

## РАЗРАБОТКА И АНАЛИЗ АЛГОРИТМА ДЕТЕКТИРОВАНИЯ ПАТОЛОГИЙ НА ЭНДОСКОПИЧЕСКИХ ИЗОБРАЖЕНИЯХ ЖЕЛУДКА НА ОСНОВЕ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

*Хрящев В.В., к.т.н., доцент Ярославского государственного университета им. П.Г. Демидова, e-mail: vhr@yandex.ru;*

*Ганин А.Н., к.т.н., генеральный директор ООО «Точка зрения», г. Ярославль, e-mail: angnn@mail.ru;*

*Лебедев А.А., аспирант Ярославского государственного университета им. П.Г. Демидова, e-mail: lebedevdes@gmail.com;*

*Степанова О.А., аспирант Ярославского государственного университета им. П.Г. Демидова, e-mail: olgalstepanova@yandex.ru;*

*Кашин С.В., к.м.н., ГБУЗ Ярославской области «Клиническая онкологическая больница», e-mail: s\_kashin@mail.ru;*

*Куваев Р.О., к.м.н., ГБУЗ Ярославской области «Клиническая онкологическая больница», e-mail: kuaev\_roman@mail.ru.*

## DEVELOPMENT AND ANALYSIS OF ALGORITHM OF PATHOLOGY DETECTION IN ENDOSCOPIC IMAGES OF GASTRIC BASED ON CONVOLUTIONAL NEURAL NETWORK

*Khryashchev V.V., Ganin A.N., Lebedev A.A., Stepanova O.A., Kashin S.V., Kuvayev R.O.*

*This paper presents the algorithm of pathology detection in endoscopic images of gastric based on convolutional neural network. Training and testing of the algorithm was carried out on the NVIDIA DGX-1 supercomputer using endoscopic images from the test base, assembled together with the Yaroslavl Clinical Oncological Hospital. As a result of experiments, the mAP metric was calculated and the value was 0.875, which is a high result for the task of object detection in images.*

**Key words:** machine learning, convolution neural network, endoscopic image analyses, gastric cancer.

**Ключевые слова:** машинное обучение, сверточная нейронная сеть, анализ эндоскопических изображений, рак желудка.

### Введение

С развитием техники и технологий все более реальным становится использование достижений цифровой обработки изображений в области медицины для создания систем автоматической диагностики, а также систем поддержки принятия решений [1]. Внедрение подобных систем в клиническую медицину нацелено на повышение эффективности диагностики и терапии, сокращение времени и расходов на исследования, проведение контроля качества, а также обучение и совершенствования врачебных навыков специалистов. Одним из актуальных направлений исследований является анализ эндоскопических изображений [2-4].

На сегодняшний день существует ряд российских и зарубежных исследований, посвященных системам автоматического анализа эндоскопических изображений. В работе Батухтина Д.М. и др. [5] представлена система контроля качества эндоскопических исследований и автоматизированного анализа эндоскопических изображений пищевода, основанная на использовании оптимального по критерию максимального правдоподобия классификатора. Тот же коллектив авторов в работе [6] описал систему сегментации изображений слизистой оболочки пищевода, обеспечившую повышение диагно-

*Разработан алгоритм детектирования патологий на эндоскопических изображениях желудка на основе глубокой сверточной нейронной сети. Обучение и тестирование алгоритма осуществлялось на суперкомпьютере NVIDIA DGX-1 с использованием эндоскопических изображений из тестовой базы, собранной в Ярославской клинической онкологической больнице. В результате численных экспериментов получено значение метрики mAP, составившее 0,875, что является высоким результатом для задачи детектирования объектов на изображениях.*

стической эффективности узкоспектральной эндоскопии по результатам 238 эндоскопических исследований.

Группа исследователей в работе [7] описала прототип системы автоматической сегментации и аннотирования эндоскопических изображений, основанный на классификации векторов топологических признаков исходного изображения.

Коваленко Д.А. и Гнатюк В.С. в работе [8] предложили метод ассоциации сцен для эндоскопических видео, позволяющий выделить ключевые сцены с помощью построения системы соседства похожих кадров и глобального анализа похожих кадров путем применения нейросетевого статистического критерия. Средняя точность предложенного алгоритма составила 57 %.

