холодные облака становятся «яркими»)
- Нелинейное преобразование BTD для подчёркивания диапазона, важного для конвекции (**порождение признака...**)
- Формирование псевдо-RGB представления, приближённого к распределениям ImageNet
- Аугментации данных: аффинные преобразования, шум, диффеоморфные преобразования «на лету» на GPU




Модель: RetinaNet + ResNet

- Архитектура: RetinaNet как одностадийный детектор объектов
- Backbone: ResNet-152, предобученный на ImageNet
 - (transfer learning + fine tuning)
- Focal loss для задач классификации боксов и борьбы с дисбалансом классов фон/объект
- Регрессия координат: Smooth L1 / IoU-based loss для уточнения расположения, размеров MCS




ПРИМЕР: MCS в данных METEOSAT

- $mAP \approx 0.75$, $F1\text{-score} \approx 0.7$
- Recall / TPR порядка 0.6–0.7
- FAR порядка 0.3–0.4 (зависит от порога)
- Малый разрыв между f -й потерь на тренировочной и валидационной выборках



Плотность MCS на ЕТР

- Нейросетевой детектор применен к многолетнему архиву снимков Meteosat
- Оценена частота обнаружения MCS (попиксельно)



Заключение

- Глубокое обучение естественным образом подходит для анализа спутниковых данных с сложными пространственными паттернами
- Формулировка задачи (segmentation / VOD / др.) критически влияет на требования к данным и результат
- Для осесимметричных MCS постановка в виде VOD с RetinaNet и эллиптическими метками — практичный компромисс
- Оценка ошибок обязательна для интерпретации

Перспективы

- Переход от осесимметричных к квазилинейным MCS и более сложным геометриям объектов
- Использование self-supervised обучения/предобучения для снижения зависимости от разметки
- Интеграция дополнительных данных (реанализа) в состав признаков

Спасибо!

krinitsky.ma@phystech.edu

<https://t.me/mkrinitskiy>

