

000 0100 0101 1101 1011 1001 0100 1010 1001 0010 0100 1110  
1110 0010 0110 0100 1011 0111 0011 1011 1100 0001 0101  
1000 0100 0101 1101 1011 1001 0100 1010 1100 1010 0101  
1001 0101 0001 0010 0110 1101 1100 1001 1110 0100 0001  
0101 0011 1011 1100 0001 0101 0001 0010 0110 1101 1110  
0101 0001 0010 0110 1101 1110 0100 0001 0101 0001 0001  
0101 0001 0010 0110 1101 1110 0100 0001 0101 0001 0001  
0101 0001 0010 0110 1101 1110 0100 0001 0101 0001 0001  
0101 0001 0010 0110 1101 1110 0100 0001 0101 0001 0001  
0101 0001 0010 0110 1101 1110 0100 0001 0101 0001 0001  
0101 0001 0010 0110 1101 1110 0100 0001 0101 0001 0001  
0101 0001 0010 0110 1101 1110 0100 0001 0101 0001 0001

ISSN 1729-5068 | 0010

# СИСТЕМЫ УПРАВЛЕНИЯ И ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

НАУЧНО-  
ТЕХНИЧЕСКИЙ  
ЖУРНАЛ

№ 3 (89)  
2022

МОДЕЛИРОВАНИЕ  
СЛОЖНЫХ  
ОБЪЕКТОВ И СИСТЕМ

ОПТИМИЗАЦИЯ  
И ПРИНЯТИЕ  
РЕШЕНИЙ

ПРИКЛАДНЫЕ ЗАДАЧИ  
И ИНФОРМАЦИОННЫЕ  
ТЕХНОЛОГИИ



Журнал зарегистрирован в Федеральной службе по надзору в сфере связи, информационных технологий и массовых коммуникаций **ПИ № ФС77-66093 от 10 июня 2016 г.** (первая регистрация от 20 мая 2003 г.)

ISSN 1729-5068

Журнал выходит четыре раза в год

## СИСТЕМЫ УПРАВЛЕНИЯ И ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

### РЕДАКЦИОННАЯ КОЛЛЕГИЯ:

Главный редактор

С.Л.Подвальный, д-р техн. наук, профессор

Заместитель главного редактора

В.Н.Бурков, д-р техн. наук, профессор

Ответственный секретарь

О.Я.Кравец, д-р техн. наук, профессор

### ЧЛЕНЫ РЕДАКЦИОННОЙ КОЛЛЕГИИ:

В.С.Балакирев, д-р техн. наук, профессор

Я.Е.Львович, д-р техн. наук, профессор

С.А.Баркалов, д-р техн. наук, профессор

Е.С.Подвальный, д-р техн. наук, профессор

В.К.Битюков, д-р техн. наук, профессор

А.К.Погодаев, д-р техн. наук, профессор

А.А.Большаков, д-р техн. наук, профессор

Ю.С.Сахаров, д-р техн. наук, профессор

В.Л.Бурковский, д-р техн. наук, профессор

Г.А.Угольницкий, д-р физ.-мат. наук,

Т.В.Киселева, д-р техн. наук, профессор

профессор

И.В.Ковалев, д-р техн. наук, профессор

В.Н.Фролов, д-р техн. наук, профессор

В.Н.Козлов, д-р техн. наук, профессор

В.П.Ханилов, д-р техн. наук, профессор

В.В.Кульба, д-р техн. наук, профессор

А.Г.Чхартишвили, д-р физ.-мат. наук, г.н.с.

Т.М.Леденева, д-р техн. наук, профессор

Статьи, поступающие в редакцию, рецензируются. За достоверность сведений, изложенных в статьях, ответственность несут авторы публикаций. Мнение редакции может не совпадать с мнением авторов материалов. При перепечатке ссылка на журнал обязательна.

Материалы публикуются в авторской редакции.

### Дизайн обложки Т.А.Бурковская

Адрес учредителя и редакции:

Телефон: (473)2437718

394006, г. Воронеж, ул. 20-летия Октября,

E-mail: [csit@bk.ru](mailto:csit@bk.ru)

дом 84

<http://www.sbook.ru/csit/>

16+

Учредитель: ФГБОУ ВО «Воронежский государственный технический университет»

Издатель: ООО Издательство «Научная книга» <http://www.sbook.ru>

Адрес издателя: 394077 Воронеж, 60-й Армии дом 25-120

Цена свободная.

Отпечатано с готового оригинал-макета в ООО «Цифровая полиграфия»

394036, г.Воронеж, ул.Ф.Энгельса, 52, тел.: (473)261-03-61

Подп. в печать 01.09.2022. Дата выхода в свет 30.09.2022. Заказ 1075. Тираж 500. Усл. печ. л. 10,2.

