

**Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение
высшего образования
«Сибирский государственный индустриальный университет»
Администрация Правительства Кузбасса
Администрация г. Новокузнецка
Институт проблем управления им. Трапезникова РАН
Федеральный исследовательский центр угля и углехимии СО РАН
АНО «Научно-образовательный центр «Кузбасс»**

**СИСТЕМЫ АВТОМАТИЗАЦИИ
(в образовании, науке и производстве)
AS' 2023**

**ТРУДЫ ВСЕРОССИЙСКОЙ НАУЧНО–ПРАКТИЧЕСКОЙ
КОНФЕРЕНЦИИ
(с международным участием)**

12-14 декабря 2023 г.

**Новокузнецк
2023**

УДК 658.011.56
С 409

Редакционная коллегия:

д.т.н., проф. В.В. Зимин (ответственный редактор),
д.т.н., проф. С.М. Кулаков, к.т.н., доц. В.А. Кубарев,
д.т.н., проф. Л.Д. Павлова, д.т.н., доц. И.А. Рыбенко,
к.т.н., доц. В.И. Кожемяченко (технический редактор).

С 409 Системы автоматизации (в образовании, науке и производстве) AS'2023: труды Всероссийской научно–практической конференции (с международным участием), 12-14 декабря 2023 г. / Министерство науки и высшего образования Российской Федерации, Сибирский государственный индустриальный университет ; под общ. ред. В.В. Зимина. – Новокузнецк : Издательский центр СибГИУ, 2023. – 420 с.

ISBN 978-5-7806-0583-6

Труды конференции посвящены научным и практическим вопросам в области современных систем автоматизации и информатизации учебных, исследовательских и производственных процессов. Представлены результаты исследования, разработки и внедрения методического, математического, программного, технического и организационного обеспечения систем автоматизации и информационно-управляющих систем в различных сферах деятельности.

Сборник трудов ориентирован на широкий круг исследователей, научных работников, инженерно-технический персонал предприятий и научно-исследовательских лабораторий, преподавателей вузов, аспирантов и обучающихся по программам бакалавриата и магистратуры.

УДК 658.011.56

© Сибирский государственный
индустриальный университет, 2023

6. Александрова М.Ю. Методы классификации текстовых данных: можно ли потенциал количественного анализа использовать в качественном исследовании? // Интеракция. Интервью. Интерпретация. 2021. Т. 13. № 2. С. 81–96. DOI: <https://doi.org/10.19181/inter.2021.13.2.5>
7. Двойникова А.А., Карпов А.А. Аналитический обзор подходов к распознаванию тональности русскоязычных текстовых данных // Информационно-управляющие системы. – 2020. – №. 4 (107). – С. 20-30.

УДК 004.93

DOI: 10.36622/VSTU.2023.88.3.001

ИСПОЛЬЗОВАНИЕ СЕГМЕНТАЦИИ ДЛЯ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Бычков А.Г., Киселева Т.В., Маслова Е.В.

ФГБОУ ВО «Сибирский государственный индустриальный университет»
г. Новокузнецк, Россия, aleksds1@yandex.ru

Аннотация. В работе рассматриваются структура метода сегментации свёрточной нейронной сети и математические методы, используемые для подсчёта её значений. Приведены основные составные части сети, влияющие на результат при использовании данного метода.

Ключевые слова: свёрточные нейронные сети, распознавание образов, сегментация, точность работы.

Abstract. The paper discusses the structure of the convolutional neural network segmentation method and the mathematical methods used to calculate its values. The main components of the network that influence the result when using this method are given.

Keywords: convolutional neural networks, pattern recognition, segmentation, accuracy.

Введение

Машинное обучение (англ. machine learning, ML) – класс методов искусственного интеллекта, характерной чертой которых является не прямое решение задачи, а обучение в процессе применения решений множества сходных задач. Для построения таких методов используются средства математической статистики, численных методов, методов оптимизации, теории вероятностей, теории графов, различные техники работы с данными в цифровой форме. Искусственный интеллект сыграл колоссальную роль в преодолении разрыва между возможностями людей и машин. Как исследователи, так и энтузиасты работают над многочисленными аспектами этой области, добиваясь удивительных результатов. Примером может служить компьютерное зрение. Одним из самых важных видов машинного обучения в компьютерном зрении являются свёрточные нейронные сети [1]. Основные задачи, решаемые ими, состоят в сегментации и детекции.

1. Метод сегментации в нейронных сетях

Подавляющее число ранних исследований в этой области было связано с классификацией. Сначала бинарной, а потом и многовариантной, но всё же классификацией одного объекта. Например, на изображении с котом есть не только кот, но и окно, горшок и т.п. Кроме того, у того же кота есть лапы, хвост и т.д. Возникла потребность извлекать автоматически больше информации. Поэтому и возникла задача сегментации. На рисунке 1 приведен пример работы сегментации.

