



ISSN 2071-2898 (Print)
ISSN 2071-2901 (Online)

**Басс Л.П., Кузьмина М.Г.,
Николаева О.В.**

Сверточные нейронные сети
с глубоким обучением в
задачах обработки
гиперспектральных
спутниковых данных

Рекомендуемая форма библиографической ссылки: Басс Л.П., Кузьмина М.Г., Николаева О.В. Сверточные нейронные сети с глубоким обучением в задачах обработки гиперспектральных спутниковых данных // Препринты ИПМ им. М.В.Келдыша. 2018. № 282. 32 с. doi:[10.20948/prepr-2018-282](https://doi.org/10.20948/prepr-2018-282)
URL: <http://library.keldysh.ru/preprint.asp?id=2018-282>

Ордена Ленина
ИНСТИТУТ ПРИКЛАДНОЙ МАТЕМАТИКИ
имени М.В.Келдыша
Российской академии наук

Л.П.Басс, М.Г.Кузьмина, О.В.Николаева

**Сверточные нейронные сети с глубоким
обучением в задачах обработки
гиперспектральных спутниковых данных**

Москва — 2018

Басс Л.П., Кузьмина М.Г., Николаева О.В.

Сверточные нейронные сети с глубоким обучением в задачах обработки гиперспектральных спутниковых данных

За последнее десятилетие глубокие сверточные нейронные сети (deep convolutional neural networks, DCNN) были успешно применены для обработки многопиксельных спутниковых изображений высокого разрешения, используемых при решении разнообразных задач восстановления характеристик земной атмосферы и поверхности Земли по данным дистанционного зондирования.

В работе дано представление о состоянии исследований по применению нейросетевых методов обработки гиперспектральных спутниковых изображений, включая краткие сведения об основных особенностях сверточных нейронных сетей (convolutional neural networks, CNN), глубоком обучении (deep learning, DL), сетях-автоэнкодерах (autoencoders, AE), используемых для сжатия информации.

К настоящему времени в Internet накоплено значительное число открытых для использования моделей сверточных нейронных сетей с глубоким обучением, позволяющих разрабатывать новые, усовершенствованные модели DCNN на основе уже созданных хорошо работающих типов этих сетей. Краткая информация о некоторых из этих моделей содержится в настоящей работе. Более подробную информацию о библиотеке открытых нейросетевых моделей и больших базах данных, необходимых для настройки DCNN, предполагается дать во второй части работы, публикация которой планируется.

Ключевые слова: гиперспектральное зондирование, сверточные нейронные сети

Leonid Petrovich Bass, Margarita Georgievna Kuzmina, Olga Vasilievna Nikolaeva

Deep convolutional neural networks in hyperspectral remote sensing data processing

During the last decade the deep convolutional neural networks (DCNN) were successfully applied in the fields related to processing of large satellite images of high resolution that are used in various inverse problems on retrieval of the earth atmosphere characteristics and the earth boundary reflectance via remote sensing data analysis.

The presented paper contains the information on the research state related to application of neural network methods to satellite hyper-spectral image processing, including brief information on the main features of convolutional neural networks (CNN), deep learning (DL) and autoencoders (AE) that are used for information compression.

Up to present time a considerable number of DCNN models created is located for open access in the Internet. These verified models with well performance allow to develop new advanced models of DCNN. A brief information on some Internet models of open access is contained in the present paper. A more detailed information on neural network models located in open Internet access, and also on large data sets that are necessary for DCNN tuning, will be contained in the second part of the present paper, that is planned to be published.

Key words: hyperspectral remote sensing, convolutional neural networks

Оглавление

1. Введение	5
1.1 Традиционные вычислительные методы анализа гиперспектральных изображений.....	7
1.2 Примеры задач дистанционного зондирования, в которых уместно применение нейросетевых подходов	12
2. Сверточные нейронные сети, принципы построения и достоинства.....	14
3. Сверточные нейронные сети с глубоким обучением.....	15
3.1 Иерархический характер обучения	15
3.2 Архитектуры глубоких сетей	16
3.3 Сети для сжатия информации	16
3.3.1 Сети-автоэнкодеры.....	16
3.3.2 Глубокие сети доверия.....	17
4. Примеры использования сетей DCNN в задачах обработки больших гиперспектральных спутниковых изображений высокого разрешения.....	17
4.1 Задачи классификации	17
4.2 Задачи поиска и распознавания объектов в изображениях	20
4.3 Задачи восстановления характеристик атмосферы и отражающих свойств подстилающей поверхности по гиперспектральным спутниковым данным ..	22
4.4 Построение дополнительных баз данных	23
5. Примеры моделей сетей DCNN, открытых для пользования в Internet.....	23
5.1 AlexNet.....	23
5.2 CaffeNet.....	24
5.3 VGGxNet	24
5.4 TensorFlow	25
5.5 Keras.....	25
Заключение.....	25
Библиографический список	26

1. Введение

Обработка спутниковых снимков позволяет выявлять многие важные характеристики земной поверхности, такие как: свойства минерального состава открытых горных пород, преобладающий видовой состав растительного покрова (и степени его нарушения), состав, состояние и влажность почвы, местоположения территорий с лесными пожарами, гарями, нелегальными вырубками. Кроме того, обработка спутниковых данных дает возможность определять газовый состав и степень аэрозольного загрязнения атмосферы, создавать карты температуры воздуха, земной поверхности и поверхности водных объектов.

Электромагнитный спектр (полный интервал всех длин волн электромагнитной радиации) варьирует от самых коротких волн (гамма и рентгеновское излучение) до самых длинных волн (микро- и радиоволны). Человеческий глаз видит мир лишь в небольшом интервале длин волн – в видимой области спектра (между длинами волн 0,4 и 0,7 μm). Дистанционное зондирование позволяет получать снимки земной поверхности практически во всех интервалах спектра, доступных съёмке (в тех участках спектра, которые не поглощаются атмосферой – в «атмосферными окнами» (atmospheric windows), рис. 1).




Рис. 1. Атмосферные окна

Каждым сенсором спутника съемка поверхности производится в спектральных каналах (spectral bands), каждый из которых имеет свой четко определенный интервал спектра. Число спектральных каналов и спектральный диапазон каждого канала разные у разных сенсоров. Пользователь получает столько отдельных сцен (файлов снимка), сколько спектральных каналов имеет данный сенсор. Сенсор спутника регистрирует отраженное и испущенное от земной поверхности излучение и сохраняет это измерение для каждого пикселя снимка в особых единицах, называемых "уровень серого" (или Digital Number, DN). Уровень серого для пикселя – это растянутое на заданное число ступеней значение цвета пикселя (от чисто черного (DN = 0) до чисто белого цвета (DN = 64)). Уровни серого снимков современных сенсоров делятся на 64, 256 и 65536

ступеней. Уровень серого каждого пикселя спутникового снимка отражает среднее значение энергии, отраженной и испущенной той частью поверхности земли, которая соответствует данному пикселю.

При выявлении характеристик земной поверхности ключевую роль играет спектральная кривая объекта, показывающая процент отраженного и испущенного объектом излучения на всем изучаемом интервале электромагнитного спектра. Дешифровка снимка и выявление характеристик объектов земной поверхности базируется на сравнении уже известных спектральных кривых (из собранных "библиотек спектральных кривых" для разных объектов земной поверхности) со спектральными кривыми каждого пикселя снимка.

Принцип распознавания объектов и выявления их характеристик по спутниковым снимкам основан на различии спектральных кривых (см. рис. 2, 3).

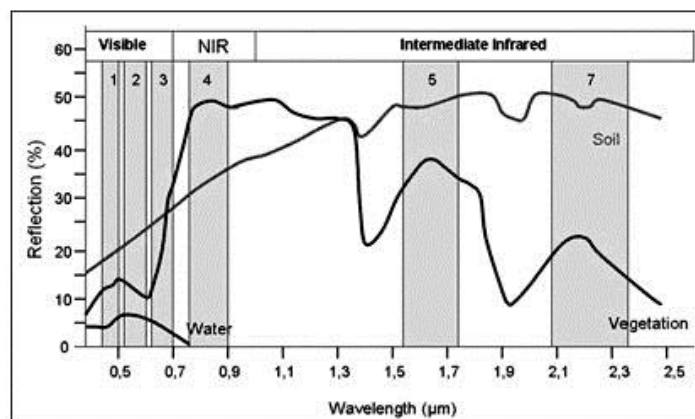


Рис. 2. Спектральные кривые растительности, почвы и воды

По стоимости спутниковые снимки делятся на коммерческие (платные) и открытого доступа (бесплатные), в зависимости от пространственного разрешения. Снимки со средним и малым разрешением (от 15 м до 1000 м) — продукт бесплатный. Их не так много: Landsat, MODIS, ASTER. Снимки с высоким и сверхвысоким разрешением (от 10 м до 0,3 м) — продукт коммерческий (GeoEye, WorldView, QuickBird, EROS, IKONOS, SPOT, RapidEye, и т.д.). Найти нужный снимок, скачать его или оформить заказ для бесплатного получения можно, например, на сайте <http://glovis.usgs.gov>.