## Содержание

<b>Раздел 1. Моделирование сложных объектов и систем (шеф-редактор В.Л.Бурковский)</b>	
Болнокин В.Е., Каперко А.Ф., Сорокин С.А., Саксонов Е.А. Модели дистанционного	
управления движением беспилотного судна .....	4
Бычков А.Г., Киселёва Т.В., Маслова Е.В. Использование сегментации в свёрточных	
нейронных сетях для повышения точности классификации.....	7
Калинин М.Ю. Цифровой имитатор случайного процесса на основе его многомерной	
марковской модели .....	10
Краев К.В., Зайцев П.А. Модели прогнозирования безотказной работы низкоорбитальных	
спутников связи .....	14
Кустов А.И., Моисеев С.И., Степанов Л.В. Моделирование продвижения новых товаров и	
услуг на рынке на основе марковских случайных процессов .....	19
Щербаков А.П., Шмырин А.М., Мишачев Н.М. Идентификация мультимодальных	
окрестностных систем .....	24
<b>Раздел 2. Оптимизация и принятие решений (шеф-редактор Т.М.Леденева)</b>	
Аль Мусави О.А.Р., Красновский Е.Е. Экспериментальное исследование эффективности	
алгоритмов повторной оптимизации запросов в облачных базах данных на основе	
компьютерного обучения.....	29
Ананьев А.В., Иванников К.С., Моисеев С.И. Применение теории латентных переменных для	
анализа элементного базиса устройств обработки сигналов на основе метода парных	
сравнений.....	35
Ахматшин Ф.Г., Казаковцев Л.А. Алгоритм FOREL-2 с жадной эвристикой выбора радиуса	
поиска локальных сгущений.....	39
Ветров И.И., Куцакин М.А., Михалев П.А. К вопросу о структурно-параметрической	
оптимизации систем федеративного машинного обучения .....	42
Громей Д.Д., Козлов С.В., Филимонов А.В. Оптимизация распределения пространства	
выборки для запросов с группированием в процессе их приближенной обработки .....	48
Львович Я.Е., Рындин Н.А. Алгоритм оптимального распределения ресурсного обеспечения	
на стадии развития и функционирования цифровой среды управления .....	54
Миньюй Гао, Цепкова М.И., Резова Н.Л., Чжаньцюнь Ма, Ступина А.А. Алгоритм	
группирования текстовых данных с рекомбинацией по принципу химической	
реакции.....	61
<b>Раздел 3. Прикладные задачи и информационные технологии (шеф-редактор</b>	
<b>Е.С.Подвальный)</b>	
Азиз А.И. Архитектура многосерверной СУБД с раздельной обработкой транзакций и	
распределением вычислений .....	66
Болнокин В.Е., Каперко А.Ф., Сорокин С.А., Сторожев В.И., Сторожев С.В. Нечетко-	
множественная методика учета разброса параметров в расчетных моделях прочности	
компонентов на платах радиоэлектронных устройств: теоретические алгоритмы.....	71
Горшков А.В., Кравец О.Я. Расширение функций мобильных программных агентов при	
решении задач балансировки нагрузки в распределенных системах управления .....	78
Морковин С.В., Невров А.А. Метод внедрения невидимых робастных цифровых водяных	
знаков в видеопоследовательность на основе изменяемых координат маркирования.....	85
Синюков Д.С. Модифицированный протокол планирования для оптимизации выполнения	
транзакций без превышения их предельных сроков .....	89
Сушкевич Н.В., Казаковцев Л.А. Анализ устойчивости системы зарядно-разрядного	
устройства для литий-ионных аккумуляторов большой емкости в режиме стабилизации	
мощности аккумуляторного элемента .....	95

### Список использованных источников

1. ГЛОНАСС: принципы построения и функционирования/ Под ред. А.И. Перова, В.Н. Харисова. - М.: Радиотехника, 2005. - 688 с.
2. What is a GPS? How does it work?. Everyday Mysteries. [https://en.wikipedia.org/wiki/Library\\_of\\_Congress](https://en.wikipedia.org/wiki/Library_of_Congress). April 12, 2022.
3. Bolnokin V.E., Uy D.V., Manh D. X. Adaptive control for group of ships (fuzzy logic approach). - Vietnam, Haiphong, National Maritime University printing company, 2007, 244 pp.
4. Bolnokin V.E., Mutin D.I., Mutina E.I., Storozhev S .V. The synthesis of the algorithms for adaptive control by nonlinear dynamic objects on the basis of the neural network// International Workshop "Advanced Technologies in Material Science, Mechanical and Automation Engineering, 2019, London, UK IOP Conf. Ser.: Mater. Sci. Eng. 537 042013, P. 42013.

