

УДК 004.93'12

ОБУЧЕНИЕ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ В УСЛОВИЯХ МАЛОЙ ВЫБОРКИ ДЛЯ КЛАССИФИКАЦИИ БИОЛОГИЧЕСКИХ ОБЪЕКТОВ ПО МУЛЬТИСПЕКТРАЛЬНЫМ ИЗМЕРЕНИЯМ

А. О. Донских, А. А. Сирота

Воронежский государственный университет

Поступила в редакцию 11.08.2019 г.

Аннотация. Исследуется возможность применения глубоких нейронных сетей для обработки мультиспектральных измерений в задачах классификации биологических объектов с определенными патологиями. Для классификации используются сверточные нейронные сети, принимающие на вход несколько спектральных функций (зависимостей амплитуды от частоты), полученных одновременно по каждому объекту с помощью различных методов (спектры отражения, спектры пропускания) и/или в различных участках спектра электромагнитных волн. Описывается структура глубокой сети с двумя слоями свертки и двумя полносвязными слоями, используемая для классификации элементов неоднородного потока зерновых смесей (на примере пшеницы), пораженных грибковыми заболеваниями, и определения сортовой принадлежности. Предлагается метод повышения качества обучения сети на основе технологии переноса обучения с использованием предварительного обучения по искусственно размноженным данным мультиспектральных измерений. На примере задачи классификации зарегистрированных спектров отражения и пропускания элементов зерновых смесей приводится сравнение результатов, полученных при традиционном обучении глубоких сетей для каждого спектрального метода в отдельности, при обучении с использованием данных для двух спектральных методов (одновременная обработка двух каналов данных, описывающих спектры пропускания и отражения), и при обучении с использованием предлагаемого метода на основе технологии переноса обучения.
Ключевые слова: глубокие нейронные сети, сверточные сети, перенос обучения, спектральные измерения, машинное обучение.

ВВЕДЕНИЕ

При построении алгоритмов классификации (распознавания) образов важную роль играет исходное представление данных, т. е. извлечение признаков из первичных наблюдений для дальнейшей обработки. Удачный выбор набора исходных описаний позволяет получить вектор признаков, который включает только информативные составляющие и имеет достаточную для эффективного решения задачи размерность. Отсутствие в со-

ставе набора признаков неинформативных составляющих и его минимальный размер значительно упрощают процесс обучения алгоритмов машинного обучения и сокращают требования к объему обучающих данных.

В зависимости от типа данных, извлечение и выбор признаков для классификации может выполняться с помощью метода главных компонент, спектральных методов анализа, ядерных методов (например, метода опорных векторов), путем статистической предобработки, например усреднения данных на некоторых интервалах наблюдений и др. Применение подобных методов к произ-

вольным данным зачастую требует большой подготовительной исследовательской работы с учетом физики и специфики решаемой задачи и высокой квалификации разработчика. Применение этих методов в «слепом» режиме без учета специфики решаемой задачи приводит к тому, что полученные признаки часто не обладают достаточной степенью обобщения и информативности [1]. В тоже время с ростом объемов обучающих данных и сложности решаемой задачи «ручной» анализ и предварительная обработка становятся все более затратными и неэффективными. Это обстоятельство делает острой проблемой автоматизации процесса извлечения признаков [1] и необходимость переходу к анализу сырых, необработанных данных как, в сущности, это и вытекает из общего направления развития современных систем прикладного искусственного интеллекта.

Прорыв [1–2] в развитии методов автоматического извлечения признаков связан с идеей построения иерархий признаков (от частных к более общим) путем обучения без учителя (в плане предобработки) глубоких моделей (в частности, глубоких нейронных сетей) с использованием необработанных исходных данных [3–4]. По сравнению с традиционным иерархическим представлением признаков оказалось более репрезентативным, обобщенным и инвариантным [1]. При этом количество уровней в иерархии признаков определяется количеством слоев в модели нейронной сети и может регулироваться в зависимости от сложности задачи. Кроме того, слои, обученные для извлечения признаков в рамках одной задачи, могут использоваться для повышения качества и скорости обучения при решении других, близких по типу данных задач [4–5], что в настоящее время реализуется в рамках технологии переноса обучения (transfer learning).