Про сегментацию можно думать как про попиксельную классификацию. На вход подаётся растровое изображение (из пикселей). На изображении выше (рисунок 1) с левой стороны приведён пример с вождением автомобиля: деревья, светофоры, машины, люди. На выходе должно получиться некое подобие того, что на правой стороне изображения. То есть, изображение того же размера, но вместо каждого пикселя предсказывает-

ся, какой класс у объекта. То есть, можно говорить про каждый пиксель как независимый классификатор [2].



Рисунок 1 – Результат работы сегментации

В рамках прошлых задач в данной ситуации у нас была бы задача по типу «на вход подаётся изображение 1000x1000 пикселей, надо найти, есть ли на нём автомобиль, на выходе имеем один бит 1 или 0 (есть или нет) или некоторое число, отображающее вероятность наличия автомобиля на изображении». В рамках задачи сегментации на выходе будет 1000x1000 пиксельных классификаторов. В этом случае в процессе backpropagation сеть получает гораздо больше обратной связи, что приводит к тому, что сегментация требует гораздо меньшего объёма тренировочных данных.

Для оценки эффективности работы сегментации используют различные метрики. Применение Precision и Recall не позволяет достичь желаемых результатов. Самые часто используемые – Dice и Jaccard (Intersection over Union – IoU) [3] как это показано на рисунке 2. На рисунке A – ground-truth, а B – предсказание.

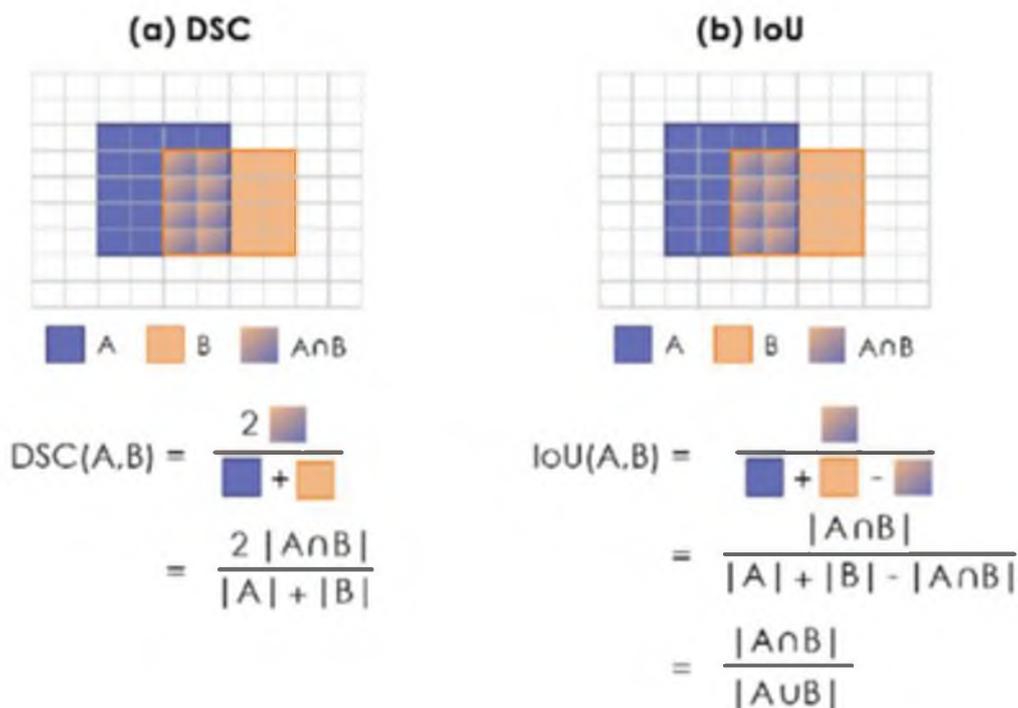


Рисунок 2 – Оценки эффективности CNN

Ground-truth в таком случае будет некоей маской для изображения, которая поясняет, что данный конкретный пиксель принадлежит конкретному объекту. Условно, в задаче определения машин на изображении (машинное зрение при создании автопилотов) пиксели, принадлежащие машине, будут иметь 1, а не принадлежащие – 0. Получается некоторая двумерная матрица из нулей и единиц. Предсказание тоже в таком случае будет формировать такую же по размеру матрицу из нулей и единиц. Метрики же позволяют рассчитать разными способами, насколько эффективным было такое предсказание. На сегодняшний день Dice чаще всего используется в медицинских снимках [4], тогда как в остальных случаях обычно используют Jaccard (IoU) как самую интуитивно понятную метрику.

Важным отличием нейронных сетей для задач сегментации от обычных CNN является уход от Dense-слоёв, то есть, от fully-connected слоёв (рисунок 3).

