



GraphiCon 2018

28-я Международная конференция
по компьютерной графике
и машинному зрению

Труды конференции

GraphiCon 2018

28th International Conference
on Computer Graphics and Vision

Conference Proceedings

Национальный исследовательский Томский политехнический университет,
Томский государственный университет систем управления и радиоэлектроники
Томск, 24–27 сентября 2018 года
<http://2018.graphicon.ru/>

УДК 004.92
ББК 32.973.26-018.2
G73

G73 **GraphiCon 2018:** труды 28-й Междунар. конф. по компьютерной графике и машинному зрению Томск, 24–27 сент., 2018 г.) / Нац. исслед. Том. политех. ун-т. – Томск, 2018. – 511 с.

ISSN 2618-8317

Настоящий сборник содержит материалы 28-й Международной конференции по компьютерной графике и машинному зрению. В её подготовке и проведении участвовали специалисты ведущих организаций, отраслевых и академических научно-исследовательских институтов, а также высшей школы.

Цикл «GraphiCon» представляет собой регулярные ежегодные конференции. Он служит международным форумом для исследователей и разработчиков со всего мира, целью которого является обмен новыми идеями, знаниями и опытом в области компьютерной графики, машинного зрения, обработки изображений, систем визуализации и виртуального окружения, систем поддержки принятия решений, облачных вычислений и обработки больших массивов данных.

В сборник включены приглашенные, пленарные и секционные доклады конференции.

Адресуется сотрудникам научно-исследовательских и образовательных организаций, предприятиям ИТ-индустрии, аспирантам, студентам, а также широкому кругу читателей.

УДК 004.92
ББК 32.973.26-018.2

ISSN 2618-8317

Организационный комитет

Захарова Алёна Александровна ТПУ	Ротков Сергей Игоревич ННГАСУ	Мамонтов Геннадий Яковлевич ТПУ
Галактионов Владимир Александрович ИПМ им. М.В. Келдыша РАН	Турлапов Вадим Евгеньевич ННГУ	Масленникова Алла Александровна МГУ
Берберова Мария Александровна МФТИ	Берберова Мария Александровна МФТИ	Медовник Александр Владимирович ТУСУР
Бондарев Александр Евгеньевич ИПМ им. М.В. Келдыша РАН	Будак Владимир Павлович МЭИ	Мещеряков Роман Валерьевич ТУСУР
Волобой Алексей Геннадьевич ИПМ им. М.В. Келдыша РАН	Вехтер Евгения Викторовна ТПУ	Небаба Степан Геннадьевич ТПУ
Евсютин Олег Олегович ТУСУР	Гергет Ольга Михайловна ТПУ	Ризен Юлия Сергеевна ТПУ
Ерёменко Евгений Николаевич ООО «Неогеография»	Губин Владимир Евгеньевич ТПУ	Серяков Вадим Александрович ТПУ
Завьялов Дмитрий Алексеевич ТПУ	Карпов Леонид Евгеньевич ИСП РАН	Шкляр Алексей Викторович ТПУ
Конушин Антон Сергеевич МГУ	Катаев Михаил Юрьевич ТУСУР	Юрченкова Елена Анатольевна ТУСУР
Крылов Андрей Серджевич МГУ	Кочегуров Александр Иванович ТПУ	Яковлев Алексей Николаевич ТПУ

Программный комитет

Авербух Владимир Лазаревич ИММ УрО РАН	Выголов Олег Вячеславович ГосНИИАС	Знаменская Ирина Александровна МГУ
Арлазаров Владимир Викторович Smart Engines	Галактионов Владимир Александрович ИПМ им. М.В. Келдыша РАН	Игнатенко Алексей Викторович МГУ
Баринова Ольга Вячеславовна МГУ	Гергет Ольга Михайловна ТПУ	Катаев Михаил Юрьевич ТУСУР
Барладян Борис Хаимович ИПМ им. М.В. Келдыша РАН	Горбачев Вадим ГосНИИАС	Конушин Антон Сергеевич МГУ
Бобков Валерий Александрович ИАПУ ДВО РАН	Давыдова Евгения Михайловна ТПУ	Копылов Андрей Валерьевич ТулГУ
Бондарев Александр Евгеньевич ИПМ им. М.В. Келдыша РАН	Дебелов Виктор Алексеевич ИВМиМГ СО РАН	Крылов Андрей Серджевич МГУ
Будак Владимир Павлович МЭИ	Дышкант Наталья Фёдоровна МГУ	Кустикова Валентина Дмитриевна ННГУ
Ватолин Дмитрий Сергеевич МГУ	Евсютин Олег Олегович ТУСУР	Местецкий Леонид Моисеевич МГУ
Волобой Алексей Геннадьевич ИПМ им. М.В. Келдыша РАН	Ерёменко Евгений Николаевич ООО «Неогеография»	Мещеряков Роман Валерьевич ТУСУР
Велижев Александр МГУ	Ерофеев Михаил Викторович МГУ	Михайлук Михаил Васильевич НИИСИ РАН
Вехтер Евгения Викторовна ТПУ	Ерухимов Виктор Itseez	Насонов Андрей Владимирович МГУ
Визильтер Юрий Валентинович ГосНИИАС	Жданов Дмитрий Дмитриевич ГОИ	Небаба Степан Геннадьевич ТПУ
	Захарова Алёна Александровна ТПУ	Николаев Дмитрий Петрович ИППИ РАН