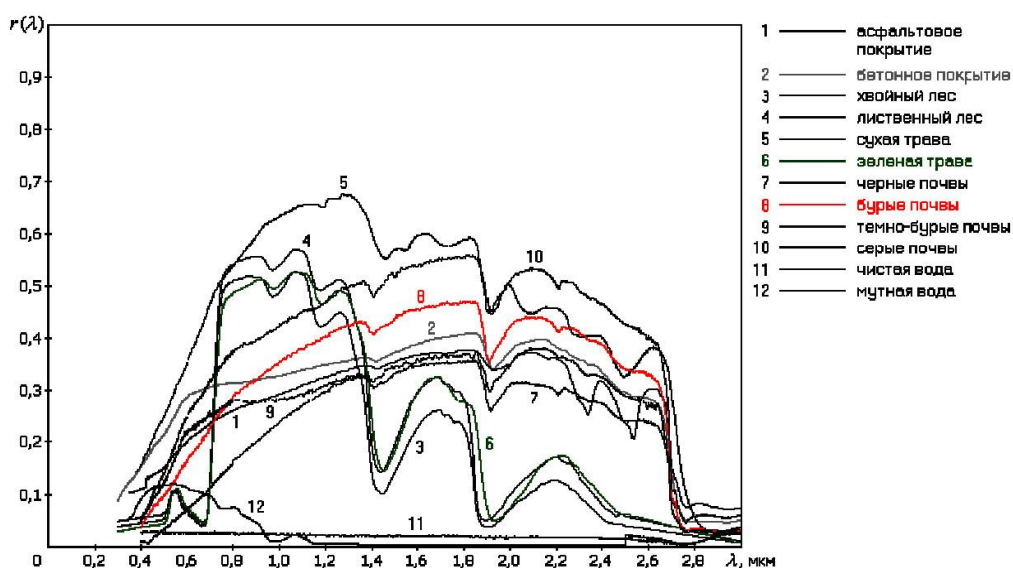


Рис. 3. Библиотечные спектры классов

1.1 Традиционные вычислительные методы анализа гиперспектральных изображений

Использование данных спутникового зондирования для исследования земной атмосферы и земной поверхности является важным средством мониторинга Земли.

Гиперспектральные спутниковые данные широко используются в задачах анализа атмосферных и ионосферных процессов, анализа климатических изменений, а также в разнообразных системах мониторинга (состояния и динамики лесных ресурсов Земли, растительных и ледяных покровов, состояния почв, свалок промышленных продуктов, пожарных режимов лесных экосистем, морских гидрофизических процессов и т.д.). Восстановление нужных характеристик атмосферы и земной поверхности как правило, требует решения обратных задач теории переноса излучения. При этом возникает необходимость развития качественных методов обработки гиперспектральных спутниковых изображений с высоким пространственным разрешением. Важное место в таких методах обработки занимает так называемая атмосферная коррекция – исключение влияния на результаты детектирования изображения эффектов, возникающих в результате многократного рассеяния света в земной атмосфере и поглощения его атмосферными газами и аэрозолями.

Трудности решения задач анализа гиперспектральных данных связаны с тремя обстоятельствами: 1) высокой размерностью измеренных данных, подлежащих обработке; 2) большим числом спектральных каналов; 3) сложным (сильно изменчивым) поведением спектральных кривых. Кроме того, при решении таких задач традиционными нейросетевыми методами (методами максимального правдоподобия, k - ближайших соседей, минимального расстояния, логистической регрессии, опорных векторов) обычно привлекаются

только спектральные характеристики спутниковых изображений. В то же время известно, что применение методов пространственно-спектральной классификации гиперспектральных изображений дает значительное улучшение качества классификации (J. Bioucas-Dias et al., 2013). Поэтому методы пространственно-спектральной классификации обработки гиперспектральных данных начали развиваться (см. например, (J. Li et al., 2013)).

В настоящее время существует обширный набор методов для атмосферной коррекции гиперспектральных спутниковых изображений, используемых в задачах ДЗЗ. Их можно разделить на три группы: эмпирические методы, методы моделирования процессов переноса излучения и гибридные методы (B. Gao et al., 2006). Первая группа методов использует упрощённые атмосферные модели, параметрически настраиваемые непосредственно по самому изображению. При таком подходе обычно устраняется только аддитивная составляющая регистрируемого излучения, что не приводит к получению истинных спектральных профилей изображения. Более точным оказывается так называемый «эмпирический линейный» метод, осуществляющий для конкретного спектрального канала линейное преобразование по прецедентам (которые задаются парами значений «коэффициент отражения поверхности» — «зарегистрированная спектральная яркость»).

Вторая группа методов использует физическую модель распространения излучения в атмосфере. Первый из таких алгоритмов (ATREM) был разработан в 1980-е годы и на протяжении последующих 20 лет претерпевал изменения в зависимости от способа моделирования рассеяния.

Третья группа методов сочетает в себе свойства двух предыдущих. При использовании методов второй и третьей группы требуется значительная информация о сцене, включающая в себя заранее известные спектральные профили территорий съёмки. Можно привести несколько примеров традиционных методов, продемонстрировавших качественную работу.

Так, в работе (C. Bassani et al., 2010) на основе применения теории переноса излучения в связанной системе атмосфера-земля для атмосферной коррекции гиперспектральных спутниковых данных был дан количественный анализ оптических характеристик атмосферы и характеристик отражения подстилающей поверхности. Кроме того, был предложен алгоритм восстановления оптической толщины аэрозольного слоя и отражательных характеристик поверхности в видимом и ближнем инфракрасном диапазонах.

Алгоритм восстановления аэрозоля (как над яркими, так и над темными участками земной поверхности, такими как пустыни и покрытые лесами регионы), демонстрирующий высокий уровень разрешения, был предложен в работе (A. Lyapustin et al., 2011). В алгоритме были использованы предварительно полученные LUT-таблицы для нескольких моделей аэрозоля и параметрическая формула для коэффициента отражения от верхней границы атмосферы. Были рассмотрены модели аэрозоля, содержащие комбинацию крупной и мелкой фракции.

В работе (Y. Knyazikhin et al., 2013) было изучено влияние свойств листовой структуры лесных деревьев на отражательные характеристики лесных покровов Земли, а также возможное влияние особенностей листовой структуры на характеристики лесных экосистем. Методы анализа основаны на решении прямых и обратных задач переноса излучения в системе атмосфера–земная поверхность, а также на решении 3D-задачи многократного рассеяния излучения внутри листа. Для анализа отражательных характеристик земных лесных покровов, восстанавливаемых по данным дистанционного зондирования, требуются оценки решения задачи переноса света во внутренности древесного листа. Помимо влияния формы и структуры листьев на их отражательные характеристики (альbedo листа), в ближней ИК области спектра имеется прямая корреляция между отражательными свойствами листвы и содержанием в листьях азота и углерода. Возможность восстановления содержания азота и углерода по данным ДЗЗ позволяет получить дополнительную информации о земном углеродном цикле, оказывающем влияние на климатические изменения. Поэтому представляется полезным специальный мониторинг состояния листвы в земных лесных массивах с использованием данных ДЗЗ. В работе найдены адекватные характеристики, удобные для детектирования различий отражающих свойств широколиственных и хвойных лесов и для определения содержания азота в листве – бинаправленный спектральный коэффициент отражения (BRF, bidirectional reflectance factor) и листовая массовая концентрация азота (foliar mass-based nitrogen concentration). Применяя эти характеристики в ближнем ИК диапазоне, отвечающем сильному поглощению света хлорофиллом, можно проанализировать особенности процесса рассеяния излучения в листве, оценить влияние различных факторов и, в частности, увидеть, в каких случаях интенсивность излучения, многократно рассеянного и отраженного внутренностью листа, оказывается сравнимой с интенсивностью отраженного от поверхности листа излучения. Это позволяет вычислять содержание азота в листве с различной внутренней структурой и различать лесные массивы с богатым и бедным содержанием азота в листве. Как показывает BRF-анализ, учет многократного рассеяния и отражения внутри листа дает существенную поправку к отражательным характеристикам лесных массивов в диапазоне 710 – 790 nm. Построен ряд характерных спектральных кривых. Были проанализированы ДЗЗ-данные по шести лесным покровам в различных районах США, полученные NASA AVIRIS (2002-2003 гг.) для 224 спектральных интервалов. При решении задачи восстановления коэффициента отражения лесных покровов по ДЗЗ-данным привлекался метод регуляризации Тихонова. Был использован стандартный метод атмосферной коррекции ДЗЗ-данных, развитый в работе (M.E. Martin et al., 2008).

