

Наибольшее количество ошибок возникало на участках, соответствующих границе задымления, а также в случае значительного рассеивания дыма.

На рисунке 2 приведен пример участка исходного изображения и соответствующей разметки классов.

На рисунке 3 изображены степени принадлежности точек участка сегментированного изображения классам. Для сравнения приведены размеченные экспертом классы.

Заключение. Для обработки спутниковых снимков предложены и реализованы с использованием библиотеки Keras (в качестве бэкенда использовалась библиотека Tensorflow) семантические сегментаторы. Предложенные сегментаторы построены по архитектурам SegNet и U-Net и обучены на двух классах: «нормальная поверхность» и «пожар». При использовании предложенных сегментаторов удалось достичь точности 92–93 %. При этом наибольшее количество ошибок возникает при рассеивании задымления.

Дальнейшие исследования предполагают использования transfer learning на базе обученных сетей архитектур VGG и ResNet для снижения количества ошибок в проблемных областях.

Работа выполнена при поддержке БРФФИ (проект №Ф18В-005) и ГКНТ Республики Беларусь (проект №Ф18ПШГ-008П).

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Использование космических снимков в тепловом инфракрасном диапазоне для географических исследований [Электронный документ]. – Режим доступа : http://www.geogr.msu.ru/cafedra/karta/materials/heat_img/files/2/pozhary.htm. – Дата доступа : 12.01.2020.
2. Карпов, А. А. Технологии определения природных пожаров с использованием данных спутниковой съемки / А. А. Карпов, Р. А. Алешко, К. В. Шошина // Молодой ученый. – 2015. – № 13(1) – С. 17–19.

3. СКАНЭКС – мониторинг природных пожаров, карта пожаров [Электронный ресурс]. – Режим доступа : <https://fires.ru/help.html>. – Дата доступа : 12.01.2020.
4. Early Forest Fire Detection and Verification using Optical Smoke, Gas and Microwave Sensors / Wolfgang Krüll, Robert Tobera, Ingolf Willms, Helmut Essen, Noravon Wahl // Procedia Engineering. – 2012. – Vol. 45. – P. 584–594.
5. Mahmoud, Mubarak A. I. Forest Fire Detection Using a Rule-Based Image Processing Algorithm and Temporal Variation / Mubarak A. I. Mahmoud, Honge Ren // Mathematical Problems in Engineering. – 2018. – Vol. 2018. – 8 p.
6. Detection and Monitoring of Forest Fires Using Himawari-8 Geostationary Satellite Data in South Korea / Eunna Jang, Yoojin Kang, Jung-ho Im, Dong-Won Lee, Jongmin Yoon, Sang-Kyun Kim // Remote Sens. – 2019. – Vol. 11(3). – 25 p.
7. Zhang, Q. Deep Convolutional Neural Networks for Forest Fire Detection / Qingjie Zhang, Jiaolong Xu, Liang Xu, Haifeng Guo // Proc. of International Forum on Management, Education and Information Technology Application. – 2016.
8. Zhao, Y. Saliency Detection and Deep Learning-Based Wildfire Identification in UAV Imagery / Yi Zhao, Jiale Ma, Xiaohui Li, Jie Zhang // Sensors (Basel). – 2018. – Vol. 18(3). – 19 p.
9. Goodfellow, I. Deep learning / I. Goodfellow, Y. Bengio, A. Courville // The MIT Press. – 2016. – 800 p.
10. Николенко, С. Глубокое обучение / С. Николенко, А. Кадурич, Е. Архангельская – СПб. : Питер, 2018. – 480 с.
11. Tensorflow API documentation [Электронный ресурс]. – Режим доступа : https://www.tensorflow.org/api_docs/python/tf/nn/softmax_cross_entropy_with_logits_v2. – Дата доступа : 28.09.2018.
12. Sokolova, M. Beyond accuracy, F-score and ROC: a family of discriminant measures for performance evaluation / Marina Sokolova, Nathalie Japkowicz, Stan Szpakowicz // Advances in Artificial Intelligence, 19th Australian Joint Conference on Artificial Intelligence. – 2006. – Hobart, Australia, December 4-8, 2006. – P. 1015–1021.