В работах зарубежных авторов [9, 10] предложены алгоритмы на основе сверточных нейронных сетей для исследования колоректальных эндоскопических изображений, обеспечивающие точность классификации 85-90 %.

Авторы [11] рассматривают свёрточные нейронные сети в сочетании с набором низкоуровневых функций для обнаружения патологии в рентгенограмме грудной клетки. В результате получены площади под ROC-кривой (AUC) 0,93 и 0,79 для разных подзадач.

Приведенный анализ литературы показывает, что использование систем компьютерного зрения для анализа эндоскопических изображений на сегодняшний день показывает высокие результаты согласно многочисленным исследованиям; следовательно, разработка подобных систем представляет собой актуальную научно-техническую задачу.

В настоящее время одним из самых распространенных онкологических заболеваний является рак желудка, занимающий второе место по смертности от злокачественных новообразований. Вторичная профилактика рака посредством ранней диагностики и адекватной терапии является наиболее эффективной стратегией повышения выживаемости пациентов [12–14].

Целью данной работы является разработка системы автоматического детектирования патологических изменений слизистой оболочки желудка на эндоскопических изображениях. Использование такой системы в реальной клинической практике позволит существенно повысить качество диагностики различных патологий желудка.

#### **Создание базы эндоскопических изображений желудка**

Задача анализа эндоскопических изображений оказывается весьма сложной в основном из-за разнообразия текстур исследуемой поверхности, ее существенной неоднородности и широкого диапазона масштабов обрабатываемых изображений. Кроме того, эндоскопические изображения характеризуются следующими отличительными особенностями:

- 1) яркость и контрастность изображений сильно зависят от геометрии рассматриваемого участка ткани;
- 2) на изображениях может присутствовать размытие, обусловленное перемещением датчика внутри полости органа;
- 3) изображения тканей могут значительно меняться во время сокращения мышечных волокон органа (перистальтики);
- 4) практически соосное расположение объектива и источника освещения приводит к появлению бликов и артефактов на изображениях [8].

Для повышения уровня диагностики патологических участков слизистой оболочки используются такие высокотехнологические методы эндоскопической диагностики, как увеличительная эндоскопия и эндоскопия в узком спектре света [13].

Увеличительная эндоскопия позволяет изучить поверхность слизистой оболочки с оптическим увеличением примерно в 115 раз, приближая эту методику к стереоскопической микроскопии. С ее помощью возможно выявление минимальных изменений типичной архитектуры слизистой оболочки в различных отделах желудка [13].

Принцип действия узкоспектральной эндоскопии основан на использовании оптических фильтров, сужаю-

щих спектр световой волны: из диапазона длин волн от 400 нм до 800 нм, использующегося при эндоскопии в белом свете, выбираются всего две световых волны длиной 415 нм и 445 нм. Данные волны хорошо поглощаются гемоглобином, что позволяет их использовать в диагностике сосудистых структур слизистой и подслизистой слоев пищеварительного тракта [12, 14].

Таким образом, эффективное использование этих методик требует от специалиста высокого уровня теоретических знаний в области эндоскопии и смежных специальностей, а также практических навыков и опыта клинического применения. По этой причине увеличительная и узкоспектральная эндоскопии остаются методиками экспертного уровня, а обучение специалистов традиционными способами представляет собой длительный процесс, что значительно затрудняет их активное внедрение в широкую клиническую практику [3, 4].

Важным шагом в разработке системы компьютерного анализа медицинских изображений является сбор тестовой базы изображений. В данной работе для анализа использовались эндоскопические изображения с увеличением в узкоспектральном режиме, полученные со следующих эндоскопических систем: эндоскопическая система OLYMPUS EXERA II, видеогастроскоп GIF 160Z; эндоскопическая система OLYMPUS LUCERA SPECTRUM, видеогастроскоп GIF 260Z; эндоскопическая система OLYMPUS EXERA III, видеогастроскоп GIF HQ290; эндоскопическая система PENTAX Medical EPK-i7010, видеогастроскоп EG-2990Zi.

База эндоскопических изображений создавалась в Ярославской клинической онкологической больнице. Размер базы составил 437 изображений, из которых 119 изображений содержат раковые патологии и 312 их не содержат. Изображения масштабировались до разрешения 300×300 пикселей таким образом, чтобы фрагмент не содержал технических надписей и регионов, не относящихся к слизистой желудка, после чего база размножалась за счет применения к каждому изображению геометрических преобразований. Далее база данных размножалась путем поворота на 90 и на 180 градусов. Итоговый размер базы данных составил 1293 изображений, из которых 357 относятся к раковым патологиям.