Универсальность глубоких моделей и их способность выявлять информативные закономерности в данных большой размерности позволило добиться значительных успехов в задачах распознавания изображений [6–9] и речи [10–12], анализа научных данных [13–14] и др.

В настоящее время методы глубокого обучения активно внедряются в процесс регистрации и обработки спектральных измерений различных типов природных объектов. Так, в [15] глубокие сверточные сети (CNN) успешно применяются для определения зрелости цитрусовых по измеренным спектрам флюоресценции. В [16] исследуется эффективность применения переноса обучения для CNN при решении задачи определения содержания глины в почве по данным спектрального анализа. В [17] демонстрируется, что способность CNN к извлечению инвариантных признаков может быть использована для компенсации различий в измерениях объектов, возникающих при использовании спектрометров с разными параметрами калибровки.

С учетом этого, представляется перспективным использование глубоких сверточных сетей при решении задач классификации биологических объектов по спектральным измерениям. При этом спецификой решения данной задачи часто является необходимость обучения алгоритмов в условиях малой выборки вследствие невозможности получения значительных по объему обучающих данных в условиях ограничения во времени и трудозатратам на проведение спектральных измерений, а иногда, и в силу объективного отсутствия необходимого количества образцов. К такого рода задачам относятся задачи диагностики различных заболеваний в медицине, а также задачи классификации элементов зерновых смесей (ЭЗС) для выявления различных патологий, оценки сортовой чистоты и пр. Следует также отметить актуальность подобной постановки задачи с точки зрения существующей практики настройки приборов экспресс-анализа, используемых для диагностики различных патологий, и необходимости их оперативной перенастройки под новую задачу.

Существующие подходы к преодолению проблемы «малой выборки» при обучении глубоких нейронных сетей и, в частности, сверточных сетей, реализуют, в основном, два варианта: это либо уже упоминавшийся подход на основе переноса обучения [17–18],

либо подход, основанный на выполнении аугментации – искусственного размножения имеющихся реальных данных, который широко применяется не только при обучении глубоких сетей, но и других алгоритмов машинного обучения [6, 19–21].

Целью данной работы является исследование эффективности применения глубоких сверточных сетей с обучением в условиях малой выборки в задачах классификации биологических объектов по мультиспектральным измерениям. При этом рассматривается подход, реализующий технологию переноса обучения и основанный на предварительном обучении CNN с использованием наборов данных, которые использовались для задач, близких по физической природе к решаемой задаче, с последующим дообучением по данным для текущей задачи. В качестве примера рассматривается задача классификации элементов зерновых смесей по мультиспектральным измерениям с целью выявления объектов, пораженных грибковыми заболеваниями (фузариозом), и определения сортовой принадлежности.

Под мультиспектральными измерениями здесь и далее понимается использование в качестве первичных наблюдений комбинаций спектральных измерений, получаемых различными оптическими методами в различных диапазонах длин волн.

Следует отметить, что ранее [22–23] авторами уже рассматривалась возможность решения указанной задачи с помощью классических нейронных сетей, имеющих структуру двуслойного персептрона. При этом выполнялась предварительная обработка с целью извлечения из спектральных измерений входного вектора признаков, обоснованию которой были посвящены весьма затратные исследования информативности различных вариантов такой обработки и наборов признаков.

ОПИСАНИЕ ПРЕДЛАГАЕМОГО МЕТОДА ОБРАБОТКИ МУЛЬТИСПЕКТРАЛЬНЫХ ДАННЫХ

Основной идеей предлагаемого в данной работе метода обработки спектральных измерений является отказ от подбираемых вручную и явным образом реализуемых алгоритмов извлечения признаков в пользу использования глубокой сверточной сети, обеспечивающих обработку «сырых» данных без выполнения специальных процедур извлечения признаков.

Специфика использования мультиспектральных данных определяет следующие принципы построения и обучения сверточной сети:

- использование предварительной обработки для исключения влияния индивидуальной настройки спектроанализатора путем нормировки по энергии вектора каждого спектрального измерения для выполнения классификации исключительно по форме кривой спектральной характеристики объекта;
- использование одномерной свертки, выполняемой параллельно по нескольким слоям (каналам) спектральных измерений (каждый слой на один тип спектра);
- необходимость обучения в условиях малой выборки и быстрого переобучения под новый тип данных без существенной трансформации архитектуры сети.