26.02.2020

GANCHENKO V. V., DOUDKIN A. A. Semantic segmentation in tasks of fire detection on data of remote sensing of the earth

In this paper, we consider problem of detection of fires according to data of remote sensing of the Earth's surface of various spatial resolutions. As a basis for detection, semantic segmentation is used. This segmentation approach is based on convolutional neural networks. The results of two neural network architectures based on SegNet and U-Net are compared.

004.89

.

Введение. В настоящее время нейронные сети широко применяются для решения различного рода прикладных задач. При этом наиболее сложным этапом нейросетевой обработки данных является процесс обучения сети [1, 2]. Несмотря на достигнутые в данном направлении результаты, проблема обучения по-прежнему является актуальной [3].

Существуют два основных подхода к обучению нейронных сетей. Один базируется на методологии градиентного спуска, а другой – на случайном поиске. Наиболее популярными являются градиентные методы, которые на практике обучают нейронные сети за приемлемое время [4]. Представители другого подхода – методы отжига – обеспечивают хорошее качество, но работают существенно медленнее [5].

В работе изучаются возможности метода отжига для обучения глубокой доверительной сети на примере решения задачи сжатия цветных изображений.

1. Анализ проблемы. Глубокие доверительные сети использу-

ются для решения целого ряда прикладных задач, таких как медицинская диагностика, распознавание образов, обработка изображений, выделение семантически значимых признаков и т. д. [6].

Опишем архитектуру глубокой доверительной сети. Для этого вначале надо описать архитектуру ограниченной машины Больцмана, так как любая глубокая доверительная сеть всегда содержит слои данного типа машины.

Известно, что в основе ограниченной машины Больцмана лежит стохастический нейрон.

Формально ее можно представить полносвязным двудольным графом $G=(X, U)$,

$$\begin{cases} X = X_1 \cup X_2, X_1 \cap X_2 = \emptyset \\ U = \{u = (x_1, x_2) \mid \forall x_1 \in X_1, \forall x_2 \in X_2\}, \end{cases} \quad (1)$$

где X – множество вершин – стохастических нейронов, U – множество

Краснопрошин Виктор Владимирович, д. т. н., профессор, зав. кафедрой информационных систем управления Белорусского государственного университета.

Мацкевич Вадим Владимирович, магистрант кафедры информационных систем управления Белорусского государственного университета.

Беларусь, БГУ, 220050, г. Минск, пр. Независимости, 4.

ребер – синаптических связей, при этом вершины подмножества X_1 – задают нейроны входного слоя, а X_2 – нейроны выходного слоя.

Число нейронов во входном слое определяется размером входного образа, а количество нейронов в выходном слое определяется исходя из требований к степени сжатия данных.

Выходные сигналы слоев ограниченной машины Больцмана реализуют некоторые законы вероятностного распределения. В зависимости от используемых законов распределения строят различные типы машин. В данной работе речь пойдет о машинах типа Гаусс-Бернулли и Бернулли-Бернулли, т. к. они являются наиболее распространенными.

Для ограниченной машины Больцмана типа Гаусс-Бернулли каждой вершине входного слоя поставим в соответствие множества параметров $VB=\{b\}$ – смещения и $\sigma = \{ \}$ – дисперсии вершин, а вершинам выходного слоя – множества параметров $HB=\{g\}$ – смещение вершин. Размеры множеств равны соответственно

$$|VB| = |\sigma| = |X_1|, |HB| = |X_2| \quad (2)$$

Каждому ребру, связывающему пару вершин входного и выходного слоев, поставим в соответствие множество параметров $W=\{w\}$ – весов ребер.

Размер множества равен следующей величине

$$|W| = |X_1| \cdot |X_2| \quad (3)$$

Таким образом, описанное семейство нейронных сетей можно задать четырьмя типами параметров:

$$RBM = (W, VB, \sigma, HB) \quad (4)$$

Замечание. У ограниченной машины Больцмана типа Бернулли-Бернулли отсутствует множество параметров σ .

Глубокая доверительная сеть содержит несколько слоев, состоящих из ограниченных машин Больцмана, и, дополнительно, для генерации выходного сигнала может содержать многослойный персептрон (в зависимости от решаемой задачи) (см. рисунок 1).