УДК 004.93

DOI: 10.36622/VSTU.2022.88.3.002

## Бычков А.Г., Киселёва Т.В., Маслова Е.В.

### ИСПОЛЬЗОВАНИЕ СЕГМЕНТАЦИИ В СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЯХ ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ КЛАССИФИКАЦИИ

Сибирский государственный индустриальный университет

*В работе рассматриваются структура свёрточной нейронной сети и математические методы, используемые для подсчёта её значений. Для повышения точности классификации предложены методы сегментации. Также рассматриваются различные способы оптимизации исходного набора данных, что также влияет на скорость работы алгоритмов.*

В настоящее время машинное обучение применяется во многих областях, как науки, так и промышленности. 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 технологии работы с данными в цифровой форме [1]. Данное определение подразумевает наличие определённых математических действий, которые могут затрачивать недопустимо большое количество машинного времени. Это является одной из причин недостаточно быстрого внедрения технологий машинного обучения в различные сферы деятельности. Довольно часто нейронные сети и машинное обучение применяется для распознавания изображений [2]. В данной статье рассмотрены возможные способы использования работы методов сегментации в машинном обучении в свёрточных нейронных сетях.

Идея свёрточных нейронных сетей состоит в том, что веса и значения активации какого-либо нейрона зависят не от всех входов, а только от некоторой окрестности «вокруг» него. После чего такое «движущееся окно» проходит по

всему изображению.

В итоге для соседнего «пикселя» в свёрточном слое будут те же самые веса, но входной кусок картинки будет сдвинут.

Идея состоит в том, что в одной ячейке свёрточного слоя записывается определённый паттерн изображения (линии, углы, цветовые пятна и т.п.), которые после прогоняются с целью найти похожие паттерны в других частях изображения, либо же других изображениях в принципе.

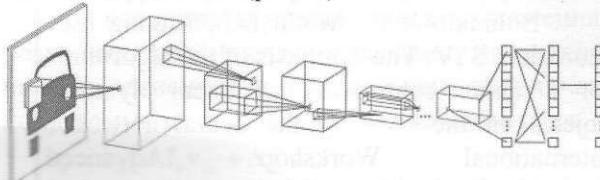
Важной особенностью свёрточных нейронных сетей является Pooling layer или, как в некоторых источниках его называют, субдискретизирующий слой [3].

Он даёт возможность менять длину и высоту активационных карт. Поставив этот слой после ReLU, можно сжать получившиеся значения. Делается это по простому правилу. К примеру, на рисунке 8 используется Max Pool - выбирается максимальное значение из квадрата 2x2 и передаётся дальше. Это позволяет во время обратного прохода отдать весь градиент именно этому значению, а остальным - нули (максимум зависит от одного входа).

Такое сжатие позволяет создать информацию, которой оперирует сеть, более глобальной. В вышеуказанном примере, в левом верхнем квадранте будет самым важным число 6, а остальные входы имеют меньшее значение, что позволит применять обученную в дальнейшем сеть к более широкому классу изображений, избегая тем самым переобучения модели. Это даёт возможность передавать дальше лишь самые выделяющиеся признаки на картинке, не вдаваясь в мелкие подробности (избегая переобучения), но при этом, обучая модель, видеть всю картинку целиком [4].

В итоге условная свёрточная нейросеть мо-

ожет выглядеть так (рис. 1).



На вход подаётся изображение, дальше свёрточный слой его обрабатывает, затем проpusкается через нелинейность (ReLU). Может быть несколько комбинаций свёрточных и ReLU-слоёв. Далее происходит сжатие с помощью Pooling Level. Вся эта конструкция может повторяться далее, пока не получается свёрточный слой, достаточно малый для того, чтобы его можно было сделать «плоским» - перевести в одномерный массив, - связать с полносвязным слоем, который можно пропустить через Softmax и получить уже готовый результат.

Данная архитектура имеет огромное преимущество: она по умолчанию адаптирована к сдвигам изображений. Если нужный элемент переместился в другой угол изображения, к примеру, то свёрточные веса тоже сдвинутся. Но в отличие от перцептрона есть ещё и Pooling-слои, которые обеспечивают максимальное значение активации. Через несколько итераций таких слоёв в итоге на выходе окажется именно тот, который отвечает за распознавание именно этого элемента [5].

Подавляющее число ранних исследований связано с классификацией. Сначала бинарной, а потом и многовариантной, но всё же классификацией одного объекта. Тогда как на изображении может быть 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. И поэтому возникла задача сегментации.