В работе (M.B. Тарасенков и др., 2014) решается задача восстановления оптических параметров атмосферы по измеренным спутниковым данным и восстановления коэффициента ламбертова поверхностного отражения

(поверхность предполагается однородной в пределах пикселя) и переотражения (в пределах радиуса). В качестве падающего излучения используется солнечная дымка (солнечное излучение, рассеянное атмосферой и не взаимодействующее с земной поверхностью). Учитывается боковой подсвет (в пределах определенного радиуса). Используются формула для солнечной дымки и расчеты методом Монте-Карло. Для коэффициента отражения получена система нелинейных уравнений. Для анализа был выбран участок поверхности (на западном побережье Африки), часть которого занимает пустынная территория, а остальная часть – море. Оптическая модель атмосферы выбиралась из множества континентальных тропических моделей безоблачного неба. Проведенные серии расчетов показали, что развитый алгоритм позволяет восстановить коэффициент отражения с достаточной точностью (коэффициент корреляции с расчетами, проведенными по двум стандартным алгоритмам NASA, был равен 0.984 и 0.999).

В работе (А.Ю. Денисова и др., 2016) был развит метод атмосферной коррекции гиперспектральных изображений, состоящий из двух этапов. На первом этапе по обрабатываемому изображению определяются параметры атмосферных искажений в рамках известной модели (модель спектральной смеси). Используя эти две модели одновременно, оцениваются параметры атмосферных искажений только по самому изображению и верифицированным данным малого объема (неискаженных спектральных профилей определенных материалов, которые могут появляться в различных их линейных комбинациях на регистрируемом изображении). Таким образом, метод может быть использован для идентификации модели атмосферных искажений и их последующего устранения. При этом для описания процессов переноса используется стандартное уравнение переноса излучения в нелинейной форме (Y. Xu et al., 2008). В результате атмосферной коррекции возможно восстановление информации об истинной отражательной способности элементов поверхности по спектральной яркости (реконструкция коэффициента отражения). Решение задачи достигается решением оптимизационной задачи с использованием градиентного метода. Метод обладает значительной вычислительной сложностью. Предложен вариант ускоренного метода. Экспериментальные исследования были проведены в среде MATLAB для набора синтезированных гиперспектральных изображений (вычисляемых в виде линейных комбинаций известных смесей, взятых со случайными коэффициентами, и генерировании атмосферных искажений). Метод продемонстрировал высокое качество оценивания параметров атмосферных искажений и устойчивость к шуму.

Одним из точных и эффективных методов определения газового состава атмосферы на основе анализа гиперспектральных изображений является известный метод DOAS (Differential Optical Absorption Spectroscopy), основанный на использовании формулы, выражающей интенсивность излучения определенной длины волны в нерассеивающей, чисто поглощающей

среде через сечение поглощения $\sigma_a(\lambda)$ для этой длины волны, длину L пройденного в среде расстояния и плотность n поглощающего газа (формула Ламберта-Бэра):

$$I(\lambda) = I_0(\lambda)e^{-\sigma_a(\lambda)nL} \equiv I_0(\lambda)e^{-\tau_\lambda}, \quad (1)$$

безразмерная величина $\tau_\lambda = \sigma_a(\lambda)nL$ есть длина оптического пути, пройденного излучением.

В качестве успешного применения DOAS-метода можно отметить явный эффективный алгоритм коррекции влияния поглощения света в атмосферных газах на поведение спектральных кривых гиперспектральных изображений, получаемых при дистанционном спутниковом зондировании (О.В. Николаева, 2018). Алгоритм основан на анализе спектральной зависимости коэффициента яркости отраженного в зенит излучения, многократно рассеянного системой атмосфера–подстилающая поверхность и состоит в получении корректирующего множителя, на который домножается коэффициент яркости. При этом не требуется предварительного задания оптических параметров аэрозоля, предположений о подстилающей поверхности и общем содержании газов. Требуется лишь учет высотной зависимости коэффициента поглощения (используется ее зонная аппроксимация).

При построении метода коррекции используется полуэмпирическое выражение для коэффициента яркости, построенное с использованием формулы Ламберта-Бэра. Оценки для решений уравнения переноса излучения получаются на основе привлечения принципов максимума и минимума для уравнения переноса со спектральной (энергетической) зависимостью (Т.А. Гермогенова, 1986). Параметры модельного коэффициента яркости находятся из условия его наименьшего отклонения от измеренного коэффициента (с использованием явного метода наименьших квадратов). Достоинством развитого метода коррекции является тот факт, что он является явным и поэтому экономичным. Метод исключает из коэффициента яркости минимумы, связанные с газовым поглощением. Таким образом, результатом коррекции является коэффициент яркости для атмосферы, из которой удалён поглощающий газ.

Тестирование метода было проведено для спектрального интервала [752, 770] нм, где существенно поглощение света в кислороде. Использовались модельные задачи с близкими к реальным параметрами (альбедо поверхности, набором спектральных каналов, моделью стандартной атмосферы для задания зависимости давления и температуры от высоты). Как было показано, даже при грубом разбиении атмосферы на четыре высотные зоны максимальная погрешность восстановления не превышает 1 %. В работе (О.В. Николаева, 2018) было также отмечено, что развитый метод коррекции может быть далее последовательно применен для дальнейшего определения оптических

параметров атмосферного аэрозоля и последующего нахождения альbedo поверхности, в то время как другие алгоритмы выполняют коррекцию всех атмосферных искажений (и газового поглощения, и аэрозольного и рэлеевского рассеяния) одновременно.

Следует также отметить, что существуют традиционные алгоритмы анализа гиперспектральных спутниковых данных, слабо чувствительные к высокой размерности входных данных. Сюда прежде всего относится известный плодотворный метод SVM (support vector machine), часто применяемый в задачах классификации. Метод SVM также относится к методам, не страдающим от так называемого явления Hughes phenomenon (ситуация, когда точность классификации сначала постепенно возрастает с увеличением числа используемых спектральных интервалов, а затем резко падает при достижении числом интервалов некоторого значения). Поэтому метод SVM широко используется в задачах обработки гиперспектральных изображений, так как обеспечивает лучшую точность по сравнению со многими методами распознавания образов (Zhuo et al., 2008).

1.2 Примеры задач дистанционного зондирования, в которых уместно применение нейросетевых подходов

Для обработки больших массивов гиперспектральных спутниковых данных наряду с развитым арсеналом традиционных вычислительных методов в настоящее время все чаще применяются нейросетевые подходы с использованием сверточных нейронных сетей (CNN, convolutional neural networks) и глубокого обучения (DL, deep learning). Можно даже сказать, что анализ гиперспектральных спутниковых данных методами глубоких сверточных сетей является важной новой подобластью применения нейросетевых подходов.

Привлечение сверточных нейронных сетей с глубоким обучением к задачам гиперспектрального дистанционного зондирования позволяет извлечь важную дополнительную информацию глобального характера (high level hierarchical abstract features) из гиперспектральных данных (Y. Chen et al., 2014; 2015; Z. Zhen et al., 2014 a). Дополнительное использование многослойных сетей-автоэнкодеров (SAE, stacked autoencoder network), позволяющих осуществлять сжатие данных в сочетании с включением совместной пространственно-спектральной информации в изображениях, нередко позволяет получить более точное решение обратных задач дистанционного зондирования по гиперспектральным спутниковым данным, задач классификации гиперспектральных изображений, задач распознавания образов и детектирования объектов в изображениях. Теория глубокого обучения дополняет обычные методы машинного обучения специальными алгоритмами, предоставляющими возможность анализа входной информации на нескольких уровнях представления. Можно сказать, что глубокое обучение способствует более всестороннему изучению предмета, выявляя скрытые взаимосвязи и

корреляции признаков. Это оказывается особенно важным в ситуациях, когда еще не найдено адекватных информационных уровней представления данных.

В задачах классификации гиперспектральных изображений адекватными оказались так называемые сети глубокого доверия (deep belief networks, DBN), позволяющие извлекать иерархически организованную абстрактную информацию из гиперспектральных данных в спектральной области (Y. Chen et al., 2015). В частности, были развиты методы (и построены соответствующие модели DCNN-сетей), позволяющие выбирать для решения задач дистанционного зондирования наиболее информативные участки спектра (A. Santara et al., 2017). На этой основе был также построен пример самоконтролируемого алгоритма классификации (P. Ghamisi et al., 2016), а также модели так называемых сверточно-несверточных сетей невязки (fully residual conv-deconv networks), использующих обучение с привлечением пространственно-спектральных характеристик изображения (L. Mou et al., 2017, а)). Наконец, большой интерес представляет построение моделей DCNN-сетей с неконтролируемым обучением, использующих накопленные базы данных (collections of labeled data) (A. Romero et al., 2016; L. Mou et al., 2017 b), c)).