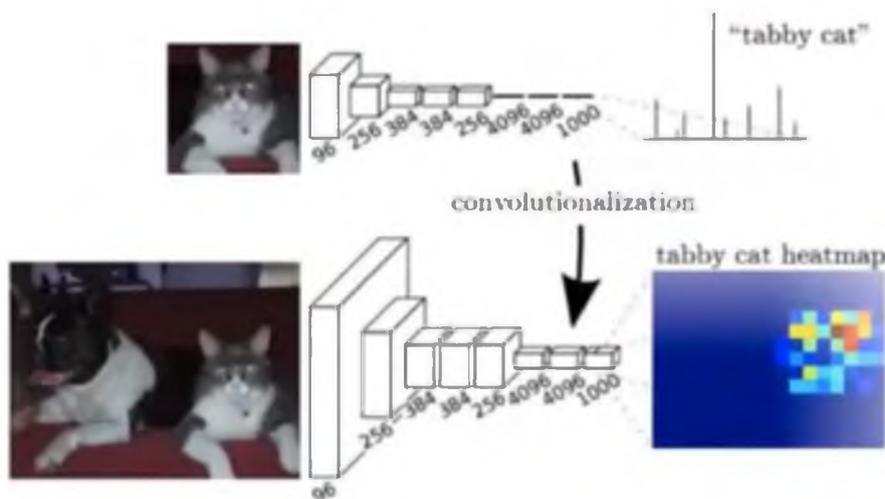


Рисунок 3 – Схема FCN

Такая сеть получила название Fully Convolutional Network (FCN). Для получения FCN из обычной CNN необходимо либо полностью убрать fully-connected слои, либо изменить их на convolutional слои. В итоге вместо вероятностей принадлежности изображения к определённому классу получается некоторая feature map, которая показывает, какие части изображения соответствуют требуемому классу. Иначе говоря, на вход подаётся изображение, а на выходе вместо вероятностей получается другое изображение/матрица.

Стоит отметить, что в таких сетях резко уменьшается число параметров, так как в CNN все расчёты обычно выполняются в convolutional слоях, а параметры хранятся в dense слоях [1]. Это позволяет как уменьшить требуемое число входных данных (вместо десятков тысяч изображений можно обойтись тысячами или даже сотнями), так и уменьшить время, затрачиваемое на обучение. Ещё одним достоинством FCN является то, что с помощью их на вход можно подавать изображения любого размера [5].

Классическая CNN проходит по изображению не самым эффективным способом. «Движущееся окно» – kernel – просто проходит шаг за шагом, строка за строкой исходное изображение, что может занимать много времени. В FCN этот процесс более эффективен: он позволяет не проходить каждый элемент исходного изображения, а брать неповторяющиеся или минимально повторяющиеся части (рисунок 4). Процесс очень похож на обычный подход, но берётся большее изображение при сохранении.

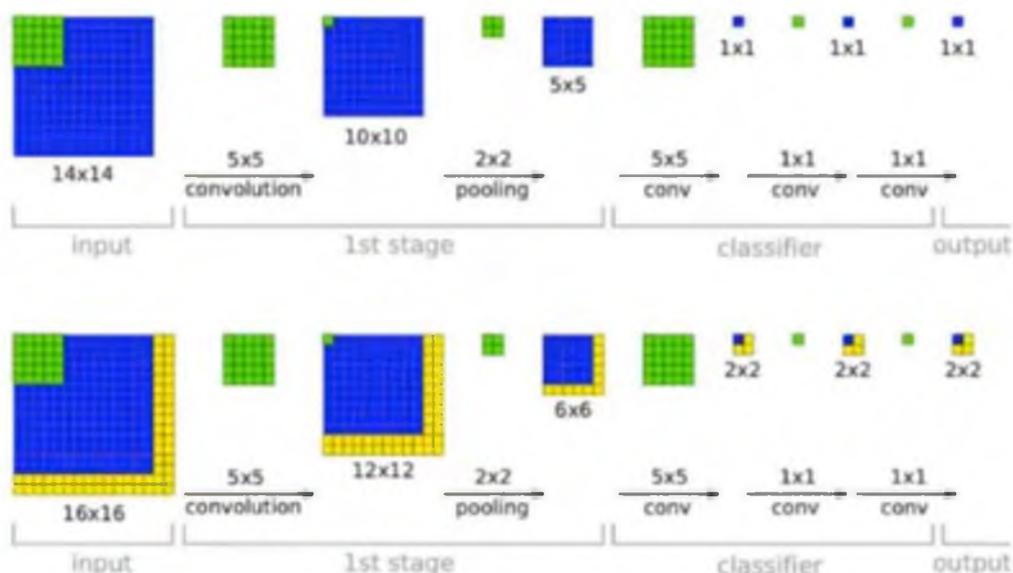


Рисунок 4 – Схема движущегося окна в FCN

Если задача ставится шире, чем определение наличия или отсутствия какого-либо класса, то есть, в случае небинарной классификации, в FCN дополнительно, кроме прочих операций, надо добавить слой upsampling [4], как это отражено на рисунке 5.

