

## 2. SPIKING RECURRENT NEURAL NETWORKS FOR THE CLASSIFICATION OF ELECTROCARDIOGRAMS BY THE TYPE OF ARRHYTHMIA

*Kirill Vyacheslavovich Nikitin, cand. sci. (engineering), associate professor, Peter the Great St. Petersburg Polytechnic University, Russia, St. Petersburg, Polytechnicheskaya str., house 29, BOX 195251, nikitin\_kv@spbstu.ru.*

**Annotation.** *Research and analysis of various models of spiking neurons and chemical synapses is performed with the help of the developed simulation environment of spiking neural networks. The results obtained are used to build a technique for the synthesis of the corresponding neural networks as a part of liquid state machine model. The problem of recognizing dynamic patterns within the paradigm of reservoir computing is considered. An example of application of the technique for the problem of classification of the electrocardiogram by the type of arrhythmia is presented.*

**Keywords.** *Liquid state machine, spiking neurons, dynamic pattern recognition, reservoir computing, synaptic plasticity, electrocardiogram classification.*

## ИМПУЛЬСНЫЕ РЕКУРРЕТНЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ КЛАССИФИКАЦИИ ЭЛЕКТРОКАРДИОГРАММ ПО ТИПУ АРИТМИИ

*Кирилл Вячеславович Никитин, к.т.н., доцент, Санкт-Петербургский политехнический университет Петра Великого, Россия, Санкт-Петербург, ул. Политехническая, дом 29, индекс 195251, nikitin\_kv@spbstu.ru.*

**Аннотация.** *С помощью разработанной среды моделирования импульсных нейронных сетей выполняется исследование и анализ различных моделей импульсных нейронов и химических синапсов. Полученные результаты используются для построения методики соответствующих нейронных сетей в составе машины неустойчивых состояний для решения задачи распознавания динамических образов в рамках парадигмы резервуар-*

ных вычислений. Рассматривается пример применения методики для решения задачи классификации электрокардиограмм по наличию и типу аритмии.

**Ключевые слова.** Машина неустойчивых состояний, импульсные нейроны, распознавание динамических образов, резервуарные вычисления, синаптическая пластичность, распознавание электрокардиограмм.

## Введение

Большинство всех существующих моделей нейронных сетей (далее — НС) можно условно разделить на два класса в зависимости от модели нейрона — искусственные нейронные сети (далее — ИНС) и биологически ориентированные нейронные сети [2.22]. В первом случае в качестве нейронов используются довольно простые математические модели, лишь поверхностно описывающие некоторые особенности своих прототипов [2.4; 2.22]: как правило, входные сигналы умножаются на веса, складываются и к ним применяется передаточная функция, чаще всего, сигмоидальная. Во втором случае нейроны моделируются как можно более правдоподобно, с учетом динамики, физических и химических свойств и процессов, происходящих в реальных нейронах [2.15; 2.18]. Одно из основных таких свойств — генерация нейронами коротких вспышек активности — импульсов (*spike*). Поэтому часто такие модели НС называют импульсными [2.18]. При моделировании *импульсных НС* для каждого нейрона составляется система дифференциальных уравнений (далее — ДУ) и далее эта система приближенно решается во временной области [2.61].

Во многих работах [2.26; 2.35; 2.37; 2.40; 2.42; 2.44] показано, что по своим возможностям импульсные НС обладают большим потенциалом по сравнению с искусственными, особенно при работе с изменяющимися во времени сигналами. Поэтому в настоящее время импульсным НС уделяется большое внимание в самых различных областях. Одним из активно развивающихся направлений в области теории нейронных вычислений являются так называемые резервуарные вычисления (*reservoir computing*, далее — РВ) [2.2; 2.33; 2.41; 2.56]. Их суть сводится [2.14] к попытке смоделировать как можно более правдоподобно некоторую область человеческого мозга — так называемый

резервуар и попытаться использовать эту модель для решения различных вычислительных задач, связанных с распознаванием образов. Термин «резервуар» означает набор некоторых элементов, связанных между собой. В качестве резервуара могут быть использованы [2.56] как чисто математические модели (*рекуррентная нейронная сеть* (далее — РНС) из искусственных, импульсных нейронов), так и физические модели (оптические, электронные, вязкие жидкие (liquid) среды) и даже биологические модели, представляющие собой выращенные искусственно популяции клеток. Если на вход резервуара подается некоторое возмущение, то это приводит к изменению его состояния по аналогии с тем, как падение предмета на поверхность воды вызывает появление затухающих волн [2.45]. По изменению состояния резервуара со временем можно определить, где, когда и какой сигнал был на его входе, т.е. решить задачу распознавания динамических образов. Отличительными особенностями данного направления являются следующие ключевые моменты [2.32; 2.45; 2.49; 2.56; 2.59]:

- резервуар выполняется в форме рекуррентной нейронной сети;
- архитектура РНС, как правило, формируется со случайными локальными связями;
- модели элементов — нейронов и связей — синапсов являются динамическими и описываются дифференциальными уравнениями;
- входная информация поступает на вход резервуара в виде последовательности изменяющихся значений;
- резервуар необходимо специальным образом сформировать и настроить, чтобы максимизировать его показатели, связанные с решением конкретной задачи [2.27; 2.38; 2.62];
- специальные устройства — считыватели извлекают информацию из состояния резервуара — для их настройки могут применяться алгоритмы обучения с учителем [2.4; 2.10; 2.16; 2.36; 2.48];
- динамический резервуар вместе со статическими считывателями эквивалентны обучаемой РНС, при этом за счет данного разделения значительно упрощается процедура обучения [2.45], так как фактически идет обучение не рекуррентной НС, а статической НС наподобие многослойного персептрона.

Резервуарные вычисления и импульсные НС имеют много общего. В частности, одна из основных моделей РВ — машина неустойчивых состояний (далее — МНС), предложенная в 2006 году Маассом [2.45], имеет в своем ядре импульсную РНС, выполняющую функцию кратковременной памяти и преобразующую входную динамику в некоторое многомерное состояние.

Направление по РВ на данный момент развивается довольно динамично [2.1; 2.3; 2.12; 2.17; 2.23; 2.54], но проблема синтеза резервуара для конкретной задачи является актуальной и нерешенной [2.33; 2.34; 2.37].

Для построения модели МНС и настройки ее параметров была разработана среда моделирования импульсных НС с большими возможностями как по моделированию отдельных составляющих импульсных НС, так и больших импульсных НС в составе системы распознавания динамических образов [2.7].

В начале данной статьи, являющейся продолжением предыдущих работ [2.6—2.8; 2.49; 2.50], приводится описание разработанной среды моделирования, исследование с помощью нее основных составляющих импульсных НС (импульсных нейронов, химических синапсов) как по отдельности, так и в составе рекуррентных нейронных сетей с локальными случайными связями. Результаты этого исследования затем используются в разработке методики синтеза резервуара — импульсной РНС в составе машины неустойчивых состояний [2.45]. Использование данной методики позволит улучшить качество распознавания и сократить время на проектирование и разработку соответствующих систем. В конечном итоге это позволит эффективно применять современные модели и методы машинного обучения [2.10; 2.20; 2.21; 2.60], в частности, в медицинских приложениях, что демонстрируется на примере с распознаванием типов аритмий по электрокардиограмме [2.19; 2.53].

## **2.1. Анализ используемых моделей и методов**

Рассмотрим некоторые модели импульсных нейронов и химических синапсов, составляющих ядро импульсных НС.

### 2.1.1. Импульсные нейроны

**Модели типа Интегрирование-Возбуждение.** Модель нейрона интегрирования и возбуждения (Integrate-and-fire (IaF)) [2.13] была предложена в 1907 году Луи Лапиком (Lapicque). Она является феноменологической и описывает работу нейрона на «поверхностном» уровне.