В настоящее время модели сетей DCNN успешно развиваются и применяются в разнообразных задачах гиперспектрального дистанционного зондирования (см., например, (P. Vincent et al., 2010; W. Hu et al., 2015)). В частности, уже многими способами удалось включить в работу нейросетевых алгоритмов пространственно-спектральную информацию, извлекаемую из гиперспектральных изображений (K. Makantasis et al., 2015; N. Kussul et al., 2017; W. Zhao et al., 2016). Были также предложены новые модели пространственно-модифицируемых сетей-автоэнкодеров и построены модели так называемых полностью сверточных сетей (fully convolutional networks, FCN), отличающиеся особенно качественной работой в задачах семантической сегментации гиперспектральных изображений (J. Long et al., 2015).

Особого внимания заслуживают нейробиологически-мотивированные методы анализа изображений высокого разрешения, имитирующие процессы обработки информации, осуществляемые зрительной корой мозга при восприятии изображений зрительной системой мозга. Именно к такому типу нейросетевых подходов относятся методы, связанные с привлечением сетей глубоких архитектур с иерархическими типами машинного обучения. Перспективными представляются также сетевые подходы, основанные на принципах работы самоорганизующихся многоагентных систем (multi-agent systems, MAS).

В целом можно сказать, что применение методов DCNN в задачах обработки больших гиперспектральных данных можно считать одной из наиболее активных ветвей исследований в области дистанционного зондирования Земли. Использование нейросетевых методов с глубоким обучением позволяет также поставить новые вопросы, связанные с анализом больших гиперспектральных изображений высокого разрешения.

2. Сверточные нейронные сети, принципы построения и достоинства

Сверточные нейронные сети (convolutional neural networks – CNN) относятся к нейронным сетям третьего поколения. Они были инициированы после появления биологически мотивированной модели нейронной сети “Neocognitron”, созданной К. Фукушимой в 1980 году для задач трансляционно-инвариантной обработки изображений (К. Fukushima, 1980) (Рис. 4). При добавлении принципов глубокого обучения CNN приобрели большую популярность при решении разнообразных задач в области компьютерного зрения (А. Krizhevsky et al., 2012; К. Simonyan et al., 2015; К. Jia et al., 2014; М.Д. Zeiler et al., 2014; С. Szegedy et al., 2015).

Сети CNN типичной архитектуры представляют собой многоступенчатый каскад сетей прямого распространения. Основные типы слоев для CNN: несколько **сверточных слоев**, слоев объединения (pooling) и слоев сетей прямого распространения с обучением.

Выходной слой сверточной сети представляет карту признаков: каждый элемент выходного слоя получен применением операции свертки между входным слоем и конечной подобластью (рецептивным полем) с применением определенного фильтра (ядра) и последующим действием нелинейной функции активации. Слои пулинга выполняют операцию понижения уровня дискретизации (downsampling operation) для карты признаков (часто — посредством вычисления максимума в пределах некоторой конечной области).




Рис. 4. Неокогнитрон К. Фукушимы (Fukushima К., 1980).

В многокаскадной сети после каскада сверточных слоев и слоев пулинга (stacked convolutional and pooling layers) обычно следует несколько полносвязных слоев (fully-connected layers, FL). Таким образом, многокаскадная CNN преобразует матрицу пиксельных значений входного изображения в матрицу окончательных признаков методом сети прямого распространения (a feedforward manner). Параметры CNN (веса связей сверточных и полносвязных

слоев сети) как правило настраиваются применением метода обратного распространения ошибки (backpropagation, BP), реализуемого посредством классического градиентного спуска (stochastic gradient descent).

3. Сверточные нейронные сети с глубоким обучением

Сверточные сети с глубоким обучением (deep convolutional neural networks – DCNN) продемонстрировали большие возможности в решении задач обработки больших изображений высокого разрешения (в частности, в решении задач классификации таких изображений) благодаря двум особенностям:

- DCNN обладают большими возможностями обучения (большой емкостью сети);
- DCNN позволяют использовать накопленные базы данных (что позволяет компенсировать отсутствие тех данных, которыми в конкретной задаче не располагают).

Для ускорения процесса обучения в DCNN часто используется в качестве функции активации сетевого нейрона нелинейная функция ReLU.

Обучение больших сетей DCNN (например, для таких сетей, как ImageNet), нередко содержащих миллионы параметров, является нелегкой задачей. Нужны достаточно большие базы данных. Тогда DCNN могут быть использованы в широком круге задач компьютерного зрения, таких как классификация зрительных сцен, детектирование образов (фрагментов изображения), семантическая сегментация изображений, распознавание образов, восстановление изображений.

3.1 Иерархический характер обучения

В отличие методов обучения классических сетей 80–90-х годов (сетей второго поколения) новые парадигмы обучения позволили избавиться от ряда проблем, которые сдерживали успешное применение традиционных нейронных сетей. Сети, обученные с помощью алгоритмов глубокого обучения, часто превосходят по точности лучшие альтернативные подходы. Наиболее успешные современные методы анализа больших систем данных, разработанные в областях компьютерного зрения и распознавания речи, построены на основе использования глубоких сетей. В настоящее время такие фирмы, как Apple, Google, Facebook, привлекают коллективы исследователей, занимающихся глубокими нейросетями.

Глубокое обучение представляет собой иерархически организованное обучение каскада нейронных сетей, состоящего из более чем трех сетевых слоев различного типа (том числе отличающихся функциями активации нейронов). При этом каскад может содержать некоторое число скрытых слоев. Идея глубокого обучения была предложена Хинтоном в 2006 г. (G.E. Hinton et al., 2006). Цель глубокого обучения – выявление глобальных (инвариантных относительно естественных геометрических преобразований типа трансляций и вращений) характеристик изображения (deep features).

На первом этапе производится неконтролируемое обучение сети (последующее контролируемое обучение без учителя, *unsupervised training*). Затем производится последующее контролируемое обучение с учителем (*supervised tuning*) с помощью некоторой обучающей выборки. Так организованные глубокие нейросетевые модели позволяют извлекать все более абстрактные характеристики изображения, инвариантные относительно локальных вариаций исходного анализируемого изображения.

3.2 Архитектуры глубоких сетей

К настоящему времени разработано несколько архитектур DCNN для решения задач обработки гиперспектральных изображений. К числу сетей часто используемых архитектур относятся: обычные многослойные сверточные сети (*multilayer convolutional neural networks, CNN*); сети глубокого доверия (*deep belief networks, DBN*) (G.E Hinton et al., 2006); глубокие машины Больцмана (*deep Boltzmann machines, DBM*) (R. Salakhutdinov et al., 2009); каскады сетей-автоэнкодеров (*stacked autoencoders, SAE*) (Y. Bengio et al., 2007); сети, называемые ограниченными машинами Больцмана (*restricted Boltzmann machines, RBM*) (G.E Hinton et al., 2010).

3.3 Сети для сжатия информации

3.3.1 Сети-автоэнкодеры

Автоэнкодер — нейросеть специальной архитектуры, позволяющая применять обучение без учителя при использовании метода обратного распространения ошибки (*back propagation, BP*). Простейшая архитектура автоэнкодера — сеть прямого распространения, без обратных связей, наиболее сходная с многослойным перцептроном (*MLP*), содержащая входной слой, скрытый промежуточный слой и выходной слой. Выходной слой содержит столько же нейронов, сколько и входной слой. Задача автоэнкодера — получить выходной вектор наиболее близким к входному (Рис. 5). Это позволяет прежде всего осуществить сжатие данных при передаче вектора входного сигнала на выход сети. Функционирование автоэнкодера напоминает действие метода главных компонент (*PCA*) в том смысле, что понижается размерность входных данных. При этом автоэнкодер осуществляет алгоритм компрессии и декомпрессии данных без потерь.




Рис. 5. Сеть автоэнкодер (autoencoder)




Рис. 6. Каскад автоэнкодеров (stacked autoencoder)

Метод работы автоэнкодера может быть и более эффективным, чем метод PCA. Как правило, сети-автоэнкодеры применяют каскадно. При этом из входных данных извлекаются все более обобщенные информационные признаки. Каскады автоэнкодеров известны как SAE (stacked autoencoders) (Рис. 6).

3.3.2 Глубокие сети доверия

В последнее десятилетие нашли успешное применение глубокие сети доверия (deep belief networks, DBN), содержащие несколько связанных между собой скрытых слоев при несвязанных нейронах внутри каждого скрытого слоя. Эти сети демонстрируют хорошую работу не только в задачах классификации, но и в задачах сегментации изображений, а также в задачах, где требуется уменьшение размерности, поиск информации, моделирование движения.