Пусть $x^{(i)} = (x_1^{(i)}, \dots, x_N^{(i)})^T$ вектор спектральных измерений, полученный по i -му типу спектра, причем $i = \overline{1, M}$, где $M \in \{1, 2, \dots\}$ – общее число одновременно измеряемых типов спектра. При этом считаем, что количество получаемых по каждому типу спектра спектральных коэффициентов N одинаково. Далее для исключения влияния индивидуальных настроек используемого датчика для каждого входного вектора выполняется преобразование

$$x_k^{(i)} = \frac{x_k^{(i)}}{\sqrt{\sum_{k=1}^N (x_k^{(i)})^2}}, \quad k = \overline{1, N}, i = \overline{1, M}.$$

В итоге формируется общая входная матрица мультиспектральных измерений

$$X = \begin{pmatrix} x_1^{(1)} & \dots & x_N^{(1)} \\ \vdots & \dots & \vdots \\ x_1^{(M)} & \dots & x_N^{(M)} \end{pmatrix}, \quad (1)$$

которая в каждой строке содержит спектральные измерения одного типа (канала).

Для обработки мультиспектральных измерений в данной работе предлагается использовать метод, сочетающий в себе автоматическое извлечение признаков и классификацию, который основан на использовании типовой глубокой сети со структурой, приведенной в табл. 1. Выбор структуры, содержащей два сверточных слоя, обусловлен тем, что в ходе предварительных экспериментов наилучшие результаты при решении задач обработки спектральных измерений были получены при использовании такой конфигурации.

При использовании глубокой сети возможно одновременное использование нескольких типов спектров с целью повышения точности классификации. При этом общая конфигурация слоев сети остается без изменений, а каждый тип спектра подается на вход сети в отдельном канале. В листинге 1 представлен фрагмент кода программы на языке Python с использованием компонентов среды Keras, дающий представление об архитектуре создаваемой сети и ее основных настройках.

Учитывая необходимость обучения в условиях небольшого объема обучающих данных, для повышения точности классификации предлагается сначала проводить предварительное обучение алгоритма с использованием близких по физической природе данных, используемых при решении схожих задач, а затем проводить процедуру переноса обучения с дообучением на данных, относящихся непосредственно к решаемой задаче.

Перед дообучением предлагается заменять скрытый и выходной полносвязные слои глубокой сети новыми полносвязными слоями, при этом количество выходов может быть изменено в соответствии с числом классов в решаемой задаче, при этом весовые коэффициенты в предварительно обученных сверточных слоях остаются неизменными. После этого полученная сеть может быть дообучена с использованием данных, относящихся к решаемой задаче.

Как можно предположить использование предварительного обучения по данным, близких по структуре к данным, обрабатываемым в рамках решаемой задачи, позволит требовательным к объему обучающих данных сверточным слоям, ответственным за извлечение признаков, обучиться выделять обобщенные и репрезентативные признаки. Последующее

Таблица 1

Структура глубокой сети для обработки спектральных измерений ЭЭС

Название слоя	Параметры
Входной слой	Размерность входных данных: $N \times 1 \times M$
Сверточный слой 1	Число фильтров: 10; Размер фильтра: 10×1 ; Шаг: 1
Слой нелинейности 1	Функция активации: ReLU («выпрямитель»)
Слой субдискретизации 1 (pooling)	Функция: максимум; Размер фильтра: 2×1 ; Шаг: 2
Сверточный слой 2	Число фильтров: 20; Размер фильтра: 10×1 ; Шаг: 1
Слой нелинейности 2	Функция активации: ReLU
Слой субдискретизации 2	Функция: максимум; Размер фильтра: 2×1 ; Шаг: 2
Слой исключения (dropout)	Доля отключаемых выходов: 50 %
Скрытый полносвязный слой	Функция активации: ReLU; Число выходов: 256
Выходной полносвязный слой	Функция активации: softmax; Число выходов: соответствует числу классов в решаемой задаче