Подвесовский Александр Георгиевич БГТУ	Серяков Вадим Александрович ТПУ	Фаворская Маргарита Николаевна СибГУ им. М.Ф. Решетнева
Потемин Игорь Станиславович НИУ ИТМО	Сорокин Дмитрий Васильевич МГУ	Фролов Владимир Александрович МГУ
Ризен Юлия Сергеевна ТПУ	Спицын Владимир Григорьевич ТПУ	Чернявский Алексей Samsung R&D Institute Rus
Ринкевичюс Бронюс Симович МЭИ	Столбова Ирина Дмитриевна ПНИПУ	Чуприна Светлана Игоревна ПГНИУ
Ротков Сергей Игоревич ННГАСУ	Тикунов Владимир Сергеевич МГУ	Шапиро Лев Залманович ИПМ им. М.В. Келдыша РАН
Рябинин Константин Валентинович ПГНИУ	Турлапов Вадим Евгеньевич ННГУ	Шкляр Алексей Викторович ТПУ
Середин Олег Сергеевич ТулГУ	Усилин Сергей Александрович ИСА РАН	Юрин Дмитрий Владимирович МГУ

Международный программный комитет

Timur Paltashev
AMD, USA

 Marina Gavrilova
University of Calgary, Canada

 Karol Myszkowski
MPI, Germany

 Vladimir Savchenko
Hosei University, Japan

 Alexei Sourin
NTU, Singapore

 Olga Sourina
FhG IGD, Germany

Tom Sederberg
Brigham Young University, USA

 Andre Gagalowicz
INRIA, France

 Sabine Coquillart
INRIA, France

 Andres Iglesias
University of Cantabria, Spain

 Wolfgang Heiden
BRS, Germany

 Andre Hinkenjann
IVC BRS, Germany

Gianluca Mura
Politecnico Di Milano, Italy

 Ekaterina Prasolova-Forland
NTNU, Norway

 Samet Refik
Ankara Uni, Turkey

 Bill Seaman
Duke Uni, USA

 Skala Vaclav
University of West Bohemia, Czech
Republic

**Адрес: ГрафиКон-2018, Национальный исследовательский
Томский политехнический университет (НИ ТПУ),
Инженерная школа информационных технологий и робототехники (ИШИТР),
634034, Россия, г. Томск, ул. Советская, д. 84/3, оф. 216.
Тел.: +7 (382) 260-61-29 E-mail: 2018@graphicon.ru Web Site: <http://2018.graphicon.ru/>**

Содержание

Пленарные доклады

<i>Е.Н. Ерёменко, А.С. Крылов, Д.Ю. Васин, Т.Т. Палташев, М.Ю. Катаев, С.Е. Сляднев</i>	
Список пленарных докладов	15

Реалистичная графика

<i>S.V. Ershov, D.D. Zhdanov, A.G. Voloboy</i>	
Treating diffuse elements as quasi-specular to reduce noise in bi-directional ray tracing	20
<i>V.A. Frolov, V.A. Galaktionov, V.V. Sangarov</i>	
Mixing ordinary and Markov chain Monte Carlo rendering techniques	26
<i>V.V. Sanzharov, V.A. Frolov</i>	
Precomputed procedural content level of detail	31
<i>Б.Х. Барладян, Е.Д. Бирюков, А.Г. Волобой, Л.З. Шапиро</i>	
Эффективный алгоритм визуализации предварительно рассчитанных лучей	36
<i>А.М. Вин</i>	
Визуализация объёмных объектов с помощью структурированного оптического излучения	40
<i>А.Д. Жданов, Д.Д. Жданов, Н.Н. Богданов, И.С. Потемин, В.А. Галактионов, И.Л. Лившиц</i>	
Использование методов виртуального прототипирования при разработке устройств виртуальной реальности, не подверженных проблеме конфликта вергенции и аккомодации зрения	43
<i>A.C. Рудникович, К.В. Шипунова</i>	
ISO 12233 и программные средства измерения частотно-контрастных характеристик изображений	48
<i>М.И. Свириденко</i>	
Съемка сферических панорам с каналом освещенности	52
<i>В.Г. Соколов, Д.Д. Жданов, И.С. Потемин, Б.Х. Барладян, Н.Н. Богданов, А.Д. Жданов</i>	
Восстановление двунаправленной функции рассеяния света для среды с объемным рассеянием	56
<i>М.И. Сорокин, Д.Д. Жданов</i>	
Использование свёрточных нейронных сетей для классификации видов искусственного освещения	61