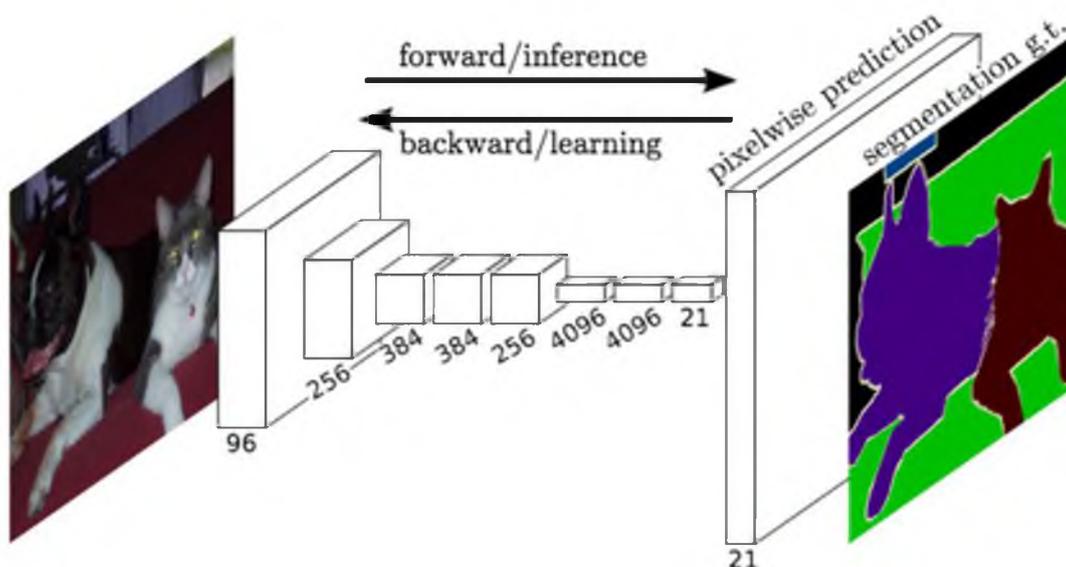


Рисунок 5 – Финальная схема FCN с upsampling

То есть, мы увеличиваем heatmap до исходного размера для корректного определения объектов. Впервые такой подход был использован в 2015 в сети под названием FCN8 [6]. Есть разные методы upsampling, но обычно используют либо nearest neighbor upsampling или bilinear upsampling. Дальше были улучшения FCN8 до SegNet в виде добавления иерархического upsampling как это показано на рисунке 6 [2].

Следующим шагом по улучшению работоспособности SegNet стало добавление skip-connections (наподобие ResNet) в виде сети UNet [7]. Пример показан на рисунке 7.

Сеть содержит сверточную (слева) и разверточную части (справа), поэтому архитектура похожа на букву U, что и отражено в названии. На каждом шаге количество каналов признаков удваивается.