Фрагмент кода, задающий структуру и параметры сети

```

model_3 = Sequential()
model_3.add(Conv1D(Nc1,Nf1,input_shape=(ny,n_channel),
strides=1,padding='valid',W_regularizer=l2(12_lambda),
init='he_normal'))
model_3.add(Activation('relu'))
model_3.add(MaxPooling1D(pool_size=2,strides=2))
model_3.add(Conv1D(Nc2,Nf2,strides=1,padding='valid',
W_regularizer=l2(12_lambda), init='he_normal'))
model_3.add(Activation('relu'))
model_3.add(MaxPooling1D(pool_size=2,strides=2))
model_3.add(Dropout(0.5))
model_3.add(Flatten())
model_3.add(Dense(256))
model_3.add(Activation('relu'))
model_3.add(Dropout(0.5))
model_3.add(Dense(2))
model_3.add(Activation('softmax'))

```

дообучение в режиме тонкой настройки позволит обучить новые полносвязные слои, непосредственно ответственные за классификацию, при этом обобщенные правила выделения признаков, выработанные сверточными слоями в процессе предварительного обучения, сохраняются, что должно способствовать повышению общей точности классификации.

РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТА И ИХ ОБСУЖДЕНИЕ

Экспериментальная проверка предлагаемого алгоритма классификации выполнялась на примере двух задач, связанных с обработкой спектральных данных семян пшеницы.

В задаче диагностики ЭЗС, зараженных грибковой патологией, в качестве объектов исследования использованы 500 здоровых семян яровой мягкой пшеницы сорта «Воронежская 12» и 500 семян, пораженных фузариозом. Задачей алгоритма при этом является определение принадлежности анализируемого образца к классу здоровых или зараженных.

При решении задачи анализа сортовой чистоты использованы семена пшеницы четырех сортов: яровая твердая пшеница «Воронежская 11» и «Светлана», яровая мягкая

пшеница «Воронежская 14» и «Черноземно-уральская» (по 500 образцов каждого сорта). В данном случае задачей алгоритма является определение принадлежности образца к одному из этих сортов. Зерна, используемые в экспериментах, были предоставлены ГНУ Воронежской ИСХ Россельхозакадемии имени В.В. Докучаева.

Для всех зерен на установке, описанной в [23], были проведены измерения спектров двух типов ($M = 2$) – пропускания и отражения – в диапазоне 450–1050 нм. Затем для каждого зерна отбиралось по одному спектру каждого типа для дальнейшей обработки. Таким образом, объем исходных данных составил 500 спектров каждого класса, при этом каждый спектр представлял собой вектор вещественных измерений размерностью 3164×1 . Общий вид измеренных спектров после преобразования (1) приведен на рис. 1 и 2.

Ранее [22–23] при обучении нейронных сетей, имеющих структуру двуслойного пересептрона, использование всех $N = 3164$ признаков являлось избыточным, поэтому авторы явным образом производили извлечение признаков с помощью метода главных компонент или путем усреднения соседних спектральных составляющих. Анализ результатов оценки качества классификации, получаемых

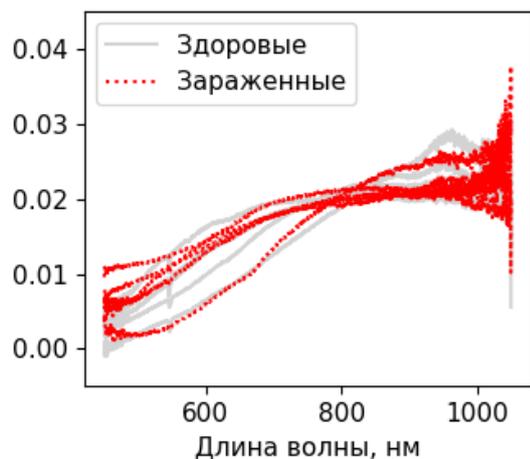


Рис. 1. Пример реальных спектров отражения здоровых и зараженных зерен пшеницы, полученных на измерительной установке

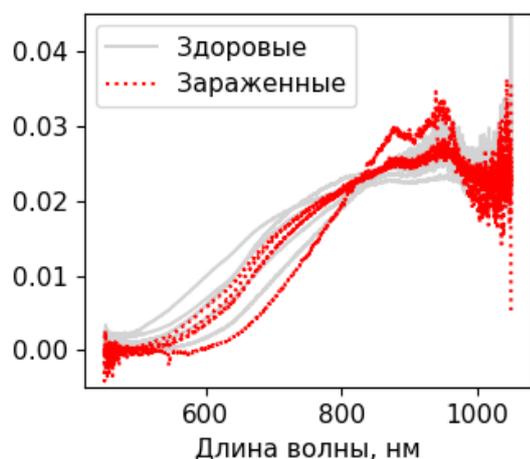


Рис. 2. Пример реальных спектров пропускания здоровых и зараженных зерен пшеницы, полученных на измерительной установке