Патологии слизистой оболочки желудка характеризуются изменениями микрососудистого рисунка и рисунка микроструктуры поверхности эпителия. Данные изменения наиболее заметны на границе патологии, которая называется демаркационной линией. В созданной базе данных все участки, содержащие патологии, выделены вручную. Как видно из рис. 1, полученные полигоны представляют собой сложные многоугольники. Для упрощения дальнейшей оценки качества работы алгоритма полигоны, ограниченные демаркационной линией, были описаны прямоугольниками.

#### **Разработка алгоритма анализа эндоскопических изображений желудка**

Стратегия эндоскопической диагностики с применением узкоспектральной и увеличительной эндоскопии зависит от обследуемого органа желудочно-кишечного тракта, определяя так называемый орган-специфичный




Рис. 1. Примеры из созданной базы данных эндоскопических изображений. Демаркационная линия изображена сплошной, демаркационные прямоугольники – пунктиром

подход в диагностике. Наиболее сложную микроархитектонику имеет слизистая оболочка желудка, поскольку при эндоскопическом осмотре требуется в равной степени оценка как микрососудистого рисунка, так и рисунка микроструктуры поверхности эпителия. Более того, слизистая оболочка желудка имеет разные типы с различным строением, а большой спектр ее патологических изменений (хроническое воспаление, атрофия, кишечная метаплазия, различные гистологические типы рака желудка) определяет разнообразные изменения в их структуре.

В современной классификации патологий, выявляемых при эндоскопической диагностике, выделяют до 8 различных типов, которые можно объединить в 3 группы: раковая патология, патологии, не относящиеся к раковым, а также слизистая без патологических изменений.

В данной работе рассматривается система анализа эндоскопических изображений, производящая детектирование объектов следующих классов:

**I класс:** слизистая без патологических изменений. Объекты данного класса не выделяются демаркационной линией.

**II класс:** не рак. Данный класс включает в себя участки слизистой с патологиями, не относящимися к раковым, а также фрагменты изображения, которые нельзя отнести к I или III классам (например, просвет

полости органа на изображении). Объекты данного класса на изображении выделяются демаркационными прямоугольниками.

**III класс:** рак. Объекты данного класса выделяются демаркационными прямоугольниками.

Для решения задачи анализа эндоскопических изображений желудка выбран аппарат сверточных нейронных сетей, ранее показавших свое превосходство в решении задач распознавания лиц [15], эмоций по изображению лица [16], объектов на спутниковых изображениях [17] и др. Применение данного подхода обусловлено преимуществами сверточных нейронных сетей перед традиционными алгоритмами машинного обучения: формирование признаков в таких сетях происходит автоматически в процессе обучения модели с помощью операции двумерной свертки, что позволяет получить лучшие результаты в задачах классификации, детектирования и распознавания объектов на изображениях. Основой разрабатываемого алгоритма детектирования в рамках данного исследования выбрана сверточная нейронная сеть SSD (Single Shot Multibox Detector) [18], архитектура которой представлена на рис. 2.

Нейронная сеть SSD представляет собой сверточную сеть прямого распространения. На вход сети подается цветное изображение размером 300x300x3 (RGB-изображения), на выходе нейронная сеть выдает нормированные координаты детектируемых объектов раз-

личных классов (их число является одним из входных параметров алгоритма).




Рис. 2. Архитектура сверточной нейронной сети SSD

Ряд начальных слоев сети представляют собой укороченную версию архитектуры VGG-16 [19]. После нее расположены сверточные слои, формирующие своеобразную пирамиду из карт признаков различного масштаба. Эти карты признаков подаются на слои классификации и детектирования, где осуществляется прогнозирование, причем каждая из карт признаков позволяет обнаруживать объекты определенного размера. Карты признаков разбивается на «боксы» прямоугольной формы различного масштаба, далее, на этапе прогнозирования, оценивается вероятность нахождения объекта того или иного класса в данном боксе, после чего происходит корректировка положения бокса. Кроме того, сеть объединяет прогнозы из нескольких карт признаков с различными разрешениями для детектирования и классификации объектов различных размеров. Затем данные о детектированных объектах различных классов обрабатываются быстрым алгоритмом NMS (Non-Maximum Supression, алгоритм подавления не-максимумов) [20] для коррекции границ и фильтрации.