Модель IaF, как следует из названия, состоит из двух частей. Первая часть – это обычный интегратор – конденсатор, заряжаемый или разряжаемый входным током. Вторая часть модели отвечает за возбуждение: как только потенциал  $v$  достигает порогового значения  $\theta$ , происходит генерация импульса, потенциал сбрасывается до значения  $v_{reset}$ , а сам нейрон переводится в состояние рефракторности на период  $T_{refrac}$ , в течение которого он не воспринимает никакие внешние сигналы. Развитием модели IaF является введение в нее утечки тока через резистор: модель с утечкой Leaky IaF (LIF). Уравнение динамики для этой модели записывается следующим образом:

$$C \cdot \frac{dv}{dt} = \frac{v}{R} + \frac{v_{rest}}{R} + i_{ext}, \quad (2.1)$$

где  $v_{rest}$  – это потенциал покоя нейрона,  $R$  – сопротивление резистора,  $i_{ext}$  – внешний входной сигнал. Электрическая схема модели с утечкой показана на рисунке 2.1.




Рис. 2.1. Электрическая схема нейрона LIF

**Детальная модель Ходжкина-Хаксли** (Hodgkin, Huxley, 1952) [2.25] является одной из наиболее подробных из известных моделей биологического нейрона и описывает его динамику в терминах работы ионных каналов Na, K, Cl и Ca. Основной особенностью модели является наличие активных проводимостей натрия и калия, зависящих от потенциала  $v$ . Модель демонстрирует широкий спектр различных вариантов поведения, наблюдаемых в реальных

нейронах, но ее недостатком является сложность — как анализа, так и моделирования.

**Модели сокращенной размерности.** Были разработаны более простые модели [2.18; 2.30], основанные на модели Ходжкина-Хаксли, например, сокращенные модели  $Na + K+$ ,  $Na + p - K+$ , Фитцху-Нагумо, Ижикевича, Мориса-Леккара. Большую популярность получила модель Ижикевича [2.30; 2.31], т.к. за счет изменения параметров она может имитировать большое количество различных моделей реальных нейронов. Исходная модель [2.29; 2.30] записывается в форме уравнений состояния

$$\begin{cases} \frac{dv}{dt} = 0.04v^2 + 5v + 140 - u + i_{ext}, \\ \frac{du}{dt} = a(bv - u) \end{cases} \quad (2.2)$$

и уравнения сброса

$$v = c, \quad u = u + d, \quad \text{если } v \geq 30, \quad (2.3)$$

где  $v$  — потенциал нейрона в мВ,  $u$  характеризует восстановление мембраны,  $i_{ext}$  — входной ток,  $t$  — время в мс,  $a, b, c, d$  — параметры модели.

### 2.1.2. Синапсы

В импульсных НС сигнал на вход импульсных нейронов поступает через специальные связи — синапсы.

**Электрические синапсы.** С точки зрения физики электрический синапс между нейронами — это прямая электрическая связь. То есть ток  $i_{post}$ , протекающий через постсинаптический нейрон, пропорционален потенциалу пре-синаптического нейрона  $v_{pre}$ :

$$i_{post} = w_{el}v_{pre}. \quad (2.4)$$

Далее этот ток вызывает соответствующее изменение потенциала нейрона  $v$  (если ток положительный, то  $v$  растет, если отрицательный, то уменьшается):

$$\frac{dv}{dt} = f(v, par) + k \cdot i_{post}. \quad (2.5)$$




Рис. 2.2. Схема работы электрического (а) и химического (b) синапса ( $v$  – потенциал на входе синапса,  $i$  – ток на выходе синапса)

Задержка в электрических синапсах очень маленькая и ее можно не учитывать. Схематичное представление работы электрического синапса дано на рисунке 2.2а. Электрические синапсы являются удобным средством для стимуляции нейрона внешним воздействием.

**Химические синапсы** в отличие от электрических передают информацию только об импульсах. Поэтому связь между двумя нейронами не прямо пропорциональна потенциалу пресинаптического нейрона. При моделировании химических синапсов постсинаптический ток  $i_{post}$ , вызванный импульсами, можно смоделировать с помощью убывающих экспоненциальных функций:

$$i_{post}(t) = w_{chem} \sum_i 1(t - t_i - \tau_{delay}) \cdot \exp\left(\frac{t - t_i - \tau_{delay}}{\tau_{syn}}\right) \quad (2.6)$$

$$\frac{dv}{dt} = f(v, par) + k \cdot i_{post}(t), \quad (2.7)$$

где  $w_{chem}$  – сила связи синапса,  $t_i$  – время  $i$  импульса,  $\tau_{delay}$  – задержка,  $1(t - t_i - \tau_{delay})$  – ступенчатая функция Хевисайда, переходящая из 0 в 1 в момент времени  $t_i + \tau_{delay}$ ,  $\tau_{syn}$  – постоянная времени, характеризующая скорость убывания экспоненты. Схематичное представление работы химического синапса дано на рисунке 2.2b.

Химические синапсы наряду с импульсными нейронами являются основной особенностью импульсных нейронных сетей. Импульсные нейроны генерируют импульсы, а химические синапсы реализуют механизм взаимодействия между нейронами на основе импульсов. Поэтому часто импульсные нейронные сети называют *импульсно-связанными (pulse-coupled)*.

В базовом варианте НС химические синапсы являются статическими в том смысле, что их сила остается постоянной на протяжении всего времени. Существуют другие разновидности химических синапсов, у которых сила изменяется временно (динамические синапсы [2.46; 2.52]) и постоянно (синапсы с пластичностью [2.18; 2.63]).

**Связь импульсных нейронов через синапсы.** Сигнал на вход импульсного нейрона может поступать через электрические и химические синапсы. Через электрические синапсы приходят непрерывные сигналы от входов и шум, а через химические синапсы приходят импульсные сигналы от других импульсных нейронов.

### 2.1.3. Машина неустойчивых состояний

МНС структурно состоит из двух составляющих [2.45] – импульсной РНС и считывателей. РНС используется как резервуар с богатой динамикой со свойством различения входных последовательностей. РНС генерируется случайным образом в начале работы без дополнительного этапа обучения. При подаче на вход РНС временной последовательности она через какое-то время переходит в новое состояние, которое подается на считыватели. Те в свою очередь выделяют из сигнала РНС полезную информацию и решают требуемую задачу. Общая схема МНС показана на рисунке 2.3.




Рис. 2.3. Схема машины неустойчивых состояний

Импульсная РНС [2.6] имеет случайную 3-х-мерную структуру. Вероятность связи между двумя нейронами задается следующим законом [2.45]:

$$P(a,b) = \min [1, C(a, b) \cdot \exp(-(D(a,b)/\lambda)^2)], \quad (2.8)$$



где символами  $a$  и  $b$  обозначаются два нейрона,  $D(a,b)$  – евклидово расстояние между этими нейронами,  $\lambda$  – параметр, управляющий средним радиусом связи между нейронами,  $C(a,b)$  характеризует плотность связей и зависит от того какой тип имеют нейроны – возбуждающий или подавляющий [2.45].

*Импульсные НС* состоят из выше рассмотренных импульсных нейронов, связанных электрическими и химическими синапсами [2.18]. На вход таких НС может поступать информация как в импульсной форме, так и в аналоговой. Топология и размер импульсной РНС могут быть произвольными. Ограничения определяются только временем моделирования. Чем сложнее используемая модель нейрона – тем, как правило, меньше размер нейронной сети [2.24].

При подаче и съеме информации с импульсной РНС требуется применение специальных методов *кодирования/декодирования* из обычной непрерывной в импульсную и наоборот [2.11; 2.58].