при использовании данных методов, показал, что выбор алгоритма извлечения признаков оказывает существенное влияние на точность работы классификатора при том же объеме обучающих данных. В связи с этим в данной работе на вход глубокой сети, описанной в табл. 1, подаются все 3164 исходные спектральные составляющие, и извлечение признаков выполняется полностью в автоматическом режиме с помощью сверточных слоев сети. Количество каналов сети равно числу одновременно используемых типов спектров: 1 для спектров отражения и пропускания отдельно и 2 при совместном анализе обоих типов спектров.

Предварительное обучение сети для задачи выявления объектов, пораженных фузариозом, выполнялось с использованием данных, предназначенных для решения задачи определения сортовой принадлежности, и наоборот. При этом 450 образцов каждого класса, выбранные случайным образом, использовались при предварительном обучении в качестве обучающей выборки, а оставшиеся 50 – в качестве валидационной выборки.

Выбор числа нейронов в выходном слое сети на этапе предварительного обучения определяется числом классов в используемом наборе данных и составляет 2 для набора данных, относящегося к задаче выявления зерен, пораженных фузариозом, и 4 для набора данных, относящегося к задаче определения сортовой принадлежности.

Во избежание переобучения предварительное обучение выполнялось в 5 эпох (epoch) с размером партии (batch size) 32. После каждой эпохи выполнялась проверка качества обучения сети с помощью валидационной выборки. В случае, если точность классификации оказывалась выше, чем в любой из предыдущих эпох, весовые коэффициенты сети для текущей эпохи сохранялись в выходной файл. После завершения предварительного обучения коэффициенты сети, при которых точность была максимальной, загружались из выходного файла для дальнейшего использования.

После завершения предварительного обучения оба полносвязных слоя удалялись из обученной сети и заменялись новыми. Выбор числа нейронов в выходном слое при этом определялось уже числом классов в решаемой задаче и составляло 2 для задачи выявления зерен, пораженных фузариозом, и 4 для задачи определения сортовой принадлежности.

Дообучение предварительно обученной сети и ее тестирование с использованием реальных данных проводилось путем кросс-валидации из 10 раундов для трех размеров обучающих выборок: по $P = 450$, $P = 250$ и $P = 125$ образцов каждого класса, выбираемых случайным образом. Оставшиеся образцы (50, 250 и 375 образцов каждого класса, соответственно) использовались для валида-

ции. В ходе каждого из раундов кросс-валидации выполнялось дообучение в 20 эпох с размером партии 32 для лучшей сети, полученной на шаге предварительного обучения. Результат наилучшего классификатора, полученного по всем эпохам в раунде, сохранялся, а итоговая точность классификации определялась усреднением результатов по 10 раундам.

Для сравнения также проводилось тестирование глубокой сети с той же структурой, обучаемой исключительно на данных, относящихся к решаемой задаче. В этом случае методика обучения и тестирования отличалась отсутствием шагов предварительного обучения и замены полносвязных слоев, т. е. на шаге дообучения в качестве исходной модели использовалась необученная сеть со случайными весовыми коэффициентами, устанавливаемым по умолчанию, и числом выходов, соответствующим числу классов в решаемой задаче.

Для создания и тестирования сети использовался язык Python 3.6 и библиотека Keras в сочетании с фреймворком TensorFlow.

Результаты, полученные при решении задачи диагностики ЭЗС, зараженных грибковой патологией, приведены в табл. 2.

Видно, что для спектров отражения точность классификации оказывается значительно выше, чем для спектров пропускания (минимальная разница составляет 6.3 % и увеличивается при уменьшении объема обучающей выборки). Схожая ситуация наблюдалась и при использовании классических нейронных сетей [22–23], что вновь подтверждает меньшую информативность спектров пропускания при решении данной задачи. Возможно

также, что при их измерении был получен определенный процент аномальных наблюдений, что можно увидеть, в частности на рис. 2, где в нижней части спектрального диапазона частот имеются отрицательные выбросы амплитуды спектральных составляющих. Это, по нашему мнению, определяет определенную неустойчивость полученных здесь и далее результатов при использовании спектров пропускания. Вероятно, этим также обусловлено то, что совместное использование спектров отражения и пропускания позволило повысить точность классификации по сравнению с одиночными спектрами отражения лишь для случая $P = 250$, в остальных случаях точность оказалась ниже, чем для спектров отражения, но выше, чем для спектров пропускания.