Научная визуализация и визуальная аналитика

<i>M. Demeshko, A. Demin, D. Oliva</i>	
Edge detection using neural network committee	66
<i>K. Ryabinin, M. Kolesnik</i>	
Using IoT Devices Powered by Scientific Visualization Tools to Create Interactive Paleontological Museum Exhibitions	70
<i>Н.В. Авербух</i>	
К вопросу о феномене присутствия в системах компьютерной визуализации на базе виртуальной реальности ..	74
<i>В.Л. Авербух, И.Л. Гвоздарев, Г.И. Левчук</i>	
Визуализация программного обеспечения с использованием виртуальной реальности	77
<i>С.В. Андреев, А.Е. Бондарев</i>	
Построение стереоанимаций на современных стереоустановках	82
<i>С.В. Андреев, Н.А. Бондарева</i>	
Построение отображения текстовой информации в стереопрезентациях	86
<i>К.Ю. Андросов, А.Н. Горбунов, С.В. Давыдов</i>	
Формирование пространства признаков для определения границ зерен структурных компонентов сплава по полихроматическому растровому изображению его микроструктуры	90
<i>Р.А. Багутдинов, С.Г. Небаба, А.А. Захарова</i>	
Редуктивно-аккомодативный принцип обработки гетерогенных данных мультисенсорной системы	94

<i>A.E. Бондарев, В.А. Галактионов, Э.С. Клышинский, Л.З. Шапиро</i>	
Система процедур визуального анализа многомерных данных	98
<i>П.А. Васёв, В.Л. Авербух, М.О. Бахтерев, Д.В. Манаков, Д.Ю. Филоненко, М.А. Форгани</i>	
Сцены визуализации в вычислительных блокнотах	103
<i>А.М. Вин, Б.С. Ринкевичюс, А.Ю. Поройков</i>	
Количественная визуализация формы физических тел с помощью точечно структурированного оптического излучения	107
<i>Т.П. Галкин, М.А. Григорьева, А.А. Климентов, Т.А. Корчуганова, И.Е. Мильман, В.В. Пилогин, М.А. Титов</i>	
Кластерный анализ вычислительных задач системы управления загрузкой эксперимента ATLAS на LHC с использованием визуальной аналитики	111
<i>Д.С. Гордеев</i>	
Модель визуализации изменений в графе внутреннего представления программ языка Cloud Sisal	115
<i>Ю.Н. Дубнищев, В.А. Арбузов, Э.В. Арбузов, В.С. Бердников, С.А. Кислицын, О.С. Мелёхина</i>	
Оптическая диагностика конвективных структур в вертикальном слое воды, ограниченном теплообменными поверхностями при нестационарных граничных условиях	119
<i>Ю.Н. Дубнищев, В.А. Арбузов, В.В. Лукашов, В.В. Леманов</i>	
Гильберт-диагностика пламён	123
<i>А.А. Захарова, Е.В. Вехтер, А.В. Шкляр</i>	
Когнитивная интерпретация визуализации	127
<i>И.А. Знаменская, Е.Ю. Коротеева, Ф.Н. Глазырин</i>	
Кросс-корреляционные методы анализа изображений в экспериментальной визуализации потоков	132
<i>И. Знаменская, Д. Наумов, И. Дорощенко, А. Кузнецов, А. Луцкий</i>	
Цифровые технологии в анализе теневых изображений газоплазменных потоков	135
<i>В.Н. Касьянов, Т.А. Золотухин</i>	
Визуализация графовых представлений потоковых программ	138
<i>В.В. Князь, С.Ю. Данилов, О.В. Выголов, А.Н. Бордодымов</i>	
Визуализация препятствий на индикаторе на лобовом стекле с помощью оценки оптического потока	142
<i>Д.В. Манаков</i>	
Визуальная аналитика и модели абстракции данных	146
<i>С.В. Мещеряков, Д.А. Щемелинин</i>	
Методы визуализации и анализа больших данных в облачных информационных системах	151
<i>С.В. Муравьев, М.А. Борисова</i>	
Анализ и визуализация данных энергоаудита методом агрегирования предпочтений	155
<i>А.Г. Подвесовский, Р.А. Исаев</i>	
Критерий когнитивной ясности как основа для построения метафоры визуализации нечетких когнитивных карт	158
<i>И.Л. Расковская, Б.С. Ринкевичюс, А.В. Толкачев, А.В. Тихомирова</i>	
Визуализация траекторий пузырьков газа в акустическом поле	163
<i>К.В. Рябинин, С.И. Чуприна, К.И. Белоусов, С.С. Пермяков</i>	
Методы визуальной аналитики вариативности речевого поведения пользователей социальных сетей в зависимости от психологических черт личности	167
<i>О.А. Салтыкова, И.В. Папкова, А.В. Крысько</i>	
Визуализация режимов колебаний балок с учетом их контактного взаимодействия	172
<i>А.О. Трубаков, Т.Д. Праздникова</i>	
Методы реставрации потерянных и искаженных участков изображений	176
<i>М.В. Харинов</i>	
Об СКО, методе K-средних и деревьях в приложении к обработке изображений	180
<i>О.О. Шумская, О.О. Евсютин</i>	
Встраивание информации в сжатые JPEG-изображения с минимизацией проявления демаскирующих признаков	185