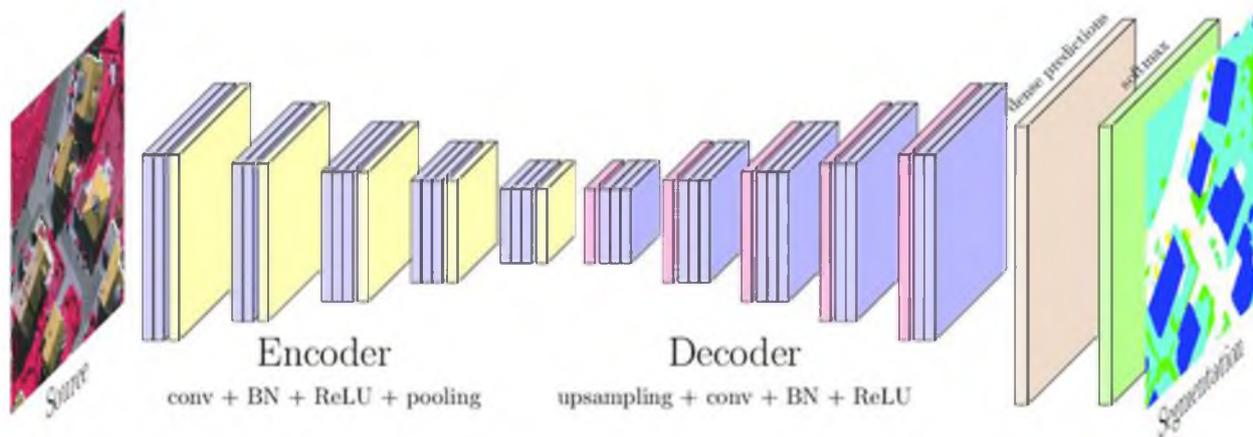


Рисунок 6 – Схема SegNet

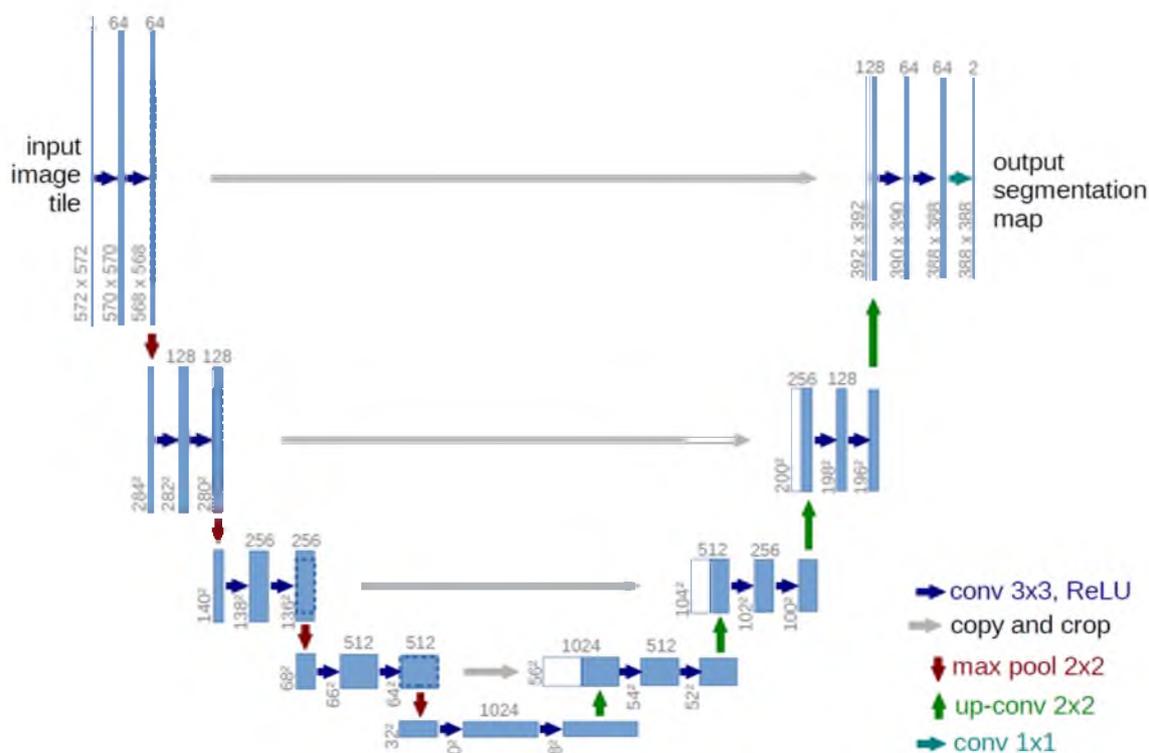


Рисунок 7 – Схема U-Net

Сверточная часть похожа на обычную свёрточную сеть, он содержит два подряд свёрточных слоя 3×3 , после которых идет слой ReLU и пулинг с функцией максимума 2×2 с шагом 2.

Каждый шаг разверточной части содержит слой, обратный пулингу, который расширяет карту признаков, после которого следует свертка 2×2 , которая уменьшает количество каналов признаков. После этого идет конкатенация с соответствующим образом обрезанной картой признаков из сжимающего пути и две свертки 3×3 , после каждой из которой следует ReLU. Обрезка нужна для того, чтобы не потерять пограничные пиксели в каждой свёртке. На последнем слое свертка 1×1 используется для приведения каждого 64-компонентного вектора признаков до требуемого количества классов. Всего сеть имеет 23 свёрточных слоя [5].

Данная архитектура на сегодняшний день является одной из самых распространённых для решения задач с повышенной точностью. Сеть UNet способна давать требуе-

мые результаты на медицинских снимках, находить объекты размером в пару пикселей на больших изображениях и т.п.

Следующим шагом является использование весов с заранее предобученных сетей. К примеру, разработанная в 2018 году русскими программистами TerausNet представляет собой тот же UNet, но с весами в encoder от предобученной VGG-11 на датасете ImageNet [8].

В итоге на сегодняшний день любая задача бинарной сегментации сводится к UNet. Будь то либо поиск поражённых тканей в медицине или поиск строений на спутниковых снимках (рисунок 8), в большинстве случаев задача решается с помощью данной архитектуры.