*Считыватели* – устройства, предназначенные для анализа динамики резервуара и решения конкретных прикладных задач: классификации, аппроксимации и др. Для их настройки часто применяются алгоритмы обучения с учителем [2.5; 2.10; 2.16].

**Иерархия подсистем в МНС.** Приведенное выше описание МНС позволяет построить обобщенную структурную схему ее основных подсистем (рисунок 2.4). Входной сигнал кодируется, подается на вход импульсной РНС. Обработка информации в РНС зависит от ее структуры, используемых нейронов и синапсов. Эти три компоненты во взаимосвязи друг с другом формируют импульсную РНС. Далее сигнал с выхода РНС подается на вход считывателей. Считывателей может быть несколько, и они могут последовательно объединяться в цепочки. Определенная группа считывателей формирует на выходе сигнал, который является выходным сигналом МНС, а также выходным сигналом всей системы распознавания.

Оригинальный подход данной работы состоит в том, что в отличие от большинства других исследований [2.9; 2.27; 2.28; 2.38; 2.39] при создании методики синтеза импульсных РНС анализировался выходной сигнал импульсной РНС, имеющий сложную нелинейную динамику, а не сигнал с выходов

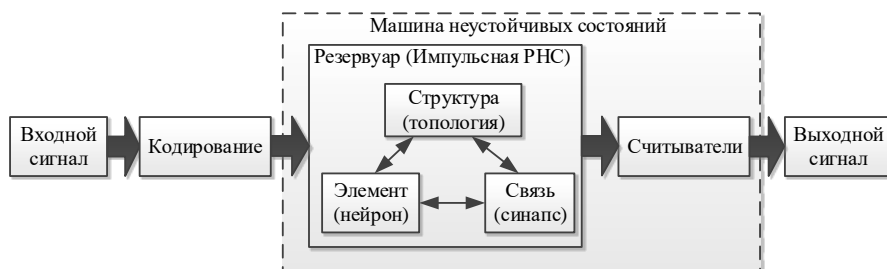


Рис. 2.4. Иерархия подсистем в исследуемой модели

считывателей. С одной стороны, это усложнило анализ, но с другой стороны дало намного больше информации.

## 2.2. Среда моделирования

### 2.2.1. Обоснование необходимости разработки среды моделирования

Для исследования импульсных РНС было принято решение о разработке своей программной среды моделирования импульсных РНС [2.24; 2.57], поскольку это дает ряд неоспоримых преимуществ:

- выполнение произвольного набора экспериментов;
- создание специализированных архитектур больших РНС;
- возможность онлайн-изменения большинства параметров используемых моделей;
- подача на вход РНС сигналов в произвольной форме;
- высокое быстродействие.

### 2.2.2. Пользовательский интерфейс

С учетом требований был продуман и реализован [2.7] настраиваемый MDI-пользовательский интерфейс (рисунок 2.5), позволяющий в разных подокнах главного окна программы задавать параметры эксперимента, запускать/прерывать моделирование, просматривать результаты (графики).

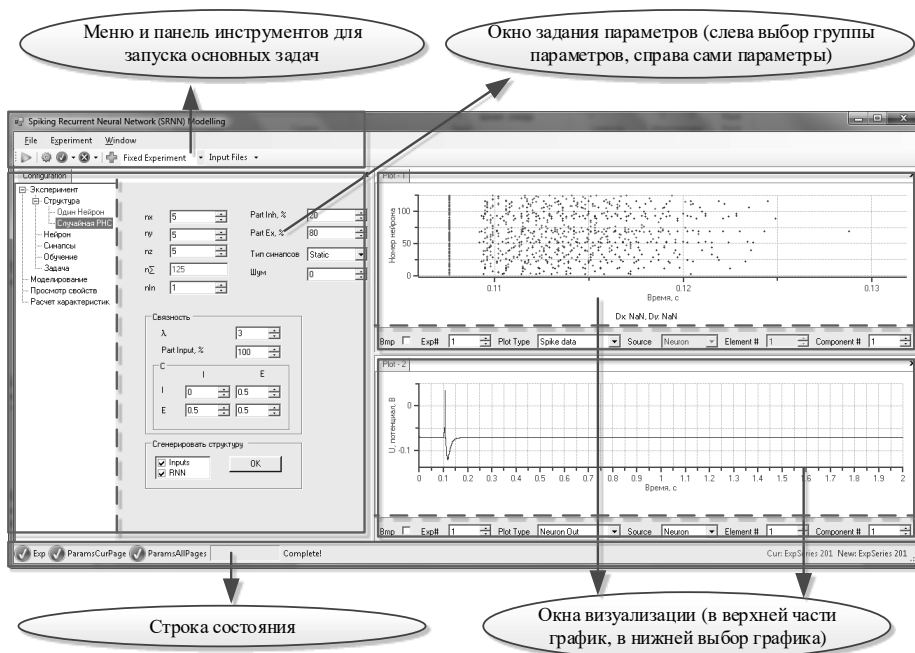


Рис. 2.5. Пользовательский интерфейс программы

### 2.2.3. Возможности разработанной среды моделирования

Приведем основные возможности разработанной среды моделирования [2.7]:

- моделирование биологических моделей нейронов (интегрирования и возбуждения – IaF, Ижикевича, Ходжкина-Хаксли, Фитцху-Нагумо, Морриса-Лекара);
- моделирование различных моделей синапсов (электрические и химические, статические и динамические, с пластичностью и без пластичности);
- обучение РНС (Spike Time Dependent Plasticity (STDP)) с различными функциями обучения (экспоненциальная, пороговая, гауссова);
- моделирование РНС различной структуры и топологии (один нейрон, случайная структура, слоистая структура);
- задание произвольных входных данных, в том числе шума на входе нейронов и начальных условий;

- обработка сигналов с РНС различными считывателями;
- задание шага моделирования, параметров записи статистики;
- построение графиков всех основных характеристик нейронов, синапсов, РНС;
- экспорт результатов (с последующим чтением например в Matlab);
- автосохранение результатов эксперимента с возможностью последующей загрузки.

*Любые новые варианты нейронов, синапсов, структур РНС и считывателей могут быть легко добавлены в программу.*

### **2.3. Исследование импульсных нейронных сетей**

Исследование такой сложной системы, как импульсная РНС со случайной структурой невозможно производить без понимания работы составляющих ее отдельных подсистем – в противном случае не понятно, какими задавать значения параметров этих подсистем. Поэтому в самом начале проводилось экспериментальное исследование различных подсистем – нейронов, синапсов, механизмов обучения импульсных РНС на основе синаптической пластичности (STDP) [2.18; 2.55], а также способов представления входных данных и анализа выходных.

#### ***2.3.1. Исследование способов представления входных данных***

Информация на вход модели импульсной РНС может подаваться тремя различными способами: в непрерывной форме, в импульсной форме, с преобразованием из непрерывной формы в импульсную.

##### ***2.3.1.1. Непрерывная форма***

В случае использования непрерывной формы входной сигнал подается на вход импульсных нейронов через электрические синапсы. Для подачи сигнала, изменяющегося во времени, используется интервальная форма представления входного сигнала. В ней производится квантование входного сигнала по времени, а затем для каждого интервала времени между моментами

квантования задается функция изменения сигнала. Функция задается либо постоянной (значение сигнала), либо линейно изменяющейся (смещение и угол наклона), либо изменяющейся по затухающей экспоненте (начальное и конечное значение, постоянная времени).

На рисунке 2.6 приведен входной сигнал, заданный на интервалах  $[0\ 0.1]$ ,  $[0.4\ 0.5]$ ,  $[0.8\ 1]$  линейно изменяющимся, на интервале  $[0.2\ 0.4]$  постоянным и на интервале  $[0.6\ 0.8]$  изменяющимся по затухающей экспоненте.