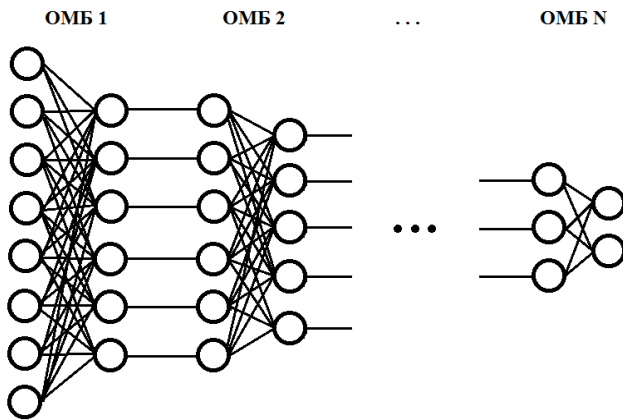


Рисунок 1 – Глубокая доверительная сеть

Глубокая доверительная сеть в слоях, состоящих из ограниченных машин Больцмана, решает задачу сжатия данных, которую формально можно описать следующим образом.

Пусть X – пространство входных образов некоторой фиксированной размерности, Y – пространство сжатых образов гораздо меньшей размерности, т. е.:

$$\begin{cases} \dim X = \text{fix} \\ \dim Y \ll \dim X. \end{cases} \quad (5)$$

Тогда задача сжатия данных заключается в построении функций сжатия f и восстановления g , таких что:

$$\begin{cases} f: X \rightarrow Y, g: Y \rightarrow X \\ d: X \times X \rightarrow \mathbb{R} \\ d(x, g(f(x))) \rightarrow \min, \forall x \in X \end{cases} \quad (6)$$

где d – функция, оценивающая различия между двумя заданными векторами.

Замечание. На практике сжатие данных осуществляется для конкретной предметной области. Это, в свою очередь, накладывает определенные ограничения на исходные данные и, следовательно, понижает размерность пространства.

Как отмечалось, наиболее трудоемким этапом использования нейронных сетей является процесс обучения. Так как глубокая доверительная сеть всегда содержит слои из ограниченных машин Больцмана, то эффективность решения задачи зависит от эффективности обучения всей сети в целом. Обучение сети можно записать в виде оптимизационной задачи для каждого из слоев.

Пусть задана обучающая выборка X и функционал оценки качества сжатия данных $d(2)$. Необходимо найти значения параметров $(w^*, b^*, g^*, \sigma^*)$, которые обеспечили бы минимум функционала качества F , т. е.

$$F(x, d, w^*, b^*, g^*, \sigma^*) = \min_{w, b, g, \sigma} F(x, d, w, b, g, \sigma) \quad (7)$$

Замечание. Ограниченная машина Больцмана типа Бернулли-Бернулли не содержит параметра σ и функционал качества F и, следовательно, не зависит от σ .

Для решения оптимизационных задач можно использовать либо метод градиентного спуска, либо случайный поиск.

Метод градиентного спуска обладает быстрой сходимостью, но в то же время имеет ряд недостатков:

- 1) сходится в точке локального минимума [5], что существенно снижает качество решения;
- 2) требует дифференцируемости целевой функции, что существенно снижает класс решаемых задач.

Метод случайного поиска не получил широкого распространения [7], однако он имеет некоторые достоинства:

- 1) не требует дифференцируемости целевой функции, что существенно расширяет класс прикладных задач;
- 2) при определенных условиях [8] и из любого начального приближения [9] обладает сходимостью к глобальному минимуму.

С учетом написанного выше получаем следующую задачу обучения.

Пусть задана обучающая выборка из N входных образов размерностью $\dim X$ и зафиксированы требования к сжатию данных, т. е. $\dim Y = \text{fix}$.

Необходимо разработать архитектуру глубокой доверительной сети и алгоритм обучения (на основе метода отжига), чтобы выполнялись следующие условия:

- 1) время обучения должно быть приемлемым (не более суток);
- 2) качество обучения должно быть максимально высоким, при этом алгоритм должен требовать как можно меньше данных для обучения.

2. Алгоритм решения. Для решения поставленной задачи была разработана следующая архитектура глубокой доверительной сети.