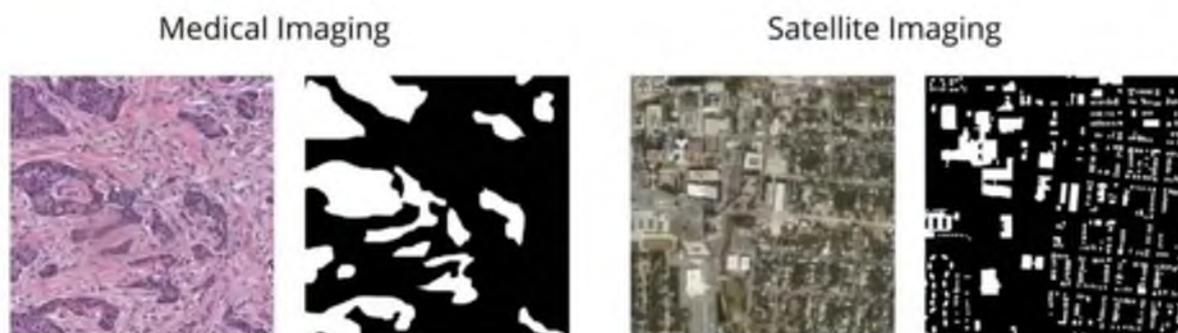


Рисунок 8 – Пример задачи определения объектов на картах

Среди прочих применений сегментации можно выделить Depth Estimation – определение расстояния до объекта по двумерному изображению, когда определяется не класс пикселя, а происходит сведение к регрессии, Optical Flow – определение вектора движения объекта по статическому изображению.

Ещё одним полезным инструментом для работы с FCN является Feature Pyramid Networks (FPN) ((d) на рисунке 9).

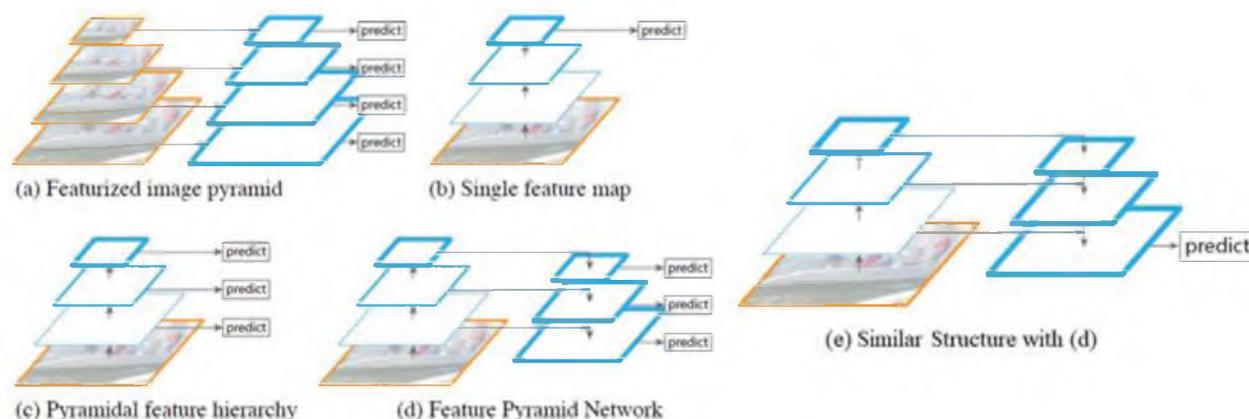


Рисунок 9 – Схемы возможных способов решения проблемы масштабирования

Использование данного инструмента позволяет решить проблему с масштабированием [5]. То есть, если сеть натренирована на поиск объектов одного масштаба, то при подаче того же объекта, но другого масштаба (объект меньше или больше, чем то, к чему привыкла сеть), то сеть не всегда корректно будет определять данный объект.

Для решения этой проблемы при обучении сначала было предложено активно применять неоднократную аугментацию исходных изображений по масштабу. То есть, много раз изменять размер исходного изображения. Это помогает, но не до конца: точ-

ность всё равно оставляет желать лучшего. Тогда были предложены различные способы улучшения качества прогнозирования. Самые часто используемые из них представлены на рисунке 9. Например, (е) является копией UNet с её skip-connections. А вот на (d), кроме всего прочего, предлагается снимать прогнозирования на каждом шаге decoder и смотреть на средний результат или же производить другую обработку [9]. Собственно, финальная схема UNet + FPN представлена на рисунке 10.