Рис. 2.6. Пример непрерывного входного сигнала

### 2.3.1.2. Импульсная форма

Предпочтительная форма представления входных сигналов — импульсная. В ней для каждого входного сигнала задаются моменты времени появления импульсов. Пример сигнала с импульсами в моменты времени 0.01с, 0.05с, 0.1с, 0.18с приведен на рисунке 2.7. Также на этом рисунке показан эквивалентный непрерывный сигнал, который подается на вход нейрона после прохождения через химический синапс с силой, равной 0.01 (в каких единицах). Каждый импульс моделируется убывающей экспонентой с постоянной времени 3 мс с задержкой 1 мс.

### 2.3.1.3. Преобразование из непрерывной формы в импульсную

Если исходный сигнал задан в непрерывной форме, то наилучшим вариантом является преобразование его из непрерывной в импульсную форму. Для этого существует большое количество способов. Существуют три основных способа: частотное преобразование с постоянной частотой, преобразование




Рис. 2.7. Пример импульсного входного сигнала: *a* — импульсы; *b* — соответствующий им входной непрерывный сигнал

в пуассоновский поток, пространственно-временной алгоритм на основе рецептивных полей [2.11].

Для выполнения преобразования исходный непрерывный сигнал должен быть задан в интервальной форме, причем внутри интервала сигнал должен быть константой. Далее рассмотрим все три способа преобразования на примерах.

На рисунке 2.8а приведен пример непрерывного сигнала, заданного на интервалах:  $i(t) = 10$ , если  $t \in [0; 0.25)$ ,  $i(t) = 100$ , если  $t \in [0.25; 0.5)$ ,  $i(t) = 50$ , если  $t \in [0.5; 1)$ . Далее на рисунке 2.8b показано преобразование этого сигнала в импульсный частотным способом. Можно убедиться, что входной сигнал преобразуется в частоту импульсов, т.е. в 10, 100 и 50 Гц соответственно.

Вышеперечисленные способы кодируют информацию о входном сигнале только во временной области. В импульсных же НС предпочтительным является пространственно-временное представление. Одним из наиболее интересных алгоритмов является рассматриваемый ниже алгоритм на основе рецептивных полей. В приводимом примере один непрерывный сигнал (рисунок 2.9а) преобразуется в десять импульсных (рисунок 2.9б). Непрерывный сигнал принимает значения от 1 до 10. Принцип кодирования заключается в том, что значение сигнала преобразуется в активность группы нейронов, при-




Рис. 2.8. Входной непрерывный сигнал (а) и преобразование этого сигнала в импульсный частотным способом (b)

чем центр этой группы зависит от значения входного сигнала — минимуму соответствует активность первых нейронов, максимуму — последних нейронов, среднему значению — средних нейронов.




Рис. 2.9. Входной ступенчато нарастающий непрерывный сигнал (а) и преобразование этого сигнала в импульсный методом рецептивных полей (b)

## 2.3.2. Исследование моделей нейронов

### 2.3.2.1. Нейрон интегрирования и возбуждения

Модель интегрирования и возбуждения может быть без утечки (чистый интегратор) и с утечкой. В случае с утечкой она имеет 5 настраиваемых параметров:  $\tau$ ,  $v_{rest}$ ,  $v_{reset}$ ,  $\theta$ ,  $T_{refrac}$ , в случае без утечки – 4 параметра (отсутствует  $v_{rest}$ ).

Численное интегрирование методом Эйлера для модели без утечки не накладывает никаких ограничений, для модели с утечкой – период должен быть меньше, чем  $2\tau$ . Постоянная времени нейрона  $\tau$  как правило имеет порядок 10–30 мс, поэтому шаг моделирования  $T_{step}$  можно выбирать в больших диапазонах – удобнее всего задать его равным 1 мс. В качестве входного сигнала будем рассматривать сигнал  $v_{ext} = R \cdot i_{ext}$ , измеряемый в вольтах.

Рассмотрим пример определения зависимости средней частоты импульсов нейронов от силы входного постоянного сигнала. Зададим значения основных параметров в соответствии с данными реальных биологических нейронов:  $\tau = 30$ ,  $v_{rest} = 0$ ,  $v_{reset} = 0$ ,  $\theta = 15$ . Построим графики зависимости частоты импульсов от значения входного постоянного сигнала для нейронов с утечкой и без утечки, а также с рефракторностью ( $T_{refrac} = 2$ ) и без рефракторности (рисунок 2.10). Видно, что нейрон с утечкой имеет определенный порог нечувствительности в том смысле, что генерация импульсов начинается только после определенного граничного значения входного сигнала. Нейрон без утечки наоборот, всегда генерирует импульсы. В обоих случаях нейроны больше похожи на нейроны с возбудимостью I типа, при которой частота генерируемых импульсов может быть сделана сколь угодно малой за счет подходящего значения входного сигнала. Рефракторность вводит зависимости частоты в насыщение, и предельная частота определяется как  $f = 1/T_{refrac}$ .

**Обобщение полученных результатов.** В сводной таблице 2.1 приведены результаты обобщения экспериментальных исследований влияния параметров нейрона интегрирования и возбуждения на его динамику.

При постоянном входном сигнале и отсутствии рефракторности частоту импульсов приблизительно можно определить, увеличив амплитуду постоянного входного сигнала в 2000 раз. Модель с утечкой имеет вначале зону нечув-



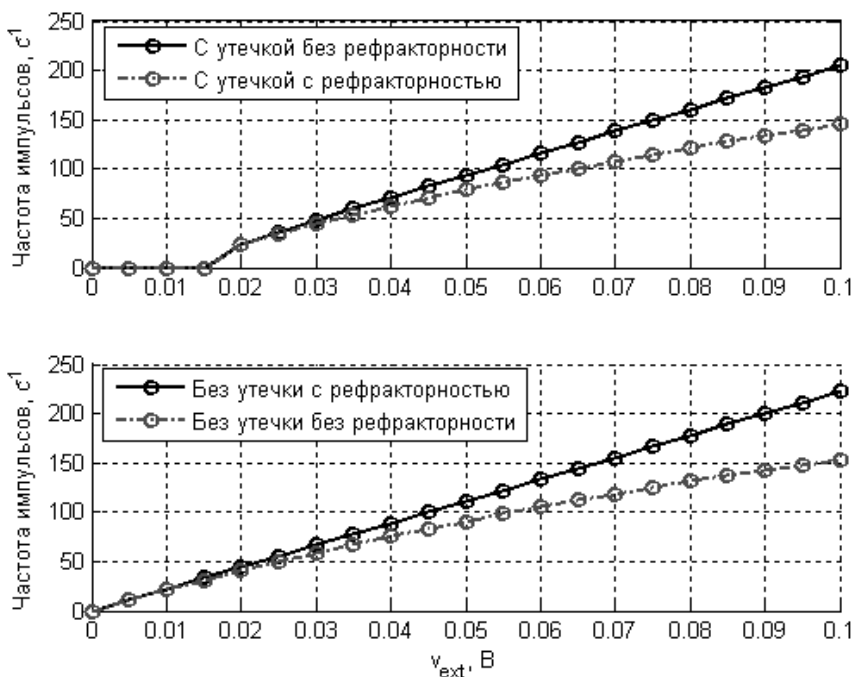


Рис. 2.10. Зависимость частоты нейрона от силы входного постоянного сигнала

ствительности до значения, определяемого порогом возбуждения нейрона. Рефракторность вводит рост частоты импульсов в насыщение, предельная частота равна значению, обратному периоду рефракторности. Эти свойства необходимо учитывать при выборе параметров электрических синапсов.