Так как входные данные, как правило, являются изображениями, то первый слой глубокой доверительной сети сформирован в виде ансамбля из M_1 ограниченных машин Больцмана типа Гаусс-Бернулли. Это позволило "покрыть" весь числовой диапазон значений входных данных. Все машины, формирующие один слой, имеют одинаковую архитектуру в пределах слоя, поэтому $\dim X$ должно быть кратно M_1 . Все последующие представляются ансамблями из ограниченных машин Больцмана типа Бернулли-Бернулли. Поэтому для каждого слоя сети должно выполняться следующее ограничение: произведение количества машин в слое на размер входного слоя каждой должен равняться произведению количества машин в предыдущем слое и размеру скрытого слоя каждой. Выходной слой сети представлен ансамблем из M_s ограниченных машин Больцмана типа Бернулли-Бернулли. Для выполнения требования к сжатию данных суммарное количество нейронов в скрытых слоях машин должно быть строго равно $\dim Y$. Количество настраиваемых параметров в каждой из машин должно быть строго меньше N . Это необходимо для обеспечения обобщающей способности сети.

Предложенная архитектура обладает рядом преимуществ:

1) декомпозиция слоев сети обеспечивает полную независимость обучаемых машин-компонент в пределах слоя сети, что позволяет распараллелить процесс обучения;

2) архитектура позволяет существенно снизить количество настраиваемых параметров сети, что уменьшает объем обучающей выборки и значительно снижает вычислительную сложность процесса обучения;

3) архитектура полностью удовлетворяет ограничениям на задачу для эффективного решения с использованием гетерогенных вычислительных устройств [10].

Рассмотрим подход к обучению ограниченной машины Больцмана с использованием метода отжига. Предлагается алгоритм, реализующий идеологию данного метода.

На предварительном этапе производится инициализация (задание начальных значений) параметров (W, VB, HB, σ), начальной температуры T_0 .

Основной этап алгоритма обучения реализует процедуру последовательного обновления значений указанных параметров с использованием некоторого функционала качества.

Опишем более подробно процедуру обновления параметров. Для простоты изложения рассмотрим ее на примере множества параметров W . Для других множеств эта процедура полностью совпадает.

Множеству параметров W поставим в соответствие отрезок LW длины L . Далее каждый элемент множества W последовательно помещаем в центр заданного отрезка. Для определения направления изменения значений параметров генерируем случайное число от 0 до 1. Если значение случайной величины больше 0.5, то значение параметра увеличивается, в противном случае – уменьшается.

Новые значения параметров определяются следующим образом. Генерируется случайная перестановка, количество элементов которой равно числу элементов множества W . Упорядочиваем элементы множества W в соответствии с полученной перестановкой и изменяем значения первых Wp элементов множества. Новое значение параметра определяется в результате реализации равномерно распределенной случайной величины на отрезке, концами которого являются текущее значение параметра, и конец отрезка, в сторону которого осуществляется изменение.

Аналогично действия последовательно выполняются для множеств VB, HB, σ .

Для вновь полученных значений параметров вычисляется функционал качества.

В качестве последнего предлагается использовать следующую функцию:

$$F(W, VB, HB, \sigma) = \frac{1}{NR} \sum_{i=1, N} \sum_{j=1, R} |x_{ij} - f^{-1}(y_{ij})|, \quad (8)$$

где y_{ij} – восстановленный входной сигнал ограниченной машины Больцмана; f^{-1} – функция, обратная предварительному преобразованию входных данных.

Дальше принимается решение о переходе в новое состояние с вероятностью:

$$P(y | x) = \min \left\{ 1, \exp \left(- \frac{F(y) - F(x)}{T_i} \right) \right\}, \quad (9)$$

где x – текущее состояние, y – выбранное для перехода состояние, F – минимизируемая целевая функция, T_i – температура i -й итерации.

В случае смены состояния происходит охлаждение по правилу:

$$T_{i+1} = \frac{T_0}{\ln(k+1)}, \quad (10)$$

где k – количество совершенных переходов в новое состояние.

В противном случае температура не изменяется.

После охлаждения производится проверка полученного решения на оптимальность:

- решение является оптимальным, если время, отведенное на обучение, истекло.

Если полученное решение оптимально, то:

- останов алгоритма,
- в противном случае – переход на следующую итерацию.

Эффективность использования нейронной сети предложенной архитектуры проверим на примере задачи сжатия цветных изображений.

3. Пример решения прикладных задач.

Для проведения экспериментов было разработано программное обеспечение в виде фреймворка, включающего алгоритмы обучения и сжатия данных.