Компьютерное зрение

<i>Д.С. Белобородов</i>	
Контурная глубина плоской фигуры: применение для определения симметрии и классификации форм	191
<i>А.П. Береснев, И.В. Зоев, Н.Г. Марков</i>	
Исследование свёрточных нейронных сетей класса YOLO для мобильных систем детектирования объектов на изображениях	196
<i>И.В. Зоев, Н.Г. Марков, А.П. Береснев, Т.А. Ягунов</i>	
Аппаратная реализация на ПЛИС свёрточных нейронных сетей для распознавания объектов на изображениях ..	200
<i>И.А. Калиновский, Г.М. Лаврентьев</i>	
Обнаружение спуфинг-атак на систему лицевой биометрии	204
<i>Д.А. Купляков, Е.В. Шальнов, В.С. Конушин, А.С. Конушин</i>	
Распределённый алгоритм сопровождения людей в видео	208
<i>Д.Н. Лепихова, В.Ю. Гудков</i>	
Метод быстрого отбора идентичных контрольных точек на изображениях отпечатка пальца	214
<i>Н.А. Ломов, С.П. Арсеев</i>	
Нейронные сети для распознавания формы по медиальному представлению	218
<i>А.К. Мовчан, В.В. Капустин, М.И. Курячий</i>	
Методы и средства томографического видения пространства активно-импульсными телевизионными измерительными системами	222
<i>Л.В. Новоторцев, А.Г. Волобой</i>	
Ускорение метода перебора плоскостей при трехмерной реконструкции строений по аэроснимкам	226
<i>Е.С. Попова, В.Г. Спицын, Ю.А. Болотова</i>	
Программа и алгоритм сегментации и распознавания рукопечатных символов с помощью сверточных нейронных сетей	230
<i>А.И. Соколова, А.С. Конушин</i>	
Обзор методов распознавания человека по походке в видео	234
<i>В.Г. Спицын, Ю.В. Савицкий, А.Б. Казиев, Ю.А. Болотова</i>	
Нейросетевой метод обнаружения размытых изображений лиц	238
<i>П.В. Хрушков, В.И. Шахуро, А.С. Конушин</i>	
Синтез изображений дорожных знаков с помощью условных порождающих противоборствующих нейросетей ..	242
<i>Т.Н. Шолохова, Л.М. Местецкий</i>	
Классификация изображений таблиц на основе структурного подхода	247

Обработка и анализ биомедицинских изображений

<i>V.V. Danilov, I.P. Skirnevskiy, R.A. Manakov, O.M. Gerget, F. Melgani</i>	
Image-based algorithm for the catheter recognition based on GLCM	252
<i>A. Khvostikov, A. Krylov, O. Kharlova, N. Oleynikova, I. Mikhailov, P. Malkov</i>	
CNN-based histological images segmentation of mucous glands	258
<i>A.A. Melnikova, A.S. Krylov</i>	
Computer analysis and restoration of motion blurred images	262
<i>Д.А. Гаврилов, А.В. Мелерзанов, Н.Н. Щелкунов, Э.И. Закиров</i>	
Диагностика меланомы с использованием нейронной сети Inception v3	266
<i>А.А. Довганич, А.С. Крылов, Д.В. Юрин</i>	
Алгоритм нелокального среднего основанный на модифицированном индексе структурного сходства	270
<i>М.В. Дубровская, М.М. Новожилов</i>	
Лучевой метод реконструкции поверхности сердца человека по данным компьютерной томографии	275
<i>Н.В. Мамаев, Д.В. Юрин, А.С. Крылов</i>	
Нахождение параметров метода шумоподавления с использованием вейвлет-преобразования на медицинских изображениях на основе анализа хребтовых структур	280