Для возбуждения нейрона импульсом необходима большая амплитуда импульса и, как следствие, большая сила химического синапса. Чем больше постоянная времени синапса, тем меньше эта амплитуда. Синхронное возбуждение несколькими импульсами еще больше уменьшает необходимую для возбуждения нейрона силу химического синапса.

При случайном сигнале нейрон IaF реагирует на среднее значение. Большой разброс значений приводит к появлению случайных импульсов.

### 2.3.2.2. Нейрон Ижикевича

Нейрон Ижикевича в зависимости от значений параметров может обладает различной динамикой и свойствами. Одной из характерной особенно-

## Влияние параметров на динамику модели нейрона интегрирования и возбуждения

Параметры	Влияние на динамику
Есть/нет утечки	Наличие утечки добавляет зону нечувствительности, в которой нейрон не генерирует импульсы в ответ на постоянный входной сигнал до какого-то порога. В отсутствии утечки этот порог отсутствует.
$\tau$	Постоянная времени замедляет процесс нарастания (убывания) потенциала нейрона и как следствие уменьшает частоту импульсов при воздействии постоянным сигналом.
$v_{rest}$	В отсутствии внешних сигналов потенциал нейрона всегда сходится к потенциалу покоя. Поэтому этот параметр влияет лишь при выходе нейрона из состояния покоя и входе в это состояние. Также от него зависит порог входного сигнала, при котором нейрон начинает генерировать импульсы.
$v_{rest}$	Потенциал сброса влияет при периодической генерации нейроном импульсов – если он близок к пороговому потенциалу, то импульсы генерируются чаще, в противном случае – реже.
$v_{thld}$	Порог влияет на пороговое значение входного сигнала и на зависимость частоты от силы входного сигнала – чем больше порог, тем больше пороговое значение входного сигнала и меньше частота генерируемых импульсов.
$T_{refrac}$	Конечное время рефракторности не позволяет нейрону генерировать импульсы со сколько угодно большой частотой, ограничивая ее фиксированным значением.

стей нейрона Ижикевича является возможность генерации так называемых *бёрстов* - последовательностей импульсов, следующих друг за другом с очень малым периодом. Помимо этого у нейрона Ижикевича можно настраивать частоту генерации импульсов, а также резонансную частоту, т.е. частоту входных импульсов, в ответ на которую нейрон возбуждается быстрее всего. Наиболее характерные варианты моделей нейрона Ижикевича приведены в таблице 2.2. Результаты исследования данных моделей при постоянном и импульсном входных сигналах приведены далее. Период моделирования  $T_{step}$  во всех экспериментах задавался равным 100 мкс.

**Влияние параметров на динамику модели нейрона  
интегрирования и возбуждения**

Класс	Модель, код	Описание	Значения параметров
Возбуждающие нейроны	RS	Regular Spiking (регулярная генерация импульсов)	$a = 0.02, b = 0.2, c = -65, d = 8$
	CH	Chattering («болтающий», генерирующий пачки бёрстов)	$a = 0.02, b = 0.2, c = -50, d = 2$
	IB	Intrinsically Bursting (генерирующий вначале бёрст, а затем периодические импульсы)	$a = 0.02, b = 0.2, c = -55, d = 4$
Подавляющие нейроны	FS	Fast Spiking (быстрая генерация импульсов)	$a = 0.1, b = 0.2, c = -65, d = 2$
	LTS	Low Threshold Spiking (с низким порогом возбуждения)	$a = 0.02, b = 0.25, c = -65, d = 2$
Особый класс	TC	Thalamo-Cortical (таламокортикальный)	$a = 0.02, b = 0.25, c = -65, d = 0.05$
Особая динамика	RZ	Rezonator, резонатор (не интегрирующий, а усиливающий определенные частоты)	$a = 0.1, b = 0.26, c = -65, d = 2$

Приведем наиболее характерные режимы каждой из моделей, а затем опишем исследование влияния силы тока на частоту и количество импульсов. Динамика моделей RS и FS приведена на рисунках 2.11 и 2.12. На верхнем графике показано изменение потенциала  $v$ , на нижнем – изменение переменной восстановления  $u$ . У модели FS переменная восстановления имеет более быструю динамику. Поэтому нейрон быстрее восстанавливается и частота импульсов выше. Также для ускорения динамики после импульса переменная  $u$  в модели FS возрастает на меньшую величину (2), чем в модели RS (8). Это также сказывается на скорости импульсов. Более часто наблюдаемая в модели RS адаптация частоты импульсов вызвана переходным процессом по переменной  $u$ .

На следующем рисунке 2.13 приведена динамика модели CH. При появлении входного сигнала потенциал и переменная восстановления растут. После первого импульса переменная восстановления скачкообразно возрастает,




Рис. 2.11. Динамика модели RS при постоянном входном сигнале: потенциал  $v$  (a) и переменная восстановления (b)




Рис. 2.12. Динамика модели FS при постоянном входном сигнале

потенциал также возрастает, и появляется второй импульс. При этом большее значение  $u$  замедляет рост  $v$ , что видно по увеличивающемуся периоду бёрстов – последовательностей следующих почти друг за другом импульсов. С увеличением силы входного сигнала динамика изменяется – нейрон выходит в режим периодической генерации импульсов после процесса адаптации, который заключается в сходимости переменной  $u$  к установившемуся значению около 0.03.

Ниже на рисунке 2.14 приведены графики зависимости средней частоты от амплитуды входного сигнала для различных моделей.

Видно, что наиболее быстрая модель – ТС. Затем по порядку убывания идут модели RZ, FS, CH, LTS, IB, RS. Модель FS примерно в 5 раз чаще генерирует импульсы, чем модель RS. Для модели CH зависимость практически




Рис. 2.13. Динамика модели СН при постоянном входном сигнале: потенциал  $v$  (a) и переменная восстановления (b)

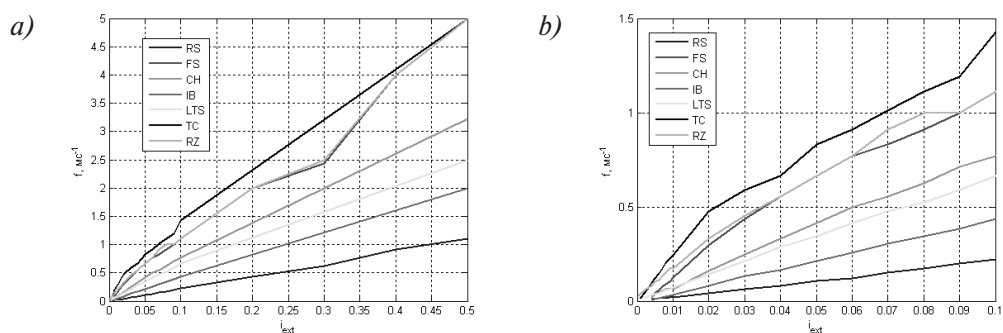


Рис. 2.14. Зависимость средней частоты импульсов от амплитуды входного сигнала для различных моделей нейронов Ижикевича: (a) - полный график, (b) - укрупненный фрагмент

является прямой линией с наклоном  $6.6 \text{ с}^{-1}/A$ , несмотря на то, что она генерирует бёрсты.

На диаграмме (рисунок 2.15) показаны режимы работы для различных моделей в зависимости от амплитуды входного сигнала.

Порог срабатывания  $i_{extThld}$  для различных моделей показан на диаграмме (рисунок 2.16). Наименьший порог имеет модель RZ, немного выше порог у моделей LTS и TC. Модели RS, FS, CH, IB имеют одинаковый порог, превышающий порог моделей LTS и TC почти в 5 раз.