4. Примеры использования сетей DCNN в задачах обработки больших гиперспектральных спутниковых изображений высокого разрешения

4.1 Задачи классификации

Решение задач классификации является наиболее популярной темой в множестве задач гиперспектрального дистанционного зондирования. В течение последних двадцати лет здесь был предложен целый ряд методов классификации, демонстрирующих высокую точность. В частности, были разработаны методы, включающие сжатие информации с помощью многослойных сетей-автоэнкодеров (SAE), работающих на основе модифицированного метода главных компонент (PCA), и методы привлечения пространственно-спектральной информации. Это привело к повышению точности классификации. Кроме того, сочетание использования глубоких сверточных сетей, сетей-автоэнкодеров с модифицированным PCA и

оперирования совместной пространственно-спектральной информацией оказалось плодотворным при решении разнообразных задач извлечения глобальных (абстрактных) признаков (high-level features) анализируемых гиперспектральных изображений. Приведем некоторые примеры.

Один из алгоритмов, содержащий такое сочетание средств, был опробован в задаче анализа смешанного растительного покрова в двух областях земной поверхности – в районах Kennedy Space Center (KSC), FL, USA и в окрестности города Павия (Pavia, Italy) (Y. Chen et al., 2014). В первом случае гиперспектральное изображение содержало 512×614 пикселей с разрешением 18 метров, 176 спектральных интервалов и 13 классов растительности. Во втором случае это было 610×340 -пиксельное изображение, содержащее 115 спектральных интервалов. Обучающая выборка содержала 3100 примеров, и для обучения АЕ-сети была использована графическая карта NVIDIA GT750M. Потребовалось 5000 эпох для предварительного обучения сети и 50000 эпох для окончательного обучения (время обучения не превышало 233 секунд). Как оказалось, метод классификации, основанный на использовании АЕ- и SAE-сетей, работает гораздо быстрее других алгоритмов классификации (в частности, сравнение производилось с различными модификациями SVM-метода). В работе (Y. Chen et al., 2014) для классификации гиперспектральных изображений были построены SAE-сети, содержащие 4–6 скрытых слоев с числом 20–60 нейронов в слое. При этом были испытаны подходы с использованием спектрально-доминирующей и пространственно-доминирующей пространственно-спектральной информации (последний продемонстрировал более высокое качество классификации). Было показано, что метод, основанный на использовании глубокой SAE-сети для извлечения абстрактных глобальных характеристик изображения, доставляет большую точность классификации и более эффективен по сравнению с такими методами, как метод SVM, метод логистической регрессии, метод главных компонент (PCA), метод факторизации неотрицательной матрицы (nonnegative matrix factorization, NMF).

Метод классификации гиперспектральных изображений, основанный на построении пятислойной глубокой CNN-сети с использованием чисто спектральной информации был предложен в работе (F. Hu et al., 2015). Сеть содержала входной слой, сверточный слой, слой пулинга (max pooling), полносвязный слой и выходной слой. Модель была испытана на гиперспектральных данных для трех реальных областей (размеры областей — 512×217 и 610×340 пикселей, пространственное разрешение — 20m, 220 спектральных каналов в видимой и инфракрасной областях спектра, 9 и 16 классов). Сравнение результатов CNN-классификации с результатами, полученными методом SVM, показало, что точность классификации CNN-методом превышает точность SVM-классификации в среднем примерно на 2%. (Точность CNN-классификации достигает более 90%). Были также испытаны DCNN-сети других архитектур (в том числе LeNet-5, представляющая из себя

сеть классической CNN-архитектуры с двумя сверточными слоями и DCNN-сеть с тремя скрытыми полносвязными слоями). Приведены результаты сравнения работы разных сетевых методов, показывающие, что точность классификации колеблется от 86,5% до 90,16% (последняя точность относится к упомянутой модели пятислойной DCNN-сети). Отмечено, что эффективность DCNN-метода можно повысить (путем снижения времени настройки), если использовать такие сети, как Caffe (Y. Jia et al., 2014). Полученные результаты показывают, что DCNN-методы вполне могут демонстрировать точную и эффективную работу в задачах классификации гиперспектральных изображений (даже в случае DCNN-сетей с небольшим числом слоев). Отмечается, что привлечение пространственно-спектральной информации также может привести к улучшению метода.

Сравнению DCNN-методов решения задач классификации гиперспектральных изображений высокого разрешения с традиционными методами посвящена большая серия работ (см., например (J. Yue et al., 2015; 2016; W. Hu et al., 2015; P. Zhong et al., 2017; T. Postadjiana et al., 2017; B. Liu et al., 2018)). При подходящем выборе сетевой архитектуры DCNN-методы, как правило, демонстрируют более высокую точность классификации.

Сети DCNN, настраиваемые на больших базах данных (HRRS scene datasets), были использованы также в задачах сегментации зрительных сцен высокого разрешения (F. Hu et al., 2015). При этом были внесены надлежащие изменения в архитектуру как сверточных, так и полносвязанных слоев DCNN, повышающие эффективность их работы. Были также предложены два различных сценария извлечения глобальных характеристик изображения, в результате чего удалось достигнуть точности классификации 98.64% - 96.90%.

Подходы, развиваемые в этом классе задач, могут оказаться полезными при решении задач восстановления характеристик атмосферы и подстилающей земной поверхности по гиперспектральным спутниковым данным.

Наконец, можно отметить интересный пример использования сетей DCNN в задаче классификации сортов пшеницы по денситограммам (Г.А. Ососков и др., 2017). Денситограмма – одномерное изображение (полоса электрофореграммы после оцифровки), состоящее примерно из 4000 пикселей, позволяющее по спектру определить соответствующий ему белок (рис. 7). При использовании сетей MLP (многослойных перцептронов), настраиваемых путем обучения методом ВР (back propagation) для классификации 50 сортов (размер обучающей выборки составляет 3225 денситограмм), требуется настройка более чем 10^6 параметров сети. Поэтому возникает необходимость в существенном сокращении объема входных данных с сохранением наиболее важной информации. Использованные ранее подходы (огрубление спектра, Фурье-анализ, вейвлет анализ, метод главных компонент) давали сокращение данных на порядок, одновременно приводя к слишком низкой эффективности классификации.




Рис. 7. Спектр денситограммы (белка пшеницы)

Используя для сжатия данных глубокую сеть в виде пятислойного автоэнкодера, осуществляющую сжатие информации нелинейным методом главных компонент (модифицированным усовершенствованным методом М. Крамера), удалось после сжатия изображения (без потерь) до 64 основных признаков (в *bottle-neck* слое) точно восстановить его в выходном слое. После дальнейших усовершенствований автоэнкодера (связанные веса, стохастический градиентный спуск, оптимизация ADAM) общее число параметров автоэнкодера составило 315 (т.е. на 5 порядков меньше, чем было необходимо для многослойного персептрона (MLP)). Затем была применена сеть DNN для классификации. Использование Internet-сервиса FloydHub (<http://cs231n.github.io/convolutional-networks/>) с применением TensorFlow и Keras дало для времени обучения DNN-сети 84 сек.

4.2 Задачи поиска и распознавания объектов в изображениях

Задачи поиска и распознавания объектов на изображениях актуальны как в области мониторинга и анализа снимков дистанционного зондирования Земли, так и для анализа аэрофотоснимков. Для решения этих задач использовались различные алгоритмы – от простой пороговой бинаризации до применения гистограмм направленных градиентов. Нейросетевые алгоритмы также получили распространение для решения этих задач. Часто задачи поиска объектов заданного типа, распознавания объектов и классификации объектов на изображении оказываются связанными, особенно в случае поиска нескольких типов объектов.

Так, в работе (А. Смирнов et al., 2017) CNN-метод был успешно использован для нахождения различных видов самолётов, находящихся на территории аэропорта. Было показано, что полученная информация после постобработки может быть использована в задачах мониторинга взлётно-посадочных полос (например, для отслеживания перемещения самолётов или подсчёта их количества). Сеть CNN содержала 13 слоев и обучалась на выборке, состоящей из четырех классов (дороги, растительность, городские застройки и самолеты). Общее количество изображений для обучающей

выборки составило около 5000. Размер каждого изображения (при необходимости) преобразовывался в 32x32 пикселя. Количество эпох обучения составило 5000 (при ошибке обучения 0,2%). Для выделения объектов использовался метод гистограмм (для получения гистограмм изображение сканировалось скользящими масками). Как было отмечено, задача поиска объектов разного масштаба продолжает оставаться трудной, и поэтому пришлось разработать метод адаптивного изменения порога (подается на вход нейронной сети несколько изображений, профильтрованных масками разного размера).