Фреймворк состоит из пяти основных модулей: `trainDeepNN`, `compressImages`, `decompressImages`, `loadFromFileDeepNN`, `buildDeepNN`.

Модуль `trainDeepNN` реализует основную функцию фреймворка. Он осуществляет обучение переданной ей глубокой доверительной сети. Модуль `compressImages` осуществляет сжатие цветных изображений. Модуль `decompressImages` – восстановление исходных изображений из их сжатого представления. Модуль `loadFromFileDeepNN` – загрузка с жесткого диска сети. Модуль `buildDeepNN` создает глубокую доверительную сеть.

Внутренний состав самого важного блока – `trainDeepNN` – представлен в виде следующей схемы (см. рисунок 2). В начале выполнения модуля осуществляется настройка OpenCL на вычислительных устройствах. Затем запускается цикл обучения глубокой доверительной сети по слоям. При переходе на следующий слой производится предварительное преобразование данных под архитектуру текущего слоя. После этого запускается циклическое обучение ограниченных машин Больцмана, формирующих текущий слой. Цикл включает в себя инициализацию начального состояния машин, передачу данных на вычислительные устройства и цикл обучения с использованием оригинального алгоритма метода отжига.

В качестве исходных данных использовалась выборка «STL-10» из репозитория Стенфордского университета [11]. Выборка содержит сто тысяч немаркированных цветных изображений размером 96x96 пикселей. Каждое изображение описывается 27648 целыми числами (в диапазоне от 0 до 255), задающими содержание красного, зеленого и синего цветов [12]. Исходя из полученных характеристик (выборка задается примерно $2,8 \times 10^9$ числами, содержит описания произвольных, немаркированных объектов), можно сделать вывод, что процесс сжатия изображений данной выборки с малыми потерями является достаточно сложной задачей.

Для обработки данных использовался стандартный компьютер с 4-ядерным процессором и видеокартой: видеокарта: `nvidia 1060 3gb`; процессор: `intel i7 4770k 3.5 GHz`; ОЗУ: `2x8 Gb 1600 MHz`; жесткий диск: `samsung 850 pro 256 Gb`; операционная система – `Lubuntu 16.04`.

В качестве программного обеспечения использовался компилятор `gcc` (библиотеки `OpenMP` и `CUDA` версии 9.1 [13]) с опциями: `gcc superOpenCLFramework.cpp -lstdc++ -D_FORCE_INLINES -O2 -lOpenCL -lgomp -lm -fopenmp`. Замер времени операций проводился с помощью функции `«gettimeofday»`.

В экспериментах использовалась следующая архитектура глубокой доверительной сети.

Первый слой состоял из объединения 432 ограниченных машин Больцмана типа Гаусс-Бернулли. Количество нейронов во входном слое и скрытом было 64 и 16 соответственно для всех машин слоя. Второй слой состоял из объединения 108 ограниченных машин Больцмана типа Бернулли-Бернулли. Количество нейронов во входном слое и скрытом было 64 и 16 соответственно для всех машин слоя. Третий слой состоял из объединения 27 ограниченных машин Больцмана типа Бернулли-Бернулли. Количество нейронов во входном слое и скрытом было 64 и 16 соответственно для всех машин слоя.

Степень сжатия изображений регулировалась за счет отключения последних слоев глубокой доверительной сети. Так, 3 слоя сети обеспечивали 512-кратное сжатие, 2 слоя – 128-кратное, а первый слой сети – 32-кратное. Для обучения первого слоя сети использовалось 2000 изображений, для второго и третьего – 4000.

В экспериментах в качестве коэффициента сжатия будем использовать показатель количества бит для кодирования одного пикселя изображения. Для кодирования без сжатия одного пикселя