Применение предварительного обучения с использованием данных, предназначенных для решения задачи анализа чистовой чистоты, и последующий перенос обучения позволили повысить точность классификации на величину от 0.4 % до 3.95 % (в зависимости от объема обучающей выборки) для спектров отражения, однако для спектров пропускания точность, напротив, ухудшилась, возможно, как уже упоминалось, из-за неустойчивого характера получаемых спектральных измерений. Одновременное использование обоих типов спектров в сочетании с предварительным обучением представляется малоцелесообразным, так как итоговая точность классификации оказывается ниже, чем при использовании только спектров отражения.

Для задачи анализа сортовой частоты (табл. 3) точность классификации по спек-

Таблица 2

Оценки точности классификации здоровых и пораженных ЭЗС

Параметры обучения	Точность классификации (%)		
	Отражение	Пропускание	Совместно
$P = 450$, без предв. обучения	99.20	92.90	98.80
$P = 450$, с предв. обучением	99.60	91.40	99.00
$P = 250$, без предв. обучения	95.68	86.82	98.26
$P = 250$, с предв. обучением	97.96	84.22	97.34
$P = 125$, без предв. обучения	91.02	83.50	89.73
$P = 125$, с предв. обучением	94.97	80.59	91.21

Оценки точности классификации при анализе сортовой чистоты

Параметры обучения	Точность классификации (%)		
	Отражение	Пропускание	Совместно
$P = 450$, без предв. обучения	99.70	95.15	98.90
$P = 450$, с предв. обучением	99.65	95.25	98.95
$P = 250$, без предв. обучения	98.74	94.10	98.03
$P = 250$, с предв. обучением	98.29	94.06	98.14
$P = 125$, без предв. обучения	96.84	93.39	97.34
$P = 125$, с предв. обучением	96.35	93.63	96.83

трам отражения также оказывается выше, чем по спектрам пропускания, однако разница в данном случае менее выражена.

Точность классификации при совместном использовании спектров отражения и пропускания также оказалась ниже, чем для спектров отражения, но выше, чем для спектров пропускания за исключением случая $P = 125$, в котором удалось получить выигрыш 0.5 %. Применение предварительного обучения с использованием данных, предназначенных для решения задачи классификации здоровых и пораженных ЭЗС, практически не оказало влияния на точность классификации, что, вероятно, обусловлено вдвое меньшим объемом данных по сравнению с основным набором данных.

ЗАКЛЮЧЕНИЕ И БЛАГОДАРНОСТИ

В рамках данной работы была исследована возможность применения глубоких сверточных сетей в задачах классификации биологических объектов по мультиспектральным измерениям при небольших объемах обучающих данных. Предложенный алгоритм классификации в задачах выявления ЭЗС пшеницы, пораженных фузариозом, и определения сортовой принадлежности, на основе глубокой сети с двумя сверточными слоями позволил добиться точности классификации выше 99 % что превосходит результаты для традиционных нейронных сетей, полученные авторами ранее.

Применение дополнительных методов повышения точности классификации, таких как

одновременный анализ спектральных данных двух типов или перенос обучения после предварительного обучения сверточной сети по данным для близкой по физической природе задаче, не дает однозначного выигрыша для всех типов данных, однако в ряде случаев все же позволяет повысить точность классификации на величину до 4 %. При этом удалось показать эффективность применения технологии переноса обучения как потенциально-го способа быстрого переобучения алгоритма классификации спектральных измерений под «новую задачу» в условиях малой выборки. Более детальное изучение особенностей применения технологии переноса обучения в глубоких сетях, а также его сочетание с другими методами, в частности, методами искусственного размножения обучающих данных, представляются перспективным направлением для дальнейших исследований.