К задачам распознавания объектов в изображении можно отнести задачу семантической сегментации изображений - задачу выделения в изображении локальных областей (сегментов), соответствующих различным классам объектов. Сегментация спутниковых изображений требуется в целом ряде областей: автоматическое создание карт местности, анализ георесурсов, градостроительство, анализ землепользования и т.д. Хотя существует целый ряд алгоритмов и методов классификации объектов на изображениях, актуальной является задача разработки методов и программных средств, позволяющих автоматизировать этот процесс и повысить эффективность его работы. Как было выяснено, нейросетевые алгоритмы с использованием именно сверточных сетей обладают такими важными преимуществами, как устойчивость к искажению входных данных, эффективность классификации, не слишком большое число настраиваемых параметров. Поэтому несколько CNN-алгоритмов для семантической сегментации цветных спутниковых изображений было разработано в работе (А.А. Друки et al., 2018). Было построено и испытано несколько CNN разной архитектуры, и выбор остановлен на шестислойной сети, содержащей 3 сверточных слоя, 1 подвыборочный слой и 2 полносвязных слоя, подробно описанной в (А.А. Друки et al., 2018). Настройка сети производилась методом BP с использованием нескольких алгоритмов оптимизации, включая Nesterov accelerated gradient, AdaGrad (Adaptive gradient) и ADAM (adaptive moment estimation). Для обучения и тестирования разработанной CNN использовалась база данных, состоящая из нескольких тысяч спутниковых снимков штата Массачусетс (США). Размер каждого изображений 1500x1500 пикселей с разрешением $1m^2$ на пиксель. Для избежания проблемы переобучения был реализован метод DropOut. Была реализована также регуляризация нейросети. В результате разработанный CNN-метод обеспечил точность сегментации 85,31%.

Возможности DCNN-сетевого подхода в задаче построения семантически сегментированных карт арктической растительности высокого разрешения по гиперспектральным спутниковым данным исследованы в работе (Z.L. Langford et al., 2017). Карты строились для областей западного побережья Аляски, содержащих тундровые и покрытые лесами области. При анализе результатов были использованы аляскинские базы растительных данных (SPOT-5. PALSAR,

и IfSAR); для настройки сетей – существующие аляскинские карты растительного покрова (AKEVT и UCVM). Построенная глубокая DCNN-сеть (содержащая сверточные слои, слои пулинга и полносвязные слои) позволила иерархическим образом вырабатывать из входных спутниковых изображений эффективные обобщенные признаки для семантической классификации. При этом были использованы сети-автоэнкодеры для неконтролируемого сжатия данных. Был также использован кусочный принцип обработки входных изображений (с разделением на фрагменты, содержащие 9, 36 и 144 пикселей). В результате удалось достигнуть точности семантической сегментации 66%—96%. Было отмечено, что для улучшения результатов (увеличения точности семантической сегментации арктического растительного покрова) требуются более детальные гиперспектральные базы данных. При работе были использованы нейросетевые модели открытого доступа (Keras и TensorFlow).

Как известно, точно работающие «очень глубокие» DCNN-сети требуют длительной настройки (большого времени для обучения). С этим связаны большие временные затраты и целый ряд других трудностей. Одним из путей преодоления длительности обучения в задачах распознавания образов и семантической сегментации оказался метод так называемого глубокого остаточного обучения (deep residual learning), предложенный в (К. He et al., 2010; 2016). Метод позволил повысить точность семантической сегментации изображений в среднем на 4–8%.

4.3 Задачи восстановления характеристик атмосферы и отражающих свойств подстилающей поверхности по гиперспектральным спутниковым данным

Анализ гиперспектральных спутниковых данных очень важен для многих прикладных задач. К числу важных приложений относится сегментация и классификация территорий земной поверхности, которая часто называется классификацией сцены (scene classification).

Как правило, эта задача выполняется в два этапа: выделение особенностей (семантическая сегментация, feature extraction) и классификация. Первый этап является особенно важным. Классификация включает детектирование объектов сцены (object detection), распознавание образов (image retrieval) и реконструкцию зрительной сцены (scene reconstruction). При этом особый интерес представляют методы автоматической сегментации изображения, которые возможно построить, применяя нейросетевой подход, основанный на использовании предварительно настроенных DCNN-сетей.

Задача восстановления характеристик атмосферы по данным удаленного зондирования тесно связана с задачей восстановления характеристик подстилающей земной поверхности и решается на основе применения теории переноса многократно рассеянного излучения в связанной системе атмосфера–земная поверхность. Так, в работе (С. Bassani, et al., 2010) развит алгоритм восстановления оптической толщины атмосферного аэрозоля по данным

гиперспектрального аэрозондирования в видимой и ближней ИК областях спектра и одновременного восстановления альbedo отражения подстилающей поверхности (для каждого пикселя изображения).

В работе (R.K. Gangwar et al., 2014) построен нейросетевой метод восстановления температурного профиля атмосферы на основе использования полученного нелинейного соотношения между температурой атмосферы и яркостной температурой спутника. Восстановление атмосферного температурного профиля рассматривалось как решение некорректно поставленной нелинейной обратной задачи. Для задачи с использованием нейросетевого подхода требуется подходящая база данных для настройки искусственной нейронной сети. Была использована база данных, накопленная в научном центре National Center for Environmental Prediction (NCEP) для трех географических областей в течение нескольких месяцев 2014 года. Алгоритм был далее тестирован на независимо созданной в AMSU-A базе данных. Кроме того, точность алгоритма анализировалась путем сравнения с температурными профилями, полученными в NCEP. Намечены пути усовершенствования метода.

4.4 Построение дополнительных баз данных

В тех случаях, когда имеющиеся в Internet базы данных оказываются слишком малыми и поэтому недостаточными для достижения нужной точности решения изучаемой задачи классификации, можно использовать так называемый one-shot подход, основанный на применении комбинации двух идентичных нейронных сетей (сетей-близнецов, siamese neural network) (K. Simonyan et al., 2013; R. Kotikalapudi, 2017; G. Ososkov et al., 2017).

Сеть близнецов состоит из пары идентичных сетей, соединенных слоем подобия, и имеет энергетический слой на выходе. Веса сетей-близнецов связаны (с целью обеспечения того результата, что почти тождественные образы должны быть близки в пространстве состояний).

Развивая принципы получения баз данных, инициированные в (K. Simonyan et al., 2013), в работе (G. Ososkov et al., 2017) удалось, отправляясь от множества, содержащего 31 изображение, построить базу данных, содержащую 1860 пар изображений.

5. Примеры моделей сетей DCNN, открытых для пользования в Internet

Можно отметить примеры часто используемых моделей DCNN, продемонстрировавших успешную работу.

5.1 AlexNet

Модель сети AlexNet разработана А. Крижевским (A. Krizhevsky et al., 2012). Используется для обработки больших изображений высокого разрешения. Состоит из пяти сверточных слоев. За первым, вторым и пятым сверточными слоями следуют слои пулинга, а затем – три полносвязных слоя (Рис. 8).

В качестве функции активации сетевого нейрона используется нелинейная функция $f(x) = \max(0, x)$ (известная как ReLU, rectified linear unit) вместо обычной нелинейной функции с насыщением ($f(x) = \tanh(x)$ или $f(x) = 1/(1 + e^{-x})$) для ускорения процесса обучения. Используется также операция разреживания сетевых связей (dropout).




Рис. 8. Схема сети AlexNet

5.2 CaffeNet

Сеть CaffeNet (Convolutional Architecture for Fast Feature Embedding) имеет архитектуру, сходную с архитектурой AlexNet, с двумя модификациями: 1) в процессе обучения не используется dropout; 2) использован другой порядок сверточных слоев и слоев пулинга. При обучении на базе данных ILSVRC-2012 качество работы CaffeNet близко к качеству работы AlexNet.

5.3 VGGxNet

На основе опыта CaffeNet были разработаны три модели глубоких CNN-сетей, позволившие улучшить либо скорость, либо точность работы сети CaffeNet (Chatfield K. et al., 2014). Были созданы следующие три модели VGGNet:

1) VGG-F (быстрая VGG-сеть). Отличается от CaffeNet тем, что требует меньшего числа фильтров и меньшим числом шагов в сверточных слоях.

2) VGG-M (VGG-сеть со средней скоростью работы). Разработана в (Zeiler M.D. et al., 2014). Характеризуется меньшим числом шагов в сверточных слоях, меньшим размером первого пулинг-слоя, а также малым числом фильтров для четвертого сверточного слоя. Это ускоряет работу сети.

3) VGG-S (медленная VGG-сеть). Разработана в (Sermanet P. et al., 2014). Использует малое число шагов во втором сверточном слое и большой размер первого и пятого пулинг-слоев.

Разработаны также VGG-VD Networks - модели очень глубоких VGG-сетей, позволившие получить высокоточные результаты в задачах распознавания образов в зрительных сценах и задачах классификации.

5.4 TensorFlow

TensorFlow — библиотека ПО (open source) для вычислений с использованием графов потоков данных (узлы графа — математические операции, ребра — многомерные массивы данных). В TensorFlow доступны параллельные вычисления на GPU после инсталляции необходимых драйверов и настройки специальных параметров. (Для установки GPU версии нужно добавить постфикс «gpu»: `pip3 install --upgrade tensorflow-gpu`).