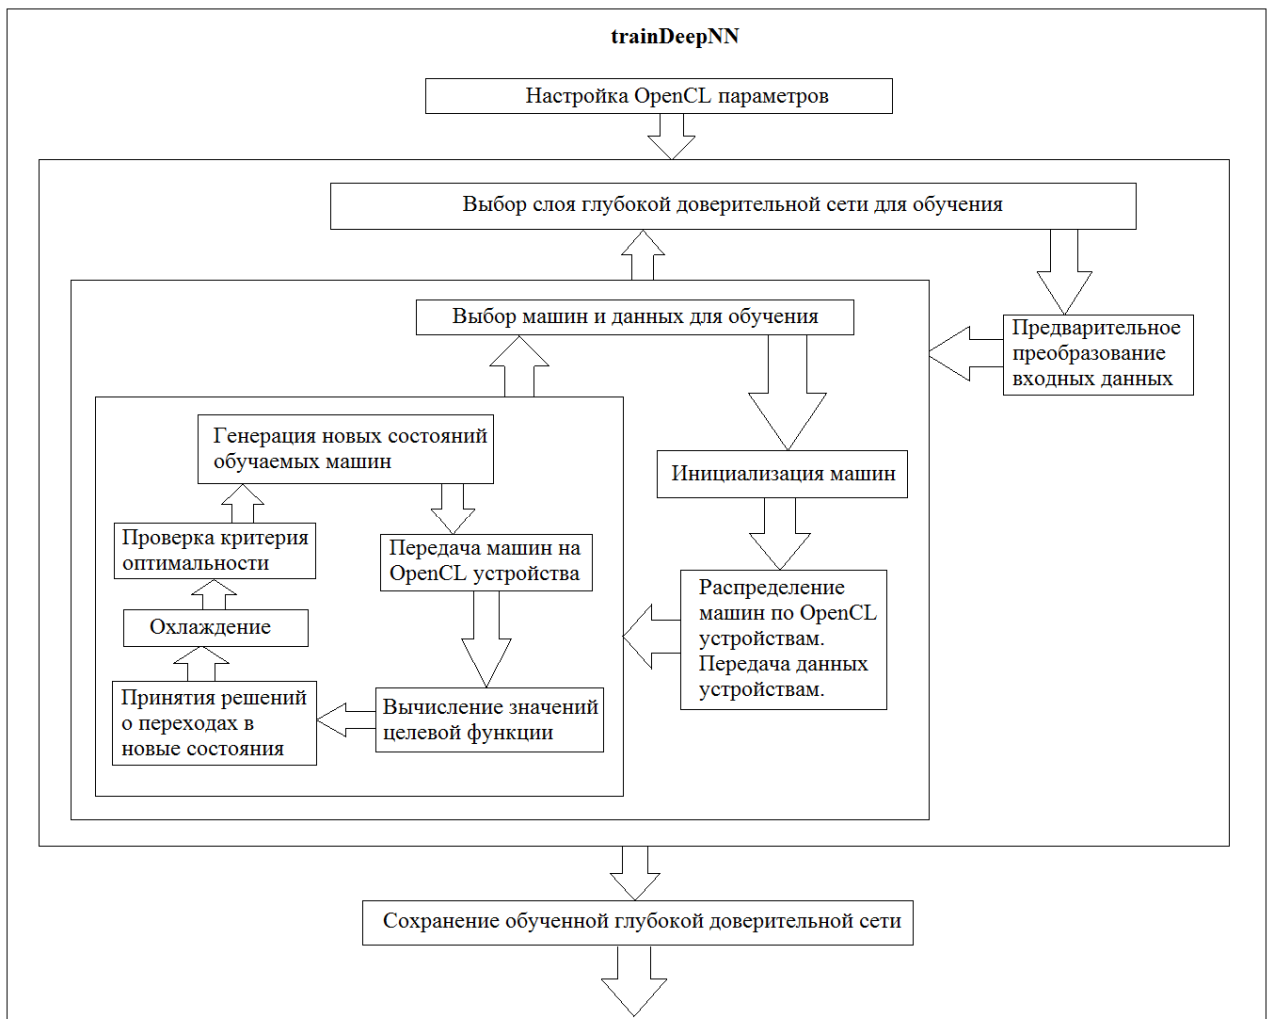


Рисунок 2 – Функция trainDeepNN

цветного изображения необходимо 24 бита. Уменьшение количества бит для кодирования пикселя приводит к сжатию изображений, например, при 24-кратном сжатии количество бит на пиксель изображения будет равно единице.

Существует множество различных функционалов для оценки качества сжатия изображений [14], однако многие из них не получили широкого распространения из-за того, что для их вычисления необходимо зафиксировать значения параметров в самом функционале для корректного сравнения результатов либо требуется большой объем вычислений.