Результаты работы получены в рамках выполнения государственного задания Минобрнауки России по проекту № 8.3844.2017/4.6 «Разработка средств экспресс-анализа и классификации элементов неоднородного потока зерновых смесей с патологиями на основе интеграции методов спектрального анализа и машинного обучения».

СПИСОК ЛИТЕРАТУРЫ

1. LeCun, Y. Deep Learning / Y. LeCun, Y. Bengio, G. Hinton // Nature. – 2015. – V. 521 – P. 436–444. – DOI: 10.1038/nature14539.
2. Bengio, Y. Representation Learning: A Review and New Perspectives / Y. Bengio, A. Cour-

- ville, P. Vincent // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2013. – V. 35. – P. 1798–1828. – DOI: 10.1109/TPAMI.2013.50.
3. *Hinton, G. E.* Reducing the dimensionality of data with neural networks / G. E. Hinton, R. Salakhutdinov // Science. – 2006. – V. 313(5786) – P. 504–507. – DOI: 10.1126/science.1127647.
4. *Bengio, Y.* Greedy layer-wise training of deep networks / Y. Bengio, P. Lamblin, D. Popovici, H. Larochelle // In Proc. Advances in Neural Information Processing Systems. – 2007. – V. 19
5. *Bengio, Y.* Deep learning of representations for unsupervised and transfer learning / Y. Bengio // JMLR W&CP: Proc. Unsupervised and Transfer Learning. – 2012.
6. *Krizhevsky, A.* ImageNet classification with deep convolutional neural networks / A. Krizhevsky, I. Sutskever, G. Hinton // In Proc. Advances in Neural Information Processing Systems. – 2012. – V. 25 – P. 1090–1098. – DOI: 10.1145/3065386.
7. *Farabet, C.* Learning hierarchical features for scene labeling / C. Farabet, C. Couprie, L. Najman, Y. LeCun // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2013. – V. 35 – P. 1915–1929. – DOI: 10.1109/TPAMI.2012.231.
8. *Tompson, J.* Joint training of a convolutional network and a graphical model for human pose estimation / J. Tompson, A. Jain, Y. LeCun, C. Bregler. // In Proc. Advances in Neural Information Processing Systems. – 2014. – V. 27 – P. 1799–1807.
9. *Szegedy, C.* Going deeper with convolution / C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. E. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich // IEEE Conference on Computer Vision and Pattern Recognition. – 2015. – P. 1–9. – DOI: 10.1109/CVPR.2015.7298594.
10. *Mikolov, T.* Strategies for training large scale neural network language models / T. Mikolov, A. Deoras, D. Povey, L. Burget, J. Cernocky // In Proc. Automatic Speech Recognition and Understanding. – 2011. – P. 196–201. – DOI: 10.1109/ASRU.2011.6163930.
11. *Hinton, G.* Deep neural networks for acoustic modeling in speech recognition / G. Hinton, L. Deng, D. Yu, G. Dahl, A.-R. Mohamed, N. Jaitly, A. Senior, V. Vanhoucke, P. Nguyen, T. Sainath, B. Kingsbury // IEEE Signal Processing Magazine. – 2012. – V. 29 – P. 82–97. – DOI: 10.1109/MSP.2012.2205597.
12. *Sainath, T.* Deep convolutional neural networks for LVCSR / T. Sainath, A.-R. Mohamed, B. Kingsbury, B. Ramabhadran // In Proc. Acoustics, Speech and Signal Processing. – 2013. – P. 8614–8618. – DOI: 10.1109/ICASSP.2013.6639347.
13. *Leung, M. K.* Deep learning of the tissue-regulated splicing code / M. K. Leung, H. Y. Xiong, L. J. Lee, B. J. Frey // Bioinformatics. – 2014. – V. 30 – P. i121–i129. – DOI: 10.1093/bioinformatics/btu277.
14. *Ciodaro, T.* Online particle detection with neural networks based on topological calorimetry information / T. Ciodaro, D. Deva, J. de Seixas, D. Damazio // Journal of Physics: Conference Series. – 2012. – V. 368 – DOI: 10.1088/1742-6596/368/1/012030.
15. *Itakura, K.* Estimation of Citrus Maturity with Florescence Spectroscopy Using Deep Learning / K. Itakura, Y. Saito, T. Suzuki, N. Kon-do, F. Hosoi // Horticulturae. – 2018. – V. 5. – DOI: 10.3390/horticulturae5010002
16. *Liu, L.* Transfer learning for soil spectroscopy based on convolutional neural networks and its application in soil clay content mapping using hyperspectral imagery / L. Liu, M. Ji, M. Buchroithner // Sensors. – 2018. – V. 18(3169). – DOI: 10.3390/s18093169.
17. *Chatzidakis, M.* Towards calibration-invariant spectroscopy using deep learning / M. Chatzidakis, G.A. Botton // Scientific Reports. – 2019. – V. 9(2126). – DOI: 10.1038/s41598-019-38482-1.
18. *Tan, C.* A Survey on Deep Transfer Learning / C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, C. Liu // In Proc. 27th International Conference on Artificial Neural Networks, Rhodes, Greece, October 4–7, 2018, Part III. – 2018. – DOI: 10.1007/978-3-030-01424-7_27.
19. *Wang, J.* The effectiveness of data augmentation in image classification using deep learning / J. Wang, L. Perez // Stanford University research report. – 2017.