CNN-based histological images segmentation of mucous glands

A. Khvostikov¹, A. Krylov¹, O. Kharlova², N. Oleynikova², I. Mikhailov², P. Malkov²

xubiker@gmail.com | kryl@cs.msu.ru

olga.arsenteva@gmail.com | noleynikova@mc.msu.ru | imihailov@mc.msu.ru | pmalkov@mc.msu.ru

¹Faculty of Computational Mathematics and Cybernetics, Lomonosov Moscow State University, Moscow, Russia;

²University Medical Center, Lomonosov Moscow State University, Moscow, Russia

Mucous glands lesions analysis and assessing of malignant potential of colon polyps are very important tasks of surgical pathology. However, differential diagnosis of colon polyps often seems impossible by classical methods and it is necessary to involve computer methods capable of assessing minimal differences to extend the capabilities of the classical pathology examination. Accurate segmentation of mucous glands from histology images is a crucial step to obtain reliable morphometric criteria for quantitative diagnostic methods. We review major trends in histological images segmentation and design a new convolutional neural network for mucous gland segmentation.

Keywords: Image segmentation, Convolutional Neural Networks, Histology, Pathology, Mucous glands

1. Introduction

Mucous glands are important histological structures presented in certain organ systems as the main mechanism for secreting proteins and carbohydrates. Malignant tumors arising from glandular epithelium, also known as adenocarcinomas, are the most prevalent form of cancer. However for the mucous glands the sequence of precancerous processes leading to the development of a malignant tumor has been studied most well: metaplasia-dysplasia-cancer. The detection of metaplasia and dysplasia in the epithelium of the mucous glands may be an extremely difficult task for surgical pathology. Minimal differences between these processes are often not available for the classical pathology examination. An important practical task is to find analytical instrument for objective diagnosis. Computational analysis is an additional analytical instrument for the segmentation of mucous glands on a microscopic images, shape analysis of the whole gland and its lumen (Fig.1), calculating nuclear-cytoplasmic ratio in mucus-forming cells, and localization of the expression of certain immunohistochemical markers. All these parameters together can potentially significantly increase the accuracy of diagnosis of pathological processes associated with mucous glands in colon, stomach, prostate, breast, bronchus, etc.

Accurate segmentation of glands is often a crucial step to obtain reliable morphological statistics. Nonetheless, the task by nature is very challenging due to the great variation of glandular morphology in different histological grades.

Today the standard dataset for the task of histological images segmentation is Warwick-QU image dataset [1], first used in [2]. The dataset provides 165 Hematoxylin and Eosin (H&E) stained slides, consisting of a variety of histological grades. The dataset is provided together with ground truth annotations made by expert pathologists. Every image contains a number of colon glands, each of them consists of lumen, cytoplasm and nuclei (Fig.1). Warwick-QU

dataset was also used in the Gland Segmentation in Colon Histology Images (GlaS) contest [3].

The goal of this paper is to give a short overview of recent trends in histological images segmentation and propose a new algorithm for mucous glands segmentation. The target aim of our research is the computer-aided diagnostics of colon polyps – adenomas (ICD-O 8140/0) and serrated lesions (ICD-O 8213/0).

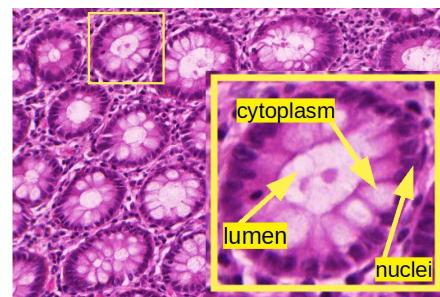


Figure 1. A histological image of colon mucous glands.

2. Review of gland segmentation methods

All major trends in gland segmentation can be roughly split into two groups (those which are based on the use of conventional image processing techniques and more modern methods based on convolutional neural networks), which are overviewed in Section 2.1 and Section 2.2 accordingly.