Реализация архитектуры сети осуществлялась с помощью фреймворка Caffe. Для инициализации части весов сверточной нейронной сети SSD использовалась модель укороченной нейронной сети VGG-16 для классификации объектов [19], обученная на базе изображений Imagenet [21]. Веса остальных слоев задавались с помощью инициализации Ксавьера. Смещения инициализировались константами – нулями. Общее количество итераций составило порядка 120 000. В качестве алгоритма численной оптимизации использовался стохастический градиентный спуск с использованием добавочного моментного коэффициента, равного 0,9. Для регуляризации модели в процессе обучения применялось правило обновления весов, в результате чего добавлялся коэффициент распада веса, равный 0,0005. Начальная скорость обучения равнялась 0,001 и затем уменьшалась в 10 раз после 80 000 итераций.

Обучение нейронной сети осуществлялось параллельно на 4 видеокартах суперкомпьютера NVIDIA DGX-1 Volta, предоставленного центром искусственного интеллекта и цифровой экономики ЯрГУ, размер батча составлял 32. Входной размер сети соответствовал разрешению изображений из базы данных: 300x300x3. Из каждого пикселя входного изображения поканально вычитались значения: mean\_value: 104,0; mean\_value: 117,0; mean\_value: 123,0. В процессе обучения изображения зеркалировались.

**Тестирование алгоритма**

Для проведения численного эксперимента из заданной базы эндоскопических изображений случайным

образом отбирались 100 изображений, из которых 24 относились к классу «рак».

Для оценки качества работы алгоритма рассчитывались значения метрики AP (Average Precision), а также mAP (mean Average Precision). Значение метрики AP вычисляется как усреднение значений точности при разных значениях порога:

$$AP = \frac{\sum_{r=1}^N P_r}{N}, \tag{1}$$

где  $P_r$  – значение точности (Precision) при фиксированном значении порога  $r$ , а  $N$  – множество значений порога. Метрика mAP используется как основная мера качества работы детекторов объектов и представляет собой усреднение значений AP по всем классам:

$$mAP = \frac{\sum_{i=1}^K AP_i}{K}, \tag{2}$$

где  $K$  – число классов.

Графики зависимости точности от полноты при варьировании порога изображены на рис. 3.

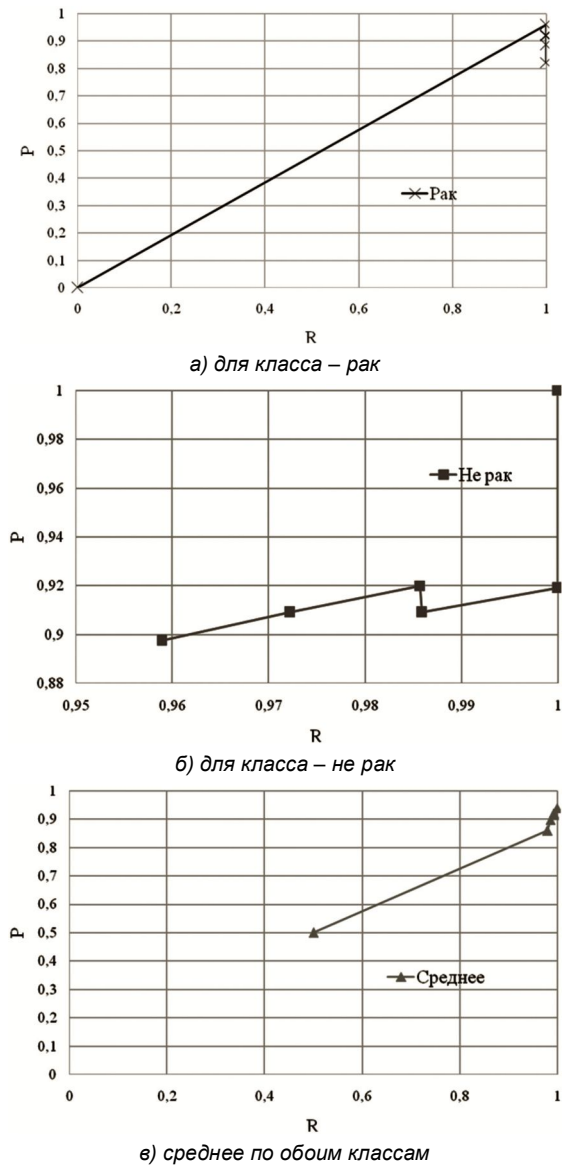





Рис. 3. Графики зависимости точности P от полноты R при варьировании порога




а) верное обнаружение рака



б) верное обнаружение рака



в) верное обнаружение иной патологии



г) верное обнаружение иной патологии

Рис. 4. Примеры работы алгоритма.