В качестве функционала качества для оценки потерь при сжатии изображений будем использовать наиболее распространенный функционал качества PSNR (peak signal-to-noise ratio), не требующий фиксации параметров и большого объема вычислений. Данный функционал вычисляет соотношение максимально возможного сигнала к средней квадратической ошибке для цветных растровых изображений следующим образом.

$$PSNR(X, Y) = 10 \log_{10} \frac{255^2}{\frac{1}{3N} \sum_i (x_i - y_i)^2}, \quad (11)$$

где X , Y – сравниваемые изображения, N – количество пикселей в изображении.

Чем выше значение функционала – тем меньше потери сжатия и выше качество. Для сжатия без потерь данный функционал равен плюс бесконечности. Для высокой степени сжатия (примерно 0,05 бит на пиксель и меньше) адекватными считаются значения в диапазоне от 8 и выше. Для средней степени сжатия (1 бит на пиксель) нормальными значениями считаются от 20 выше.

4. Результаты экспериментов

По итогам проведенных экспериментов были получены следующие результаты (см. таблицу 1):

Таблица 1 – Обучение глубокой доверительной сети

степень сжатия (бит/пиксель)	0,75	0,1875	0,046875
функционал качества (PSNR)	19,14	17,15	14,96
время обучения (ч)	6	10	11

Полученные результаты показывают высокую эффективность архитектуры глубокой доверительной нейронной сети и алгоритма обучения на основе метода отжига. Для настройки отдельной машины, состоящей из 1168 параметров, в первом слое сети понадобилось всего 2000 изображений, в то время как для машин последующих слоев, состоящих из 1104 параметров, понадобилось всего 4000 изображений, что говорит об очень высокой эффективности метода отжига в обучении нейронных сетей.

Время, затраченное на обучение сети, показывает, что при грамотном подборе параметров алгоритма обучения метод отжига может обладать высокой скоростью сходимости.

Полученные результаты подтверждают предположение, что метод отжига может быть использован для обучения глубоких доверительных сетей [15]. С учетом того, что выборка STL-10 достаточно сложная, то в сравнении с другими результатами [16] [17] можно утверждать, что разработанный оригинальный алгоритм метода отжига является достаточно эффективным.

5. Заключение. В работе рассмотрена проблема организации эффективного обучения глубоких доверительных сетей. Предложен один из возможных подходов к решению проблемы на основе декомпозиции данных и метода отжига.

Эффективность предложенного подхода демонстрируется на примере решения задачи сжатия цветных изображений с использованием глубокой доверительно нейронной сети. Задача решалась на компьютере с многоядерным процессором и видеокартой.