2.1 Conventional methods of segmentation

The first methods of image segmentation ever applied to histological images were methods based on K-means clustering, Chan-Vese algorithm, histogram analysis, edge detection, and watershed algorithm. Although these methods of segmentation are very simple, they are not effective enough, and can be used only for semiautomatic segmentation [4].

The next generation of algorithms was based on a more complex feature-based approaches and could perform automatic image segmentation in most cases. E.g. a region growing algorithm is presented in [5].

The initial seeding regions are identified based on the lumen inside the glands by fitting with a large moving window. The seeding regions are then expanded by repetitive application of a morphological operation. False gland regions are removed based on either their excessive ages of active growth or inadequate thickness of dams formed by goblet cell nuclei outside the grown regions.

In [6] the tissue image is segmented using the definition of object-graphs instead of using the pixel-based approach. The image is decomposed into a set of circular objects, and depending on the organizational properties of these objects initial seeds are determined. After that the inner regions of glands are found by growing the seeds in accordance with nuclei location.

A more complex approach was proposed in [2]. Each gland in the image is treated as a polygon of random number of vertices, while the vertices represent approximate locations of epithelial nuclei. The problem of constructing such a graph is formulated as a Bayesian inference problem by defining a prior for spatial connectivity and arrangement of neighboring epithelial nuclei and a likelihood for the presence of a gland structure.

2.2 Segmentation with neural networks

Recently, image segmentation methods using convolutional neural networks are gaining in popularity. Due to their good generalization capacity and versatility these methods demonstrate the state-of-the-art level of performance. Almost all CNN-based segmentation methods use the same idea of convolutional autoencoder (CAE) [7]. With minor changes these CNN-based segmentation methods can be also applied to histological images.

The first approach of semantic image segmentation using CNN was Fully Convolutional Network (FCN) proposed by Long et al. in [8]. The key ideas of the approach are to replace the fully-connected layers with convolutions, perform upsampling with transposed convolutions (or so called upconvolutions) and use skip connections. All in all FCN re-purposes imagenet pretrained networks for semantic segmentation problem.

Despite it's upconvolutional layers and a few shortcut connections FCN produces too coarse segmentation maps. SegNet [9] proposes another way of upsampling. The decoder part of the SegNet uses pooling indices computed in the max-pooling step of the corresponding encoder part to perform non-linear upsampling. This leads to more accurate segmentation and makes SegNet more memory efficient than FCN.

The main contribution of U-Net [10] compared to other fully convolutional segmentation networks is that while upsampling and going deeper in the network the upsampled features are concatenated with

the higher resolution features from down part for better localization. Furthermore, apart from proposing the new architecture and a special way of data augmentation U-Net was the first CNN-based method applied for biomedical image segmentation.

The main problem of the mentioned above approaches of segmentation is the impossibility of the algorithms to separate close or contiguous objects. Various ideas were proposed to solve this problem.

For example in [11] the authors introduced a new high-level loss function, that takes into account high level shape priors, such as smoothness and preservation of complex interactions between object regions. This loss was used in the FCN network trained on the Warwick-QU dataset and demonstrated better performance compared to the FCN trained with conventional per-pixel loss.

In [12] Kainz et al. trained two FCN networks on the Warwick-QU dataset. The first network performs a 4-class object segmentation (benign background, benign gland, malignant background and malignant gland), while the second one is trained to separate close glands. The CNN predictions are then regularized using weighted total variation to produce the final segmentation result.

Chen et al. in [13] proposed a DCAN architecture with similar idea of object detection and separation, but unlike [12] these two steps are performed simultaneously with one FCN-based network that has two outputs. First output predicts probabilities of gland object, while the second predicts the probability map of contours separating glands. The final segmentation masks are calculated using the threshold rule. To strengthen the training process DCAN uses 3 weighted auxiliary classifiers in the 3 deepest layers of the network.

The idea of splitting segmented glands got a further development in [14]. The authors introduce a CNN with 3 pipelines: a FCN for the foreground segmentation, Faster R-CNN [15] for the object detection and HED [16] for edge detection. All three pipelines are fused into one, and are followed with several convolution layers to predict the final instance segmentation map. This approach leads to the state-of-the-art level of segmentation accuracy.

3. Proposed method

In this paper we consider the problem of histological mucous gland segmentation. For this problem we suggest a rather simple yet effective CNN architecture. The approach is based on the U-Net [10] with batch normalization [17] layers added after each convolution. The main building blocks of the network are Conv block (Fig.2(a)) and Upconv block (Fig.2(b)).