Эталонная демаркационная линия изображена пунктиром, результат работы алгоритма – сплошной линией

Таким образом, AP для класса рак составила 0,827, для класса не рак – 0,923; mAP для разработанного алгоритма составляет 0,875.

Примеры детектирования патологий предложенным алгоритмом приведены на рис. 4.

### Заключение

Предложен и протестирован алгоритм анализа эндоскопических изображений для классификации патологий слизистой оболочки желудка. В его основе лежит реализация сверточной нейронной сети. Обучение и тестирование алгоритма проводилось параллельно на четырех видеокартах суперкомпьютера NVIDIA DGX-1.

В результате численных экспериментов получено значение метрики mAP, составившее 0,875, что является достаточно высоким результатом для задачи детектирования объектов на эндоскопических изображениях желудка. Основной задачей дальнейших исследований является сбор более репрезентативной базы эндоскопических изображений, необходимой для повышения обобщающей способности алгоритма на основе сверточных нейронных сетей. Собрать такую базу планируется в коллаборации с современными медицинскими

центрами из Великобритании, Японии, Австрии и Тайваня.

### Литература

1. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / 2017. ДМК-Пресс, 652 с.
2. Bisschops R, Areia M, Coron E, Dobru D., Kaskas B., Kuvaev R., Pech O., Ragunath K., Weusten B., Familiari P., Domagk D., Valori R., Kaminski M.F., Spada C., Bretthauer M., Bennett C., Senore C., Dinis-Ribeiro M., Rutter M.D. R. Performance measures for upper gastrointestinal endoscopy: a European Society of Gastrointestinal Endoscopy (ESGE) Quality Improvement Initiative // Endoscopy. 48(9). 2016. pp. 843-864.
3. Куваев П.О., Никонов Е.Л., Кашин С.В., Капранов В.А., Гвоздев А.А. Контроль качества эндоскопических исследований, перспективы автоматизированного анализа эндоскопических изображений // Кремлевская медицина. Клинический вестник. 2013. 2. С. 51–56.
4. Лебедев А.А., Степанова О.А., Юрченко Е.А., Хрящев В.В. Разработка алгоритмов анализа изображений для классификации патологий слизистой оболочки желудка // Цифровая обработка сигналов и ее применение

ние (DSPА-2018): докл. 20-й междунар. конф. М., 2018. Т. 2. С. 644–649.

5. Батухтин Д.М., Пеганова Е.В., Митракова Н.Н., Роженцов А.А., Фурман Я.А. Анализ узкоспектральных эндоскопических изображений на внутренней поверхности пищевода // Вестник Поволжского государственного технологического университета. Серия: радиотехнические и инфокоммуникационные системы. 2014. № 4 (23). С. 45–57.

6. Пеганова Е.В., Батухтин Д.М., Митракова Н.Н. Автоматизированная система сегментации узкоспектральных изображений для оптимизации эндоскопической диагностики при патологии пищевода // ЭИИГ. 2014. № 3 (103).

7. Дунаева О.А., Малкова Д.Б., Мячин М.Л., Эдельсбруннер Х. Сегментация клинических эндоскопических изображений, основанная на классификации векторных топологических признаков // Модел. и анализ информ. систем. 2013. 20:6. С. 162–173.

8. Коваленко Д.А., Гнатюк В.С. Ассоциация сцен в эндоскопических видео // GraphiCon 2017: Обработка и анализ биомедицинских изображений. Пермь. 2017. С. 269–274.

9. Tamaki T., Sonoyama S., Hirakawa T., Raytchev B., Kaneda K., Koide T. Computer-Aided Colorectal Tumor Classification in NBI Endoscopy Using CNN Features // in The Korea-Japan joint workshop on Frontiers of Computer Vision (FCV2016). 2016. pp. 61-65.