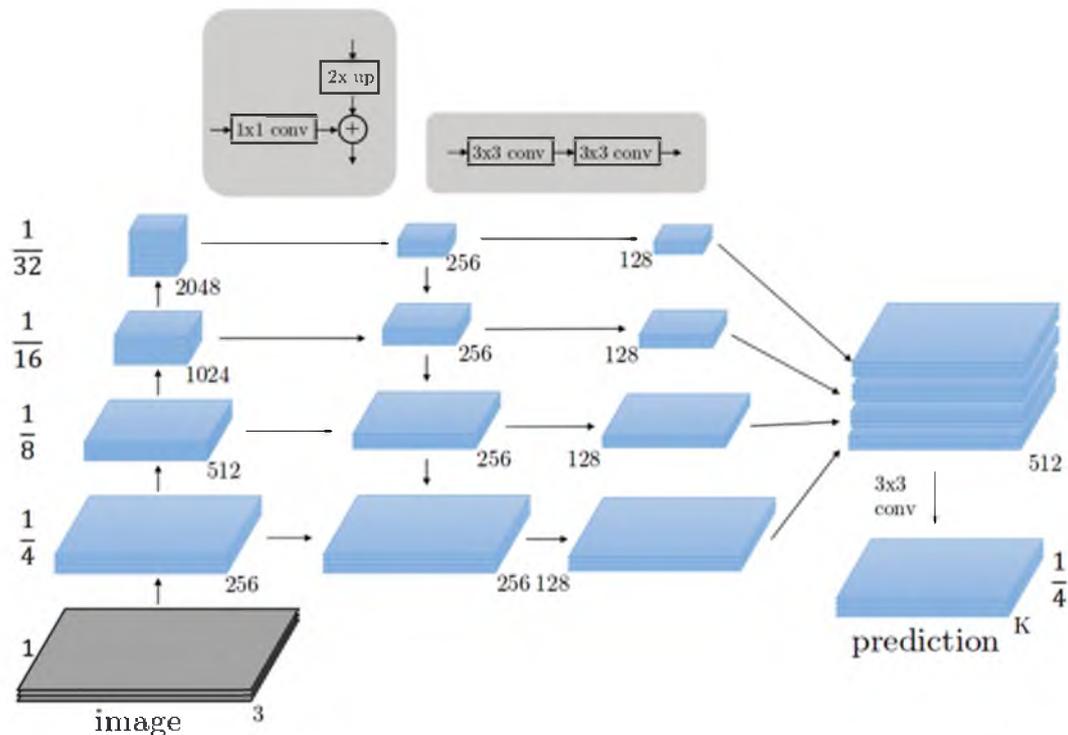


Рисунок 10 – Схема U-Net с применением FPN

Для обучения необходима функция потерь. Так как сегментацию можно рассматривать как попиксельную классификацию, то нужно внести изменения в формулы для расчёта [10]. Самым простым, пусть и затратным с точки зрения машинного времени, является рассматривание каждого пикселя. То есть, каждый пиксель рассчитывается как отдельный классификатор (с вычислением loss-функции), а потом значения всех этих классификаторов усредняются. Затратно это потому, что в случае с исходным изображением 1000x1000 необходимо рассчитать 1000000 классификаторов. В качестве loss-функции обычно используется либо Binary Cross Entropy (BCE) в случае бинарной классификации, либо Categorical Cross Entropy (CCE) в случае, когда число классов превышает 2.

Пример CCE представлен в виде формулы (1):

$$CCE = -\sum_c y(c) \cdot \log p(c), \quad (1)$$

- где c – порядковый номер класса;
 $y(c)$ – целевое значение (ground truth) этого класса;
 $p(c)$ – рассчитанная вероятность получения этого класса.

Выводы

В статье было рассмотрено текущее состояние области задач сегментации искусственного интеллекта. Особенность задач искусственного интеллекта состоит в том, что, как только эти задачи будут решены, они переходят в разряд задач обычного вычисления.

Показана история развития сверточных нейросетей на основе сегментации и детекции, их эволюция. Описаны методы, которые были использованы для повышения эффективности работы сетей.

Библиографический список

1. Киселева, Т.В., Маслова Е.В., Бычков А.Г. Машинное обучение для решения задач распознавания образов. В кн.: Сборник трудов 50-ой Международной конференции по информационным технологиям в науке, образовании и управлении. Гурзуф, 2021 // ИТНОУ. 2021. № 2 (18). С. 19-24.
2. Киселева, Т.В., Е.В. Маслова, А.Г. Бычков. Машинное обучение в задачах распознавания изображений // Информатизация и связь. 2021. № 8. С. 15-19.
3. J. Long, E. Shelhamer, T. Darrell: The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, pp. 3431-3440.
4. V. Badrinarayanan, A. Kendall, R. Cipolla: «SegNet: A deep convolutional encoder-decoder architecture for image segmentation», arXiv:1511.00561, 2015.
5. O. Ronneberger, P. Fischer, T. Brox: «U-net: Convolutional networks for biomedical image segmentation», Proc. Med. Image Comput. Comput.-Assisted Intervention pp. 234-241, 2015.
6. Бычков, А.Г., Киселева Т.В., Маслова Е.В. Использование сегментации в сверточных нейронных сетях для повышения точности. // Системы управления и информационные технологии. 2022. №3 (89). С. 7 – 10.
7. V. Iglovikov, A. Shvets: «TernausNet: U-net with vgg11 encoder pre-trained on imagenet for image segmentation», arXiv:1801.05746, 2018.
8. TY. Lin, P. Dollar, R. Girshick, K. He, D. Hariharan, S. Belongie: The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, pp. 2117-2125.
9. M. Berman, A. Rannen-Triki, M. Blaschko: The lovasz-softmax loss: a tractable surrogate for the optimization of the intersection-over-union measure in neural networks, The IEEE conference on Computer Vision and Pattern Recognition, 2018, pp. 4413-4421.
10. M. Yeung, E. Sala, CB. Schonlieb, L. Rundo: Unified Focal loss: Generalising Dice and cross entropy-based losses to handle class imbalanced medical image segmentation, Computerized Medical Imaging and Graphics, 2022, article 102026.