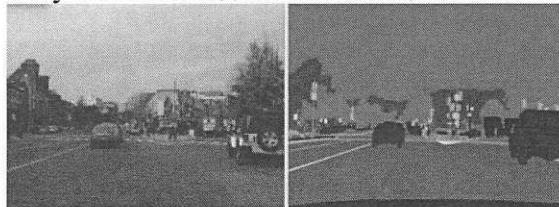


Рис. 2. Результат работы сегментации

Про сегментацию можно говорить как про попиксельную классификацию. На вход подаётся растровое изображение (из пикселей). На изображении выше (рис. 2) с левой стороны приведён пример с вождением автомобиля: деревья, светофоры, машины, люди. На выходе должно получиться некое подобие того, что на правой стороне изображения. Т.е., изображение того же размера, но вместо каждого пикселя

предсказывается, какой класс у объекта. Т.е., можно думать про каждый пиксель как независимый классификатор [6].

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 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 меньше тренировочных данных.

Для оценки эффективности работы сегментации используются различные метрики. Использование Precision и Recall уже не позволяет достичь желаемых результатов. Самые часто используемые - Dice и Jaccard (Intersection over Union - IoU).

Ground-truth в таком случае будет некоей маской для изображения, которая утверждает, что данный конкретный пиксель принадлежит конкретному объекту. Условно, в задаче определения машин на изображении (машиное 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, тогда как в остальных случаях обычно используют Jaccard (IoU), как самую интуитивно понятную метрику [7].

Важным отличием нейронных сетей для задач сегментации от обычных CNN является уход от Dense-слоёв, т.е., от fully-connected слоёв (рис. 3).

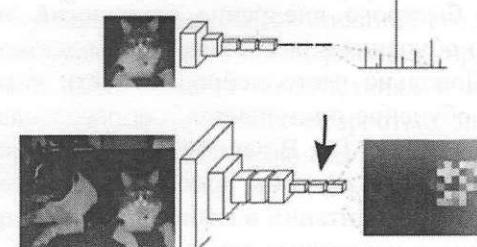


Рис. 3. Схема FCN

Такая сеть получила название Fully Convolutional Network (FCN). Для получения FCN из обычной CNN необходимо либо полностью убрать fully-connected слои, либо изме-

нить 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 они используют на входе изображения любого размера [9].

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 его части. Процесс очень похож на обычный подход, но берётся большее изображение при сохранении.

Если задача стоит шире, чем определение наличия или отсутствия какого-либо класса, т.е., в случае небинарной классификации, то в FCN дополнительно, кроме прочих операций, надо добавить слой upsampling, как на рис. 4.

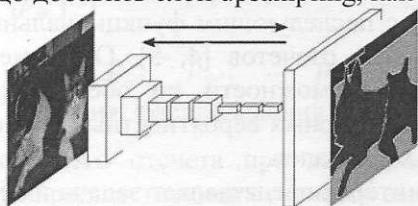


Рис. 4. Финальная схема FCN с upsampling

Т.е., мы увеличиваем heatmap до исходного размера для корректного определения объектов. Впервые такой подход был использован в 2015 в сети под названием FCN8 [1]. Есть разные методы upsampling, но обычно используют либо nearest neighbor upsampling, или bilinear upsampling. Дальше авторы улучшили FCN8 до SegNet в виде добавления иерархического upsampling [10].

Следующим шагом по улучшению работоспособности SegNet стало добавление skip-connections (наподобие ResNet) в виде сети UNet [5]. Пример показан на рис. 5.

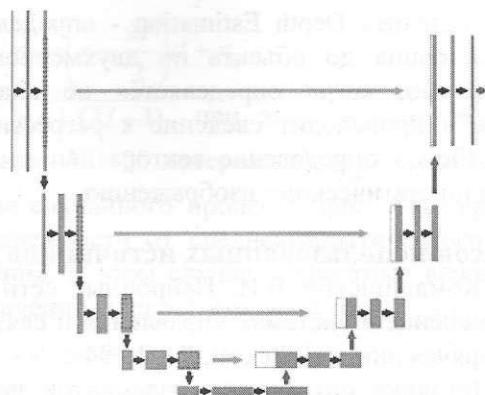


Рис. 5. Схема U-Net

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 [10].

Сверточная часть похожа на обычную свёрточную сеть, она содержит два подряд свёрточных слоя  $3 \times 3$ , после которых следует слой ReLU и пулинг с функцией максимума  $2 \times 2$  с шагом 2.