Рис. 2.15. Зависимость режимов работы различных моделей нейрона Ижикевича от амплитуды входного сигнала




Рис. 2.16. Порог срабатывания для различных моделей нейронов Ижикевича

### Обобщение полученных результатов.

- А. В отличие от нейрона интегрирования и возбуждения нейрон Ижикевича может генерировать бёрсты и обладает свойством адаптации частоты импульсов. За счет подстройки параметров нейрон Ижикевича может демонстрировать различное поведение, что позволяет просто

формировать популяции нейронов с различными свойствами, например при создании импульсной РНС:

1. задавать возбуждающие нейроны медленными, а подавляющие нейроны быстрыми;
  2. задавать свойства одного типа нейронов (возбуждающих) немного отличающимися (случайными), как в реальных биологических НС.
- V. Самые быстрые нейроны – TC, RZ, FS, немного более медленные – нейроны CH, LTS, IB, самые медленные – типа RS.
- C. Практически у всех моделей средняя активность (частота импульсов) линейно зависит от амплитуды входного сигнала. Модели CH, IB при небольшой амплитуде входного сигнала демонстрируют бёрстовую активность. При большой амплитуде входного сигнала все модели генерируют импульсы с постоянной большой частотой.
- D. У моделей RS, FS, CH пороговая амплитуда постоянного входного воздействия равна  $i_{extThld} = 0.004$ , пороговая сила химических синапсов при импульсном воздействии равна –  $w_{thld} = 0.01$ . У моделей LTS, TC, RZ  $i_{extThld}$  чуть менее 0.001,  $w_{thld} = 0.002$ . Для импульсного воздействия пороговая амплитуда почти не зависит от постоянной времени импульсного тока  $\tau_{syn}$ .

### **2.3.3. Исследование синапсов**

#### **2.3.3.1. Электрические синапсы**

Электрические синапсы передают входной непрерывный сигнал без изменения его формы, пример их работы приведен на рисунке 2.17. На рисунке 2.17а показан подающийся на вход синапса сигнал, равный 5 до 0.5 с и 15 после 0.5 с. Сила синапса равна 0.015. Моделируется синаптический шум со средним значением 0.0135 и СКО (расшифровать) 0.001. Результирующий сигнал, подающийся на вход нейрона, представлен на рисунке 2.17б.

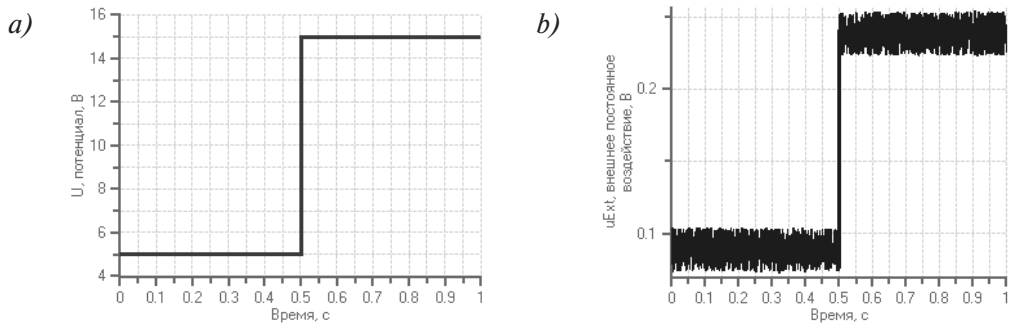


Рис. 2.17. Зависимость средней частоты импульсов от амплитуды входного сигнала для различных моделей нейронов Ижикевича: *a)* — полный график, *b)* — укрупненный фрагмент

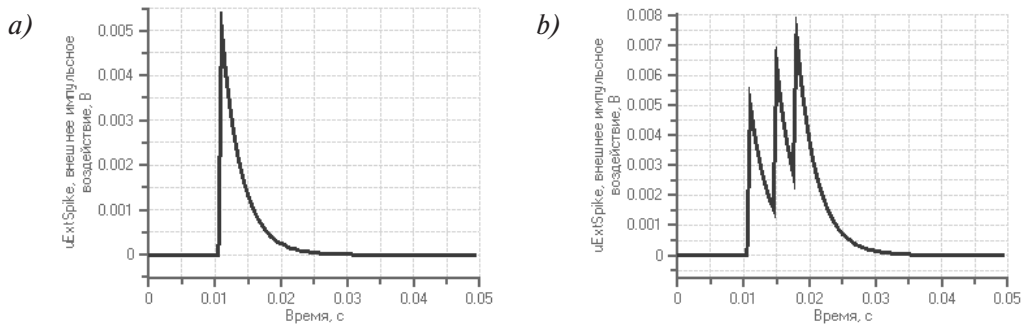


Рис. 2.18. Сигнал на выходе химического синапса при передаче одного (*a)* и трех (*b)* импульсов

### 2.3.3.2. Химические синапсы

Химические синапсы передают импульсы с помощью тока, затухающего по экспоненте. Они характеризуются 3-мя параметрами: силой синапса  $w$ , постоянной времени затухающего тока  $\tau_{syn}$ , а также величиной задержки  $\tau_{delay}$ . График выходного сигнала химического синапса в ответ на импульс приведен на рисунке 2.18. Входной импульс пришел в момент времени 0.01 с. Через задержку 1 мс появился сигнал, начальная амплитуда которого равна силе синапса 0.005. Через время, равное примерно трем постоянным времени  $3 \cdot 3 = 9$ , сигнал почти равен 0.

При передаче трех импульсов, поступающих в моменты времени 0.01с, 0.014с, 0.017с, выходной сигнал синапса равен сумме импульсных токов, вы-



званных каждым отдельным импульсом с учетом времени между импульсами. То есть с течением времени после импульса сигнал от каждого импульса затухает по экспоненте с постоянной времени  $\tau_{\text{суп}}$ .

### 2.3.3.3. Динамические синапсы

Динамические синапсы, рассматриваемые в работе, являются разновидностью химических синапсов, наделенных дополнительной кратковременной памятью. При проходе через них импульсов синаптическая эффективность временно уменьшается, а затем восстанавливается. Пример приведен на рисунке 2.19. На вход синапса подаются 11 импульсов с шагом 1 мс, начиная с 0.01с. Выходной сигнал динамического синапса представлен на рисунке 2.19б.




Рис. 2.19. Входные импульсы (а) и реакция (выходной сигнал) динамического синапса (b)

Данная реакция объясняется внутренней динамикой синапса.

## 2.3.4. Исследование структуры импульсных РНС

### 2.3.4.1. Влияние параметров на связность

Вероятность связи между двумя нейронами в РНС, входящей в состав МНС, определяется по формуле 2.8. Чтобы лучше представить, как влияют параметры на вероятность связей, можно построить графики зависимости вероятности связи от параметров. Для простоты будем считать, что значения матрицы связности  $C[a,b]$  одинаковы и равны константе  $c$ .

На рисунке 2.20 показана зависимость вероятности связи  $P(a,b)$  от расстояния между нейронами  $D(a,b)$  при различных значениях  $\lambda$  и одном и том же значении  $c$ , равном 1. Из графика видно, что  $\lambda$  влияет на дальность (глубину, среднеквадратическое отклонение(СКО)) связей. Черным кружком обозначены случаи, когда расстояние равно  $\lambda$ . В этом случае вероятность связи равна  $c/e \approx 0.37$ .




Рис. 2.20. Зависимость вероятности связи от расстояния между нейронами при различных значениях  $\lambda$  и одинаковом значении  $c = 1$

На рисунке 2.21 показана зависимость вероятности связи  $P(a,b)$  от расстояния между нейронами  $D(a,b)$  при различных значениях  $c$  и одном и том же значении  $\lambda = 2$ .