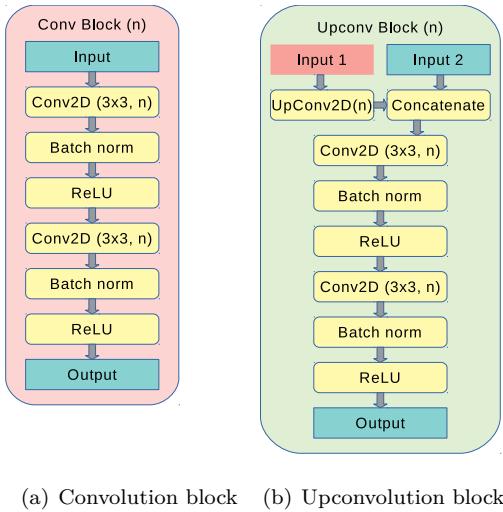


Figure 2. Base building blocks of the proposed network.

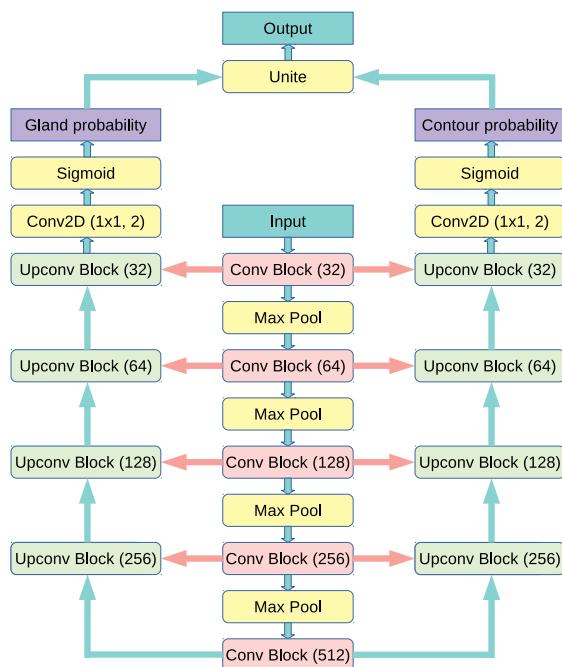


Figure 3. Proposed network architecture for mucous glands segmentation.

Conv blocks form the contracting path of the network, while Upconv blocks form the expansive path. Here Conv2D ($S \times S, n$) operation stands for the 2D convolution with n filters of size $S \times S$, while UpConv2D (n) operation stands for the double upsampling of the feature map followed by 2D convolution with n filters of size 2×2 . In contrast to the U-Net we use two different expansion paths in order to detect glands and separating contours. Each expansion paths ends with a 1×1 2D convolution, which reduces the number of features to 2 (background/foreground) and a sigmoid activation function to get the output probability map. Thus, the first expansion path out-

puts the probability of gland and the second - the probability of gland contour. Uniting these two probabilities by threshold we get the final result of segmentation (Fig.3). The network is learned using RMSprop optimizer [18], dividing the gradient by a running average of its recent magnitude. We use a sum of a binary cross entropy value and a dice coefficient as the loss for both of the network outputs.

4. Experiments and results

The algorithm was evaluated on the Warwick-QU dataset [1], which consists of a wide range of histological grades from benign to malignant subjects. The dataset contains 85 train and 80 test images. We enlarged the dataset by 10 times using augmentation process with random shift, rotation, zoom and flip operations.

The proposed algorithm was implemented using open source neural network library Keras [19] with TensorFlow backend. The training was performed on a platform with Intel(R) Core(R) i7-6700HQ CPU and NVIDIA GeForce GTX 960M GPU. Due to the relatively high resolution of the images from the used dataset, every processed image is first split into non-overlapping patches of 256×256 size, each of the patches is fed to the network and after that the output image is merged from the processed patches.

The segmentation results after training the proposed network for 12 epochs are shown in Fig.4. The sum of the binary cross entropy and the dice coefficient was 0.872 on the validation set. The evaluation on the test set demonstrates sufficiently good results in both gland and contour segmentation.

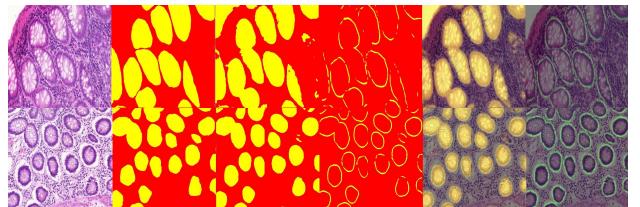


Figure 4. Segmentation results on the test images from dataset [1]. The columns: source image, ground truth mask, network outputs (gland and contour detection), superpositions of source image and the outputs.