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

Данная архитектура на сегодняшний день является одной из самых распространённых для решения задач с повышенной точностью. Сеть UNet способна давать требуемые результаты на медицинских снимках, находить объекты размером в пару пикселей на больших изображениях и т.п.

Следующим шагом стало использование весов с заранее предобученными сетями. К примеру, разработанная в 2018 году русскими программистами TernausNet представляет собой тот же UNet, но с весами в encoder от предобученной VGG-11 на датасете ImageNet [11].

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, в большинстве случаев задача решается с помощью данной архитектуры.

Среди прочих применений сегментации

можно выделить Depth Estimation - определение расстояния до объекта по двухмерному изображению, когда определяется не класс пикселя, а происходит сведение к регрессии, Optical Flow - определение вектора движения объекта по статическому изображению.

#### **Список использованных источников**

1. Комашинский В.И. Нейронные сети и их применение в системах управления и связи. - М.: Горячая линия-Телеком, 2002. - 94 с.
2. Методика оптимизации элементов нейронной сети на примере персептрона/ А.Г. Бычков, Т.В. Киселева, Е.В. Маслова// Системы управления и информационные технологии. - 2022. - № 1. - С. 4-8.
3. Червяков Н.И. Применение нейронных сетей для задач прогнозирования и проблемы идентификации моделей прогнозирования// Нейрокомпьютеры: разработка и применение, 2003. - № 10. - С. 11-14.
4. Круглов В.В. Искусственные нейронные сети. Теория и практика. - М.: Горячая линия-Телеком, 2001. - 382 с.
5. Хайкин С. Нейронные сети. Полный курс. - М.: ИД «Вильямс», 2006. - 1104 с.
6. Глубокое обучение/ С. Николенко, А. Кадурин, Е. Архангельская. - СПб.: Питер, 2018. - 480 с.
7. Комплекс программ для навигации мобильных устройств внутри помещений с помощью нейронных сетей/ Е.Л. Яковлев, А.Д. Хомоненко, П.А. Новиков // Информационно-управляющие системы. - 2016. - № 1. - С. 32-39.
8. Shelhammer L.E., Darrell T. Fully convolutional networks for semantic segmentation// The IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 2015, p. 3431-3440.
9. SegNet: A deep convolutional encoder-decoder architecture for image segmentation/ V. Badrinarayanan, A. Kendall, R. Cipolla. - arXiv:1511.00561, 2015.
10. U-net: Convolutional networks for biomedical image segmentation/ O. Ronneberger, P. Fischer, T. Brox// Proc. Med. Image Comput. Comput.-Assisted Intervention., 2015, p. 234-241.
11. Iglovikov V., Shvets A. TernausNet: U-net with vgg11 encoder pre-trained on imagenet for image segmentation. - arXiv:1801.05746, 2018.

УДК 621.396.932

DOI: 10.36622/VSTU.2022.88.3.003

Калинин М.Ю.

## **ЦИФРОВОЙ ИМИТАТОР СЛУЧАЙНОГО ПРОЦЕССА НА ОСНОВЕ ЕГО МНОГОМЕРНОЙ МАРКОВСКОЙ МОДЕЛИ**

ООО «ГОЛДЕКС», г. Москва

*Рассматривается цифровой имитатор случайного процесса с заданным трехмерным распределением вероятностей отсчетов на основе многомерной марковской модели, формирующий последовательность отсчетов с требуемыми вероятностными и корреляционными связями соседних значений.*

#### **Введение**

Устройства и программные модули для формирования случайных сигналов [1-6] с заданными вероятностными свойствами применяются в различных областях науки и техники, при проектировании, исследовании и испытаниях аппаратуры, для управления устройствами имитации радиоканалов с различными видами аддитивных и мультиплексных помех, в задачах прогнозирования, распознавания или классификации состояний наблюдаемых объектов.

В аналоговых генераторах случайных процессов в основном используются источники теплового шума. В простейших цифровых ими-

таторах применяются датчики чисел с одномерным равномерным распределением вероятностей [1, 7] с последующим функциональным преобразованием отсчетов [4, 5]. Они имеют ограниченные возможности по обеспечению заданных многомерных вероятностных свойств формируемых сигналов.

Особый интерес представляет задача имитации случайных процессов с заданными двух и трехмерными вероятностными свойствами, которые определяются по экспериментальному потоку данных, например, случайных числовых последовательностей в задачах прогнозирования [8] с использованием их трехмерных статистических связей.

Рассматриваются алгоритмы [9-11] и устройства [12] имитации случайных процессов с заданных многомерным распределением вероятностей на основе цепей Маркова [13, 14]. Они позволяют формировать последовательность отсчетов с заданным трехмерным распределением вероятностей.