Видно, что с уменьшением  $c$  увеличивается плотность, количество связей, но средняя дальность (расстояние между связанными нейронами) остается такой же. Также важно, что при больших  $c$  зависимость входит в насыщение




Рис. 2.21. Зависимость вероятности связи от расстояния между нейронами при различных значениях  $c$  и одинаковом значении  $\lambda = 2$

при маленьких расстояниях. В частности при  $c \geq 3$ , вероятность  $P(a,b) = 1$  для всех  $D(a,b) < \lambda$ .

Для РНС в форме 3-мерной решетки максимальным расстоянием является

$$D_{max} = \sqrt{n_x^2 + n_y^2 + n_z^2}. \quad (2.9)$$

В случае решетки в форме куба со стороной из  $n$  нейронов  $D_{max} = n\sqrt{3}$ , для  $n = 5$  максимальное расстояние  $D_{max} \approx 8.6$ .

#### 2.3.4.2. Представление структур с помощью матрицы связности

Для того, чтобы визуализировать связность в какой-либо структуре элементов, используется графическое изображение матрицы связности, в которой цветом кодируется некоторая характеристика связи между соответствующими элементами структуры. Такой характеристикой может быть расстояние, вероятность связи, наличие/отсутствие связи, сила связи.

В случае, если пространство одномерное, то график получается визуально понятным. Однако при размерности пространства два и выше такая форма представления имеет некоторые особенности.

Для исследуемой импульсной РНС структура имеет форму 3-мерной решетки. Поэтому далее рассмотрим особенности визуализации этой структуры с помощью матрицы связности.




Рис. 2.22. Графики матрицы расстояний (*a*) и матрицы вероятностей связей: ( $\lambda = 3, c = 1$  (*b*);  $\lambda = 3, c = 0.5$  (*c*);  $\lambda = 2, c = 1$  (*d*)) для РНС, структура которой – линия из 5 нейронов

Пусть РНС состоит всего из 5 нейронов, соединенных в одномерную структуру – линию. Графики матрицы расстояний и матрицы вероятности связей представлены на рисунке 2.22.

Из матрицы расстояний видно, что чем больше разница между индексами нейронов, тем больше расстояние между ними. В матрице вероятностей связи учтено то, что связи нейронов на самих себя отсутствуют. Из графика матрицы вероятностей связи видно, что чем ближе индексы нейронов, тем больше вероятность связи. С увеличением  $\lambda$  дальность связей увеличивается, а с увеличением  $c$  (или значений матрицы  $C$ ) увеличивается плотность связей.

Далее рассмотрим случай, когда структура РНС – 2-мерная решетка, состоящая из  $5 \times 5 = 25$  нейронов. На рисунке 2.23 приведен график матрицы расстояний. Из графика видно, что матрица является вложенной. Ее можно рассматривать как матрицу из  $5 \times 5 = 25$  матриц каждой размерности  $5 \times 5 = 25$ . Причем распределение значений во внешней и внутренних матрицах такое




Рис. 2.23. Графики матрицы расстояний (a) и матрицы вероятностей связей (b) для РНС, структура которой – 2-мерная решетка из  $5 \times 5 = 25$  нейронов

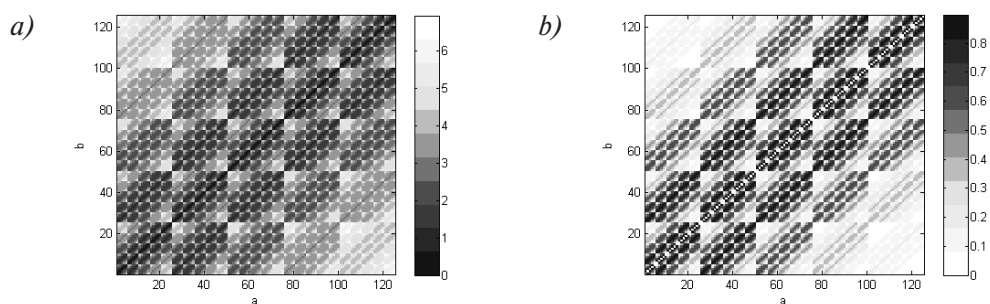


Рис. 2.24. Графики матрицы расстояний (a) и матрицы вероятностей (b) связей для РНС, структура которой – 3-мерная решетка из  $5 \times 5 \times 5 = 125$  нейронов

же, как и у матрицы на рисунке 2.22, т.е. на диагонали значения максимальные, а по мере удаления от диагонали значения уменьшаются.

На рисунке 2.23б показана матрица вероятностей связей – она имеет более четко выраженный характер: связи с наибольшей вероятностью сосредоточены вокруг главной диагонали. Далее идет «провал» вероятностей связей и затем опять две диагонали вокруг главной с локальными максимумами связей и т.д. с постепенным чередованием максимумов и «провалов» и с постепенным уменьшением локальных максимумов.

В заключение рассмотрим случай, когда РНС – 3-мерная решетка, состоящая из  $5 \times 5 \times 5 = 125$  нейронов. На рисунке 2.24а приведен график матрицы расстояний, а на рисунке 2.24б – матрицы вероятностей связей.

В данном случае матрица является вдвойне вложенной, т.е. ее можно рассматривать как матрицу  $X$  из  $5 \times 5 = 25$  матриц  $Y$ , каждая из которых состоит из  $5 \times 5 = 25$  матриц  $Z$  размерности  $5 \times 5 = 25$ . И распределение значений во

всех матрицах такое же, как и у матрицы на рисунке 2.22. Если говорить о структуре матрицы вероятностей, то она похожа на матрицу для двумерного случая (рисунок 2.23), но диагонали с локальными максимумами и минимумами теперь имеют прерывистый характер, т.е. в диагональ максимумов «врезаются» минимумы и также в диагональ минимумов «врезаются» максимумы.

Другой вариант представления структуры РНС показан на рисунке 2.25 – по осям  $X$  и  $Y$  представлены номера нейронов с 1 по 125, темными точками показано наличие связи, белыми – отсутствие. С целью экономии места, номера нейронов не отображаются, подразумевается, что по оси  $X$  они увеличиваются слева направо, а по оси  $Y$  – снизу вверх.



Рис. 2.25. Представление структуры импульсной РНС в программе моделирования

#### 2.3.4.3. Представление динамики импульсной РНС

Динамика импульсных НС может быть представлена различными способами. Основной способ – это общий график всех импульсов от каждого из нейронов. По оси  $Y$  отображаются нейроны, по оси  $X$  – время. Сами импульсы рисуются либо короткими вертикальными линиями, либо точками при большом числе нейронов. Импульсы от возбуждающих нейронов для удобства окрашиваются в один оттенок цвета (например, более светлый), а импульсы от подавляющих нейронов – в другой цвет (например, более темный). Иногда возбуждающие и подавляющие нейроны могут объединяться в отдельные группы и на графике вначале по оси  $Y$  отображаются возбуждающие нейроны, затем – подавляющие. Также для удобства на этот же график могут наноситься импульсы от входных сигналов. Они отображаются в отри-

цательной области  $Y$  и, например, импульсы для значения  $y = -k$  соответствуют импульсам от  $k$  входного сигнала.

На рисунке 2.26 приведен график импульсной динамики РНС из 125 нейронов в течение 0.2 с. Импульсы от возбуждающих нейронов представлены светлыми точками, от подавляющих — темными, от входов — также темными в нижней части графика в области отрицательных значений  $Y$ . На верхнем графике (рисунок 2.26а) нейроны расположены в своем порядке, соответствующем структуре, на нижнем графике (рисунок 2.26б) порядок нейронов определен с учетом их типа — возбуждающие снизу, подавляющие — сверху. Таким же образом могут быть построены и графики структуры — в первом случае метод упорядочивания нейронов соответствует структуре (рисунок 2.27а), во втором случае вначале располагаются подавляющие нейроны, а за ними - возбуждающие (рисунок 2.27б).