5.5 Keras

Keras – Python Deep Learning библиотека, предоставляющая высокоуровневый API, использующий TensorFlow в качестве backend.

Заключение

В настоящее время многие задачи восстановления характеристик атмосферы и подстилающей земной поверхности на основе анализа гиперспектральных спутниковых данных решаются нейросетевыми методами с использованием сверточных нейронных сетей с глубоким обучением (DCNN-сетей, deep convolutional neural networks). В тех случаях, когда для настройки DCNN-сетей удастся использовать достаточно большие базы накопленных данных в качестве обучающей выборки, нейросетевые методы обеспечивают высокую точность решения таких задач, как классификация гиперспектральных изображений, сегментация изображений, распознавание образов, поиск и выделение объектов в изображениях, восстановление характеристик областей земной поверхности, восстановление температурного профиля атмосферы и др. Многие из этих задач тесно связаны с обратными задачами теории переноса излучения, на основе которых решаются задачи восстановления характеристик атмосферы и земной поверхности давно разработанными традиционными вычислительными методами. К достоинствам DCNN-методов относится тот факт, что помимо решения перечисленных типов задач они позволяют попутно иерархически выработать нужные в каждом конкретном случае глобальные абстрактные характеристики анализируемого изображения (high-level features). Кроме того, разработанные модели глубоких сетей автоэнкодеров, позволяют осуществлять сжатие информации (без потерь), эквивалентное (а иногда и более эффективное) тому, что предоставляет классический метод главных компонент (principal component analysis, PCA). Наконец, весьма привлекательной является возможность автоматического способа получения многих результатов, который могут предоставить нейросетевые подходы.

По этим причинам получение представления о состоянии исследований в области применения глубоких сверточных сетей к решению характерных задач

восстановления, связанных с обработкой больших гиперспектральных спутниковых изображений высокого разрешения, кажется актуальным.

Библиографический список

(C. Bassani. et al., 2010) C. Bassani, R. M. Cavalli, and S. Pignatti. Aerosol Optical Retrieval and Surface Reflectance from Airborne Remote Sensing Data over Land. *Sensors (Basel)* 10(7): 6421–6438, 2010. DOI: [10.3390/s100706421](https://doi.org/10.3390/s100706421) PMID: [22163558](https://pubmed.ncbi.nlm.nih.gov/22163558/)

(Y. Bengio et al., 2007). Y. Bengio., P. Lamblin, D. Popovici, and H. Larochelle. Greedy layer-wise training of deep networks, in *Proc. Neural Inf. Process. Syst.*, Cambridge, MA, USA, pp. 153–160, 2007.

(J. Bioucas-Dias et al., 2013) J. Bioucas-Dias et al., Hyperspectral remote sensing data analysis and future challenges, *Geosci. Remote Sens. Mag.*, v. 1, n. 2, pp. 6–36, 2013.

(K. Chatfield et al., 2014). K. Chatfield, K. Simonyan, A. Vedaldi, A. Zisserman. Return of the Devil in the Details: Delving Deep into Convolutional Nets. In *Proceedings of the British Machine Vision Conference*, Nottingham, UK, 1–5, September 2014.

(Y. Chen et al., 2014) Y. Chen, Z. Lin, X. Zhao, G. Wang, and Y. Gu, Deep learning-based classification of hyperspectral data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 7, n. 6, pp. 2094–2107, 2014.

(Y. Chen et al., 2015) Y. Chen, X. Zhao, and X. Jia, Spectra-spatial classification of hyperspectral data based on deep belief network, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 6, pp. 2381–2392, 2015.

(K. Fukushima, 1980). K. Fukushima. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol. Cybern.* v. 36, no. 4, pp. 193–202, 1980.

(R. K. Gangwar et al., 2014). R. K. Gangwar, A. K. Mathur, B. S. Gohil, and Sujit Basu. Neural network based retrieval of atmospheric temperature profile using AMSU-A observations, *International Journal of Atmospheric Sciences*, vol. 2014, Article ID 763060, 8 pages
<http://dx.doi.org/10.1155/2014/763060>

(P. Ghamisi et al., 2016) P. Ghamisi, Y. Chen, and X. Zhu, A self-improving convolution neural network for the classification of hyperspectral data, *IEEE Geoscience and Remote Sensing Letters*, v. 13, n. 10, pp. 1537–1541, 2016.

(K. He et al., 2010) K. He, X. Zhang, S. Ren, and J. Sun, Deep residual learning for image recognition, Open Access version, Computer Vision Foundation, 2010.
<http://image-net.org/challenges/LSVRC/2015> ;
<http://mscoco.org/dataset/#detections-challenge2015>

(K. He et al., 2016) K. He, X. Zhang, S. Ren, and J. Sun, Deep residual learning for image recognition, *IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.

(G. Hinton et al., 2006 a) G. Hinton, and R. Salakhutdinov., Reducing the dimensionality of data with neural networks, *Science*, vol. 313. no. 5786, pp. 504–507, 2006.

(G. Hinton et al., 2006 b) G. E. Hinton, S. Osindero, and Y. Teh, A fast learning algorithm for deep belief nets, *Neural Computation*, vol. 18, no. 7, pp. 1527–1554, 2006.

(G. Hinton et al., 2010). G. Hinton et al., A practical guide to training restricted Boltzmann machines, Dept. Comput. Sci., Univ. Toronto, Toronto, ON, Canada, Tech. Rep. UTML TR2010-003, 2010.

(W. Hu et al., 2015) W. Hu, Y. Huang, L. Wei, F. Zhang, and H. Li, Deep convolutional neural networks for hyperspectral image classification, *Journal of Sensors*, v. 2015, n. 258619, 2015. <http://dx.doi.org/10.1155/2015/258619>

(F. Hu et al., 2015). Fan Hu , Gui-Song Xia, Jingwen Hu and Liangpei Zhang. Transferring Deep Convolutional Neural Networks for the Scene Classification of High-Resolution Remote Sensing Imagery. *Remote Sens.* 2015, 7(11), 14680-14707; DOI :[10.3390/rs71114680](https://doi.org/10.3390/rs71114680)

(Y. Jia et al., 2014). Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, T. Darrell, Caffe: Convolutional Architecture for Fast Feature Embedding. In *Proceedings of the ACM International Conference on Multimedia*, Orlando, FL, USA, 3–7 November 2014.

(Y. Knyazikhin et al., 2013) Y. Knyazikhin, M.A. Schull, P. Stenberg, M. Möttus, M. Rautiainen, Y. Yang, A. Marshak, P. L. Carmona, R.K. Kaufmann, P. Lewis, M. I. Disney, V. Vanderbilth, A.B. Davis, F. Baret, S. Jacquemoud, A. Lyapustin, and

R.B. Myneni. Hyperspectral remote sensing of foliar nitrogen Content. Proc. of National Academy of Sciences, 110, E185-E192, 2013.

(R. Kotikalapudi, 2017) R. Kotikalapudi, contributors (2017). keras-vis, 2017.

(A. Krizhevsky et al., 2012). A. Krizhevsky, I. Sutskever, and G. Hinton, Imagenet classification with deep convolutional neural networks, Advances in Neural Information Processing Systems (NIPS), Lake Tahoe, NV, USA, 3–8 December 2012; pp. 1097–1105.

(N. Kussul et al., 2017) N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov, Deep learning classification of land cover and crop types using remote sensing data, IEEE Geoscience and Remote Sensing Letters, DOI:10.1109/LGRS. 2017. 2681128.

(Z.L. Langford et al., 2017). Z. L. Langford, J. Kumar, and F.M. Hoffman. Convolutional Neural Network Approach for Mapping Arctic Vegetation using Multi-Sensor Remote Sensing Fusion. IEEE International Conference on Data Mining Workshops, 2017. DOI 10.1109/ICDMW.2017.48

(J. Li. et al., 2013). J. Li, J.M Bioucas-Dias, and A. Plaza. Spectral-spatial classification of hyperspectral data using loopy belief propagation and active learning, IEEE Trans. Geosci. Remote Sens., vol. 51, no. 2, pp. 844–856, Feb. 2013.

(B. Liu et al., 2018). Bing Liu; Xuchu Yu; Anzhu Yu; Gang Wan. Deep convolutional recurrent neural network with transfer learning for hyperspectral image classification, J. of Applied Remote Sensing, 12(2), 2018.
<https://doi.org/10.1117/1.JRS.12.026028>

(J. Long et al., 2015) J. Long, E. Shelhamer, and T. Darrell, Fully convolutional networks for semantic segmentation, IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 2015.