10. Ribeiro E., Uhl A., Wimmer G., Häfner M. Exploring Deep Learning and Transfer Learning for Colonic Polyp Classification // Computational and Mathematical Methods in Medicine. vol. 2016.

11. Bar Y., Wolf L., Diamant I., Greenspan H. Deep Learning with Non-Medical Training Used for Chest Pathology Identification // In: SPIE Medical Imaging. 2015.

12. Куваев Р.О., Кашин С.В., Никонов Е.Л., Itoh T., Gotoda T., Gono K. Ранний рак желудка: методики скрининга, эндоскопической диагностики и малоинвазивного

лечения // Доказательная гастроэнтерология. 2014. 3 (3). С. 44–51.

13. Куваев Р.О., Кашин С.В. Современное эндоскопическое исследование желудка с использованием методик узкоспектральной и увеличительной эндоскопии: техника проведения и алгоритмы диагностики // Доказательная гастроэнтерология. 2016. 2 (5). С. 3–13.

14. Куваев Р.О., Никонов Е.Л., Кашин С.В. Helicobacter pylori-ассоциированный хронический гастрит: новые технологии эндоскопической диагностики // Доказательная гастроэнтерология. 2015. 4 (1). С. 19–24.

15. Хрящев В.В., Приоров А.Л., Стефаниди А.Ф., Топников А.И. Разработка и исследование алгоритмов обработки и распознавания речевых сигналов и изображений для систем мультимодальной биометрии // Цифровая обработка сигналов. 2017. № 3. С. 45–49.

16. Khryashchev V., Ivanovsky L., Priorov A. Deep Learning for Real-Time Robust Facial Expression Analysis // Proceedings of the International Conference on Machine Vision and Applications (ICMVA 2018). Singapore, 23-25 April. 2018. pp. 66–70.

17. Khryashchev V., Pavlov V., Priorov A., Kazina E. Convolutional Neural Network for Satellite Imagery // Proceedings of the 22th Conference of Open Innovations Association FRUCT'22. Jyväskylä, Finland, 15-18 May 2018. pp. 344–347.

18. Liu W., Anguelov D., Erhan D., Szegedy C., and Reed S.E. SSD: Single Shot Multibox Detector. CoRR, abs/1512.02325, 2015.

19. Fully convolutional reduced VGGNet [Электронный ресурс]. Режим доступа: <https://gist.github.com/weiliu89/2ed6e13bfd5b57cf81d6>.

20. Canny J. A Computational Approach to Edge Detection // IEEE Transactions On Pattern Analysis And Machine Intelligence. 1986. vol. Pami-8, no. 6. pp. 679–698.

21. ImageNet Image Database [Электронный ресурс]. Режим доступа: <http://www.image-net.org/>.

**Солонина А.И.**

### *Цифровая обработка сигналов в зеркале MATLAB*

**РЕЦЕНЗЕНТЫ:** Е.Б. Соловьева, д-р техн. наук, завкафедрой теоретических основ электротехники Санкт-Петербургского государственного электротехнического университета «ЛЭТИ»; А.А. Монаков, д-р техн. наук, проф. кафедры радиотехнических систем Санкт-Петербургского государственного университета аэрокосмического приборостроения.

Учебное пособие представляет собой базовый курс по цифровой обработке сигналов с традиционными темами: линейные дискретные системы; эффекты квантования в цифровых системах с фиксированной точкой; дискретные сигналы с описанием в частотной области, включая алгоритмы дискретного и быстрого преобразования Фурье; случайные процессы и их статистические характеристики; методы непараметрического и параметрического спектрального анализа; цифровые фильтры общего и специального назначения; многоскоростные системы и их полифазные структуры; банки фильтров; основы адаптивной обработки сигналов.

Теория ЦОС преподносится с позиции моделирования в MATLAB: теоретические аспекты базовых методов и алгоритмов ЦОС увязываются с их моделированием в MATLAB и иллюстрируются соответствующими примерами.

Книга предназначена для студентов и преподавателей вузов, а также специалистов в области цифровой обработки сигналов.



www.bhv.ru

Отдел оптовых поставок

E-mail: [opt@bhv.spb.su](mailto:opt@bhv.spb.su)