20. Fadaee, M. Data Augmentation for Low-Resource Neural Machine Translation / M. Fadaee, A. Bisazza, C. Monz // In Proc. 55th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers) – 2017. – P. 567–573. – DOI: 10.18653/v1/P17-2090.

21. Акимов, А. В. Модели и алгоритмы искусственного размножения данных для обучения алгоритмов распознавания лиц методом Виолы–Джонса / А. В. Акимов, А. А. Сирота // Компьютерная оптика. – 2016. – Т. 40, № 6. – С. 911–918. – DOI: 10.18287/2412-6179-2016-40-6-911-918.

22. Donskikh, A. O. Optical methods of identifying the varieties of the components of grain mixtures based on using artificial neural networks for data analysis / A. O. Donskikh, D. A. Minakov, A.A. Sirota // Journal of Theoretical and Applied Information Technology – 2018. – Vol. 96 (2) – P. 534–542.

23. Algazinov, E. K. Compound methods of spectral analysis of nonuniform flow of grain mixtures / E. K. Algazinov, A. O. Donskikh, D. A. Minakov, A. A. Sirota // Measurement Techniques. – 2019. – V. 61(12) – P. 1187–1195. – DOI: 10.1007/s11018-019-01568-3.

Донских А. О. – аспирант кафедры Технологий обработки и защиты информации, факультет компьютерных наук, Воронежский государственный университет.
E-mail: a.donskikh@outlook.com

Сирота А. А. – д. т. н., профессор, заведующий кафедрой Технологий обработки и защиты информации, факультет компьютерных наук, Воронежский государственный университет, Россия, Воронеж. E-mail: sir@cs.vsu.ru

TRAINING OF DEEP NEURAL NETWORKS FOR CLASSIFICATION OF BIOLOGICAL OBJECTS BASED ON SPECTRAL MEASUREMENTS

A. O. Donskikh, A. A. Sirota

Voronezh State University

Annotation. The possibility of using deep neural networks for processing multispectral measurements in the classification of biological objects with specific pathologies is estimated. Convolutional neural networks accepting as an input multiple spectral functions (amplitude and frequency dependencies) retrieved simultaneously for each object using various spectral methods (reflection, transmission) or different wavelength ranges. The structure of a deep network with two convolutional layers and two fully connected layers for classifying wheat seeds in order to identify grains affected by fungal diseases and to identify the variety of the seeds is described. A method for improving the quality of network learning based on applying transfer learning method after training on artificially generated data is proposed. A comparison of the classification results obtained for reflection and transmission spectra of elements of grain mixtures with traditional deep learning approaches (for each spectral method separately), with learning on data for two spectral methods (simultaneous processing of two data channels representing the transmission and reflection spectra), and with the proposed transfer learning-based method is provided.

Keywords: deep neural networks, convolutional networks, transfer learning, spectral measurements, machine learning.

Donskikh A. O. – Postgraduate Student, Department of Processing Technology and Information Security, Computer Sciences Faculty, Voronezh State University. E-mail: a.donskikh@outlook.com

Sirota A. A. – Doctor of Technical Sciences, Professor, Head of Department of Processing Technology and Information Security, Computer Sciences Faculty, Voronezh State University, Russia, Voronezh. E-mail: sir@cs.vsu.ru