(A. Lyapustin et al., 2011) A. Lyapustin, Y. Wang, L. Laszlo, R. Kahn, Korkin, L. Remer, R. Levy, and J. S. Reid. Multiangle implementation of atmospheric correction (MAIAC): 2. Aerosol algorithm. JOURNAL OF GEOPHYS. RESEARCH, v. 116, D03211, 2011.
[DOI:10.1029/2010JD014986](https://doi.org/10.1029/2010JD014986), 2011

(K. Makantasis et al., 2015) K. Makantasis, K. Karantzalos, A. Doulamis, and N. Doulamis, Deep supervised learning for hyperspectral data classification through convolutional neural networks, IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2015.

(M.E. Martin et al., 2008) M.E. Martin, L.C. Plourde, S.V. Ollinger, M.L. Smith, B.E. McNeil. A generalizable method for remote sensing of canopy nitrogen across a wide range of forest ecosystems. *Remote Sens Environ* 112(9):3511–3519, 2008.

(L. Mou et al., 2017, a)) L. Mou, P. Ghamisi, and X. X. Zhu, Fully conv-deconv network for unsupervised spectral-spatial feature extraction of hyperspectral imagery via residual learning, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2017.

(L. Mou et al., 2017 b)) L. Mou, P. Ghamisi, and X. Zhu, Unsupervised spectral-spatial feature learning via deep residual conv-deconv network for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, in press.

(L. Mou et al., 2017 c)) L. Mou, P. Ghamisi, and X. Zhu, Deep recurrent neural networks for hyperspectral image classification,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 7, pp. 3639–3655, 2017.

(G. Ososkov et al., 2017) G. Ososkov, P. Goncharov. Shallow and deep learning for image classification. *Opt. Mem. Neural Netw.* 26(4), 221–248, 2017.

(A. Plaza et al., 2009). Plaza A, Plaza J., and Martin G, Incorporation of spatial constraints into spectral mixture analysis of remotely sensed hyperspectral data,” in *Proc. IEEE Int. Workshop Mach. Learn. Signal Process.*, Grenoble, France, 2009, pp. 1–6.

(T. Postadjiana et al., 2017). T. Postadjiana, A. Le Brisa, H. Sahbib, C. Malleta. Investigating the potential of deep neural networks for large-scale classification of very high resolution satellite images. *Remote Sensing and Spatial Information Sciences*, Volume IV-1/W1, pp. 183 – 190, 2017.

(Z. Qu et al., 2003). Z. Qu, B. Kindel, A.F.H. Goetz. The high accuracy atmospheric correction for hyperspectral data (HATCH) model, *IEEE Transaction on Geoscience and Remote Sensing*. v. 41, n. 6, pp. 1223-1231, 2003. DOI: [10.1109/TGRS.2003.813125](https://doi.org/10.1109/TGRS.2003.813125).

(A. Romero et al., 2016) A. Romero, C. Gatta, and G. Camps-Valls, Unsupervised deep feature extraction for remote sensing image classification, *IEEE Transactions on Geoscience and Remote Sensing*, v. 54, n. 3, pp. 1349–1362, 2016.

(V.V. Rozanov et al., 2010). V.V. Rozanov, A.V. Rozanov. Differential optical absorption spectroscopy (DOAS) and air mass factor concept for a multiply scattering vertically inhomogeneous medium: theoretical consideration. *Atmospheric Measurement Techniques*, v.3? pp. 751– 780, 2010. DOI: [10.5194/amt-3-751-2010](https://doi.org/10.5194/amt-3-751-2010).

- (R. Salakhutdinov et al., 2009). R. Salakhutdinov, and G.E. Hinton. Deep Boltzmann machines, in Proc. Int. Conf. Artif. Intell. Statist., Clearwater Beach, FL, USA, pp. 448–455, 2009.
- (A. Santara et al., 2017) A. Santara, K. Mani, P. Hatwar, A. Singh, A. Garg, K. Padia, and P. Mitra, Bass net: Band-adaptive spectral-spatial feature learning neural network for hyperspectral image classification, IEEE Transactions on Geoscience and Remote Sensing, v. 55, n. 9, pp. 5293–5301, 2017.
- (P. Sermanet et al., 2014). P. Sermanet, D. Eigen, X. Zhang, M. Mathieu, R. Fergus, Y. LeCun. OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks. In Proceedings of the International Conference on Learning Representations. CBLIS, Banff, AL, Canada, 14–16, April 2014.
- (K. Simonyan et al., 2013) K. Simonyan, A. Vedaldi, A. Zisserman, Deep inside convolutional networks: visualizing image classification models and saliency maps. arXiv preprint arXiv:1312.6034, 2013.
- (K. Simonyan et al., 2015). K. Simonyan, A. Zisserman. Very deep convolutional networks for large-scale image recognition. In Proceedings of the International Conference on Learning Representations (ICLR), San Diego, CA, USA, 7–9 May 2015.
- (C. Szegedy et al., 2015) C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich. Going deeper with convolutions. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA, 7–12 June 2015; pp. 1–9.
- (P. Vincent et al., 2010) P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P. Manzagol, Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion, Journal of Machine Learning Research, vol. 11, pp. 3371–3408, 2010.
- (Y. Xu et al., 2008) Y. Xu, R. Wang, S. Liu, S. Yang, B. Yan. Atmospheric correction of hyperspectral data using MODTRAN model, Proceedings of SPIE. vol. 7123. 2008.
DOI: 10.1117/12.815552.
- (J. Yue et al., 2015). Jun Yue, Wenzhi Zhao, Shanjun Mao & Hui Liu, Spectral-spatial classification of hyperspectral images using deep convolutional neural networks. Remote Sensing Letters, v. 6, pp. 468-477, 2015.

(J.Yue et al., 2016). Jun Yue, Shanjun Mao & Mei Li. A deep learning framework for hyperspectral image classification using spatial pyramid pooling. *Remote Sensing Letters*, v. 7, pp. 875-884, 2016.

(M.D. Zeiler et al., 2014) M.D. Zeiler, R. Fergus. Visualizing and understanding convolutional networks. In *Proceedings of the European Conference on Computer Vision*, Zurich, Switzerland, 6–12 September 2014; pp. 818–833.

(W. Zhao et al., 2016) W. Zhao and S. Du, Spectral-spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach, *IEEE Transactions on Geoscience and Remote Sensing*, v. 54, n. 8, pp. 4544–4554, 2016.

(Z. Zhen et al., 2014 a). Z. Zhen, and G. Wang. Learning discriminative hierarchical features for object recognition, *IEEE Signal Process. Lett.*, vol. 21, no. 9, pp. 1159–1163, 2014.

(P. Zhong et al., 2017). Ping Zhong, Zhiqiang Gong. A Hybrid DBN and CRF Model for Spectral-Spatial Classification of Hyperspectral Images. *Stat., Optim. Inf. Comput.*, v. 5, pp 75–98. 2017.

(Т.А. Гермогенова, 1986). Т.А. Гермогенова, Локальные свойства решений уравнения переноса, М.: Наука, 1986. – 272 с.

(А.Ю. Денисова и др., 2016) А.Ю. Денисова, В.В. Мясников. Атмосферная коррекция гиперспектральных изображений с использованием малого объёма верифицированных данных // *Компьютерная оптика*, т. 40, № 4, С. 526-534, 2016. DOI: [10.18287/2412-6179-2016](https://doi.org/10.18287/2412-6179-2016).

(А.А. Друки et al., 2018) А.А. Друки, В.Г. Спицын, Ю.А. Болотова, А.А. Башлыков, Семантическая сегментация данных дистанционного зондирования Земли при помощи нейросетевых алгоритмов // *Известия Томского политехнического университета. Инжиниринг георесурсов*. т. 329. № 1. 59–68, 2018.

(О.В. Николаева, 2018). О.В. Николаева, Алгоритм коррекции влияния поглощения света в атмосферных газах на гиперспектральные данные дистанционного зондирования // *Компьютерная оптика*, 2018, том 42, №2, 2018. DOI: [10.18287/2412-6179-2018-42-2-328-337](https://doi.org/10.18287/2412-6179-2018-42-2-328-337).

(Г.А. Ососков и др., 2017). Г.А.Ососков, П.В. Гончаров, А.В. Цитринов. Применение глубоких нейронных сетей для классификации изображений. 19 Международная научно-техническая конференция «Нейроинформатика-2017», 2-6 окт. 2017, НИЯУ МИФИ, Москва.

(А.В. Смирнов et al., 2017) А.В. Смирнов, Е.С. Иванов. Использование механизма сверточных нейронных сетей для поиска объектов на аэрофотоснимках // Программные системы: теория и приложения, том 8, выпуск 4, 85–99, 2017. DOI:
<https://doi.org/10.25209/2079-3316-2017-8-4-85-99>.

(М.В. Тарасенков и др., 2014) М.В.Тарасенков, И.И.Белов. Комплекс программ восстановления отражательных свойств земной поверхности в видимом и УФ-диапазонах // Оптика атм. и океана, т. 27, №7, 2014.