Figure 5. Segmentation results of an image fragment of mucous glands in hyperplastic colon polyp in real biopsy diagnostic material. The columns: source image; network outputs (gland and contour detection); superpositions of source image and the outputs.

Moreover, Fig.5 demonstrates the results of applying the proposed algorithm for the classification of real biopsy diagnostics material. It should be noticed, that for this example the network was trained on the Warwick-QU dataset [1] and was not fine-tuned on the used data due to the absence of the ground-truth markup. Even though, the obtained results look reasonable. Creating the markup for this data and fine-tuning the network are the further work directions.

5. Conclusion and further directions

Further directions of our work include performing a more complex segmentation to make also an inner-gland segmentation (detect nuclei, lumen and cytoplasm), which can be used for the ensuing analysis. In particular, analyzing the histological images of mucous glands helps to detect changes in its lumen shape (serration), in the nuclear-cytoplasmic ratio inside mucus-forming cells, and in the character of the expression of immunohistochemical markers [20].

6. Acknowledgements

The work was supported by Russian Science Foundation grant 17-11-01279. In our study, the review of segmentation methods and designing the CNN were performed by the authors from the Faculty of Computational Mathematics and Cybernetics, the medical problem statements and experimental work - by the authors from the University Medical Center.

7. References

- [1] Warwick-QU image dataset description. <https://warwick.ac.uk/fac/sci/dcs/research/tia/glascontest/about/>.
- [2] Korsuk Sirinukunwattana, David RJ Snead, and Nasir M Rajpoot. A stochastic polygons model for glandular structures in colon histology images. *IEEE transactions on medical imaging*, 34(11):2366–2378, 2015.
- [3] Korsuk Sirinukunwattana and et al. Gland segmentation in colon histology images: The glas challenge contest. *Medical image analysis*, 35:489–502, 2017.
- [4] Rodrigo Fernandez-Gonzalez and et al. Automatic segmentation of histological structures in mammary gland tissue sections. *Journal of biomedical optics*, 9(3):444–454, 2004.
- [5] H-S Wu, R Xu, N Harpaz, D Burstein, and J Gil. Segmentation of intestinal gland images with iterative region growing. *Journal of Microscopy*, 220(3):190–204, 2005.
- [6] Cigdem Gunduz-Demir, Melih Kandemir, and et al. Automatic segmentation of colon glands using object-graphs. *Medical image analysis*, 14(1):1–12, 2010.
- [7] Jonathan Masci, Ueli Meier, Dan Ciresan, and Jürgen Schmidhuber. Stacked convolutional auto-encoders for hierarchical feature extraction. In *ICANN*, pages 52–59. Springer, 2011.
- [8] Jonathan Long, Evan Shelhamer, and Trevor Darrell. Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3431–3440, 2015.
- [9] Vijay Badrinarayanan, Alex Kendall, and Roberto Cipolla. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on PAMI*, 39(12):2481–2495, 2017.
- [10] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer, 2015.
- [11] Aïcha BenTaieb and Ghassan Hamarneh. Topology aware fully convolutional networks for histology gland segmentation. In *MICCAI*, pages 460–468. Springer, 2016.
- [12] Philipp Kainz, Michael Pfeiffer, and Martin Urschler. Segmentation and classification of colon glands with deep convolutional neural networks and total variation regularization. *PeerJ*, 5:e3874, 2017.
- [13] Hao Chen, Xiaojuan Qi, Lequan Yu, Qi Dou, Jing Qin, and Pheng-Ann Heng. Dcan: Deep contour-aware networks for object instance segmentation from histology images. *Medical image analysis*, 36:135–146, 2017.
- [14] Yan Xu and et al. Gland instance segmentation using deep multichannel neural networks. *IEEE Transactions on Biomedical Engineering*, 64(12):2901–2912, 2017.
- [15] Shaoqing Ren and et al. Faster r-cnn: Towards real-time object detection with region proposal networks. In *Advances in neural information processing systems*, pages 91–99, 2015.
- [16] Saining Xie and Zhuowen Tu. Holistically-nested edge detection. In *Proceedings of the IEEE international conference on computer vision*, pages 1395–1403, 2015.
- [17] Sergey Ioffe and Christian Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*, 2015.
- [18] RMSprop optimizer. https://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf.
- [19] François Chollet et al. Keras. <https://keras.io>, 2015.
- [20] OA Kharlova, NV Danilova, PG Malkov, NV Ageikina, and MV Knyazev. Serrated lesions of the large intestine: Prevalence analysis and clinical and morphologic characteristics. *Arkhiv patologii*, 77(4):24–32, 2015.