УДК 519.6

ИССЛЕДОВАНИЕ МЕТОДОВ ЗАЩИТЫ ДАННЫХ ОТ УТЕЧЕК В СИСТЕМАХ DLP НА ПРИМЕРЕ КРЕДИТНЫХ ОРГАНИЗАЦИЙ

Чернова Л.В.

ФГБОУ ВО «Сибирский государственный индустриальный университет»
г. Новокузнецк, Россия, lilekm095@mail.ru

Аннотация. Кредитные организации собирают, обрабатывают и хранят большой объем конфиденциальной информации своих клиентов и сотрудников. Утечка такой информации может привести к серьезным финансовым потерям и потере доверия со стороны клиентов. Для защиты от утечек конфиденциальной информации в кредитных организациях широко используются системы предотвращения утечек данных (DLP). В статье проведено исследование методов защиты от утечек данных в системах DLP на примере кредитных организаций.

Ключевые слова: DLP-системы; утечка данных, методы защиты, кредитные организации; конфиденциальная информация.

Abstract. Credit organizations collect, process and store a large amount of confidential information of their customers and employees. Leakage of such information can lead to serious financial losses and loss of trust on the part of customers. Data leak prevention systems (DLP) are widely used in credit institutions to protect against leaks of confidential information. The article examines the methods of protection against data leaks in DLP systems on the example of credit institutions.

<i>Павлова Л.Д., Фрянов В.Н.</i> Алгоритм численной оценки эксплуатационной устойчивости подготовительных выработок на наклонных угольных пластах	208
<i>Лисиенко В.Г., Чесноков Ю.Н., Лантева А.В.</i> Автоматизация производства и искусственный интеллект	216
СЕКЦИЯ 3. ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ В УПРАВЛЕНИИ ОРГАНИЗАЦИОННЫМИ СИСТЕМАМИ	
<i>Буркова И.В.</i> Минимизация затрат в проектах на основе мягких зависимостей	219
<i>Жилина Н.М.</i> Демографические показатели современной России в международном сравнении	224
<i>Каиркенов Х.К., Зимин А.В.</i> Формирование программ развития в организациях с многоцелевыми проектами	230
<i>Прохоров И.М.</i> Функциональная структура саморазвивающейся системы управления техническим обслуживанием и ремонтами оборудования промышленного предприятия	240
<i>Гасымов Р.Р., Рыбенко И.А., Куценко А.И.</i> Проектирование информационной системы формирования плана финансово-хозяйственной деятельности университета	243
<i>Бабичева Н.Б., Кирчева А.С., Мамедов И.В.</i> Применение цифрового следа в построении непрерывной образовательной траектории	248
<i>Бычков А.Г., Киселева Т.В., Маслова Е.В.</i> Использование сегментации для повышения эффективности свёрточных нейронных сетей	254
<i>Чернова Л.В.</i> Исследование методов защиты данных от утечек в системах DLP на примере кредитных организаций	261
<i>Батенков К.А.</i> Основа определения оперативных норм на параметры ошибок каналов и трактов плезиохронной цифровой иерархии	265
<i>Васянин А.К., Калашников С.Н.</i> Управление порожними вагонопотоками в железнодорожном узле металлургического комбината	267
<i>Кузнецова Е.С., Кузьмина С.Ю., Кузьмин С.А.</i> Интеллектуальный учет электроэнергии основа перехода к цифровизации в электроэнергетике	271
<i>Кузнецова Е.С., Долгих Р.В., Захаров А.В.</i> Разработка системы прогнозирования состояния работы электрооборудования	275
<i>Купчик Б.М., Новиков А.А., Заверячев С.А., Коровин Е.В., Купчик М.Б.</i> Принятие управленческих решений в здравоохранении на основе автоматизированной системы анализа доказанной эффективности	

Научное издание

**СИСТЕМЫ АВТОМАТИЗАЦИИ
(в образовании, науке и производстве)
AS' 2023**

**ТРУДЫ ВСЕРОССИЙСКОЙ НАУЧНО–ПРАКТИЧЕСКОЙ
КОНФЕРЕНЦИИ**
(с международным участием)

12-14 декабря 2023 г.

Под общей редакцией д.т.н., доц. В.В. Зимина

Техническое редактирование и компьютерная верстка В.И. Кожемяченко

Подписано в печать 01.12.2023 г.

Формат бумаги 60×84 1/16. Бумага писчая. Печать цифровая.

Усл. печ. л. 25.04. Уч.-изд. л. 26.64. Тираж 20 экз. Заказ 260.

Сибирский государственный индустриальный университет
654007, Кемеровская область – Кузбасс, г. Новокузнецк, ул. Кирова, зд. 42.

Издательский центр СибГИУ