В силу того, что возможности метода отжига сильно ограничены вычислительными мощностями компьютеров (которые постоянно растут), и с учетом полученных результатов можно сделать предположение, что метод отжига имеет огромный потенциал. Поэтому описанные в работе идеи могут оказаться полезными при обучении глубоких нейронных сетей.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Krasnoprosin, V. V. Statistical approach to image compression based on a restricted Boltzmann machine // V. V. Krasnoprosin, V. V. Matskevich // Proceedings of the 12-th International Conference "Computer Data Analysis and Modeling" – CDAM'2019. – Minsk, 2019. – P. 207–213.
2. Matskevich, Vadim Annealing method in training restricted Boltzmann machine / Vadim Matskevich, Victor Krasnoprosin // Proceedings of the 14-th International Conference – PRIP'2019. – Minsk, 2019. – P. 264–268.
3. Glorot, Xavier Understanding the difficulty of training deep feedforward neural networks / Glorot Xavier, Bengio Yoshua // Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics. – PMLR. – Vol. 9. – 2010. – P. 249–256.
4. Aicher, C. Adaptively truncating backpropagation through time to control gradient bias / C. Aicher, N. J. Foti, E. B. Fox [Электронный ресурс]. – Режим доступа : arxiv.org/abs/1905.07473 – Дата доступа : 04.01.2020.
5. Treadgold, N. K. Simulated annealing and weight decay in adaptive learning: the SARPROP algorithm / N. K. Treadgold, T. D. Gedeon // IEEE Transactions on Neural Networks. – Vol. 9. – Issue, 4 Jul 1998.
6. Головкин, В. А. Применение нейронных сетей глубокого доверия для выделения семантически значимых признаков / В. А. Головкин, А. А. Крощенко // Открытые семантические технологии проектирования интеллектуальных систем = Open Semantic Technologies for Intelligent Systems (OSTIS-2015) : материалы V Междунар. науч.-техн. конф. (Минск, 19-21 февраля 2015 года) / редкол. : В. В. Голеньков (отв. ред.) [и др.]. – Минск : БГУИР, 2015. – С. 481-486.
7. Locatelli, M. Convergence properties of simulated annealing for continuous global optimization // Journal of Applied Probability. – December 1996. – Vol. 33. – Issue 4. – P. 1127–1140.
8. Hajek, B. Cooling schedules for optimal annealing // mathematics of operations research. – Vol. 13. – No 2. – May 1988.
9. Sanguthevar Rajasekaran On the Convergence Time of Simulated Annealing [Электронный ресурс]. – Режим доступа : repository.upenn.edu/cis_reports/356/ – Дата доступа : 04.01.2020.
10. Краснопрошин, В. В. Эффективная обработка данных на гетерогенных вычислительных устройствах / В. В. Краснопрошин, В. В. Мацкевич // Вестник Брестского государственного технического университета. – Серия : Физика математика, информатика. – 2018. – № 5 (113). – С. 15–18.
11. STL-10 dataset [Электронный ресурс]. – Режим доступа : academictorrents.com/details/a799a2845ac29a66c07cf74e2a2838b6c5698a6a – Дата доступа : 25.02.2018.
12. STL-10 dataset description [Электронный ресурс]. – Режим доступа : stanford.edu/~acoates/stl10/ – Дата доступа : 24.02.2018.
13. CUDA toolkit [Электронный ресурс]. – Режим доступа : developer.nvidia.com/cuda-downloads – Дата доступа : 23.02.2018.
14. Dogancan Temel. Ghassan AlRegib Perceptual Image Quality Assessment through Spectral Analysis of Error Representations // Signal Processing: Image Communication. – Vol. 70. – 2019. – P. 37-46, ISSN 0923-5965.
15. Rasdi, Rere L. M. Simulated Annealing Algorithm for Deep Learning / L. M. Rasdi Rere, Mohamad Ivan Fanany, Aniat Murni Arymurthy // Procedia Computer Science. – 2015. – Vol. 72. – P. 137–144.
16. Toderici, G. Full Resolution Image Compression with Recurrent Neural Networks / G. Toderici, D. Vincent, N. Johnston, Jin Hwang Sung, D. Minnen, J. Shor, M. Covell [Электронный ресурс]. – Режим доступа : arxiv.org/abs/1608.05148 – Дата доступа : 04.01.2020.
17. Zhou, X. An Efficient Compressive Convolutional Network for Unified Object Detection and Image Compression / X. Zhou, L. Xu, S. Liu, Y. Lin, L. Zhang, C. Zhuo // Proceedings of the AAAI Conference on Artificial Intelligence. – 2019. – Vol. 33. – P. 5949–5956.

29.01.2020

KRASNOPROSHIN V. V., MATSKEVICH V. V. Annealing method in training deep belief networks

The paper deals with the problem of organizing efficient deep belief networks training. A possible approach to solving the problem based on annealing method using the data parallelization technology is proposed. The effectiveness of the approach is demonstrated by the example of solving the problem of compressing color images using a restricted Boltzmann machine.

The ideas described in the paper may be useful in training deep belief networks on clusters.

004.89

. . .

Постановка задачи детекции маркировки. Применение нейронных сетей в промышленных целях является перспективным направлением машинного обучения. Это особенно относится к задачам детекции объектов в регулярных производственных процессах. В качестве примера можно назвать обнаружение объектов специальных классов, которые перемещаются по производственной линии. Критически важно, чтобы подобные операции выполнялись очень

быстро. В настоящее время широкое применение находят глубокие архитектуры нейронных сетей [1, 2], которые с успехом применяются для решения задач детекции и сегментации.

Перед нами была поставлена задача обнаружения и распознавания цифр в маркировке молочной продукции, производимой ОАО «Савушкин продукт» (йогурт, кефир и т. д.) [3, 4]. Помимо решения этой задачи, система должна выявлять ошибки нанесения маркиров-

Головкин Владимир Адамович, д. т. н., профессор, заведующий кафедрой интеллектуальных информационных технологий Брестского государственного технического университета.

Крощенко Александр Александрович, старший преподаватель кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.