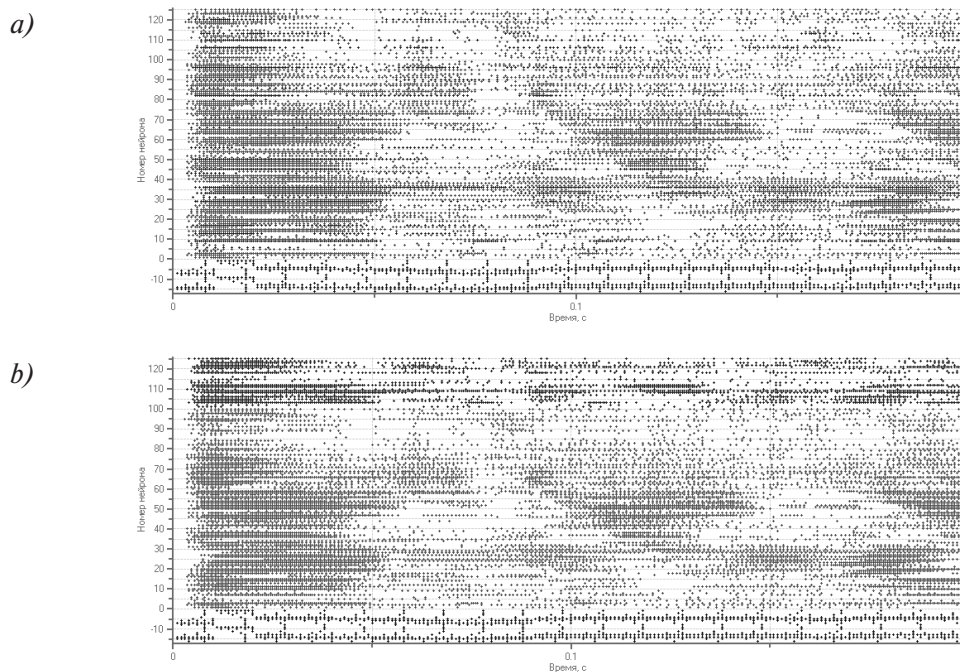


Рис. 2.26. Пример графиков динамики импульсной РНС




Рис. 2.27. Структура импульсной РНС, динамика которой показана на рисунке 2.26

## 2.4. Описание обобщенной методики синтеза импульсных РНС

Анализ результатов экспериментального исследования влияния параметров на динамику и введенные показатели импульсной РНС позволил построить обобщенную методику синтеза импульсных РНС и встроить ее в схему решения задачи распознавания динамических образов. Соответствующая схема представлена на рисунке 2.28.

### 2.4.1. Входные данные и их предобработка

Входные данные представлены набором примеров динамических образов в виде пар «входной сигнал — соответствующий ему выходной сигнал». Входной и выходной сигналы в общем случае являются многомерными функциями времени с размерностями  $n_{in}$  и  $n_{out}$  соответственно. Возможны две формы задания сигналов — непрерывная и импульсная.

- Показатели качества во многом зависят от набора обучающих примеров:
- количество примеров должно быть достаточным для обучения классификатора;
  - примеры должны максимально полно описывать задачу и равномерно «накрывать» пространство, соответствующее множеству входных сигналов;
  - шум в примерах должен быть «полезным», т.е. отображать наиболее характерные отклонения во входных сигналах;





Рис. 2.28. Схема решения задачи распознавания динамических образов с помощью МНС

- следует провести фильтрацию выборки на предмет наличия примеров, которые несут в себе мало «полезной» или наоборот много «бесполезной» информации.

После того, как определен набор примеров, необходимо выбрать способ их подачи на вход резервуара – импульсной РНС. *Предпочтительной* является импульсная форма представления входных сигналов. Поэтому если входной сигнал задан непрерывным, следует выполнить преобразование этого сигнала в импульсную форму. Среди всех алгоритмов преобразования из непрерывной в импульсную форму следует отдать предпочтение алгоритмам на основе пространственно-временного кодирования, в частности, алгоритму на основе рецептивных полей [2.11]. Этот алгоритм автоматически выполняет нормирование входных данных, поэтому никакая дополнительная предобработка не требуется. Ключевыми параметрами этого алгоритма являются:

- $k_x$  – во сколько импульсных входов преобразуется каждый непрерывный вход;
- $T_{min}$  – минимальный период импульсов.

При выборе их значений следует руководствоваться соображениями, что чем сложнее форма непрерывного сигнала, тем большее значение  $k_x$  следует задавать. Следует начинать со значения  $k_x$ , равного 8 и далее увеличивая до 16, 32, 64 и т.д. Минимальный период  $T_{min}$  следует задавать не меньше, чем 1 мс и не больше, чем постоянная времени нейрона (20–30 мс).

Если входной сигнал подается в непрерывной форме, то необходимо проинтерпретировать его нормирование, так чтобы значения, которые он принимает, лежали в диапазоне от 0 до 1.

Помимо проблемы представления входных данных в импульсной форме существует проблема, связанная с *временем представления входных образов*. Это время не должно превышать *глубину памяти* резервуара – в противном случае часть информации о входном сигнале будет «забыта». Глубину памяти резервуара можно определить следующим образом: сформируем две временные последовательности, у которых в конце есть общая одинаковая часть длины  $h$ ; тогда глубина памяти это максимальная продолжительность общей части  $h$ , выше которой две последовательности переводят резервуар в одно и то же состояние. Ограниченная глубина памяти связана с тем, что РНС по условию должна обладать свойством затухающей памяти. Для решения этой проблемы может быть использована техника нормализации сигналов во временном диапазоне. Средняя глубина памяти импульсной РНС равна 0.1–0.5 с. Если время представления входного образа превышает эти значения, следует сжать входной образ во времени до  $t_{norm}$  (например, до 0.25 с).

На данном шаге также может быть определена нечеткая мера, характеризующая *сложность* образов. Она зависит от скорости изменения, случайности, энтропии входных сигналов, их различимости и коррелированности для разных классов. Чем быстрее изменяются входные сигналы, чем выше их энтропия, случайность, чем хуже их различимость и чем больше коррелированность, тем сложность образов больше и наоборот.

#### **2.4.2. Синтез резервуара**

После того, как определен способ подачи данных на вход резервуара, можно приступить ко второму этапу – синтезу резервуара (импульсной РНС). Далее приводятся рекомендации по выбору типа и задания значений всех пара-

метров импульсной РНС, составленные на основе экспериментального исследования и анализа динамики импульсных РНС.

Вначале определяется количество входов  $n_{vh}$  РНС. Если преобразование из непрерывной в импульсную форму не происходит, то оно равно количеству входных сигналов  $n_{in}$ , если преобразование выполняется, то количество входов равно произведению количества входных сигналов на коэффициент размножения по входам  $k_x$ , который в предыдущем подразделе 2.4.1 был определен также как число импульсных входов для непрерывного сигнала.

Вероятность связи между входами и нейронами резервуара  $p_{vh}$  следует задать равной 10-20 %.

Количество нейронов  $n_{nrn}$  резервуара определяется сложностью задачи распознавания, определенной в конце подраздела 2.4.1 и количеством входов. Чем выше сложность и чем больше количество входов, тем больше должно быть нейронов. Минимально-допустимое значение числа нейронов равно 125 и соответствует трехмерной решетке  $5 \times 5 \times 5$ .

Процент подавляющих нейронов  $p_{inh}$  задается равным 20-30 % для любых типов нейронов.

Средняя длина связей  $\lambda$  вначале задается равной 2. Затем возможно скорректировать это значение, немного увеличив его (предельное значение равно 3).

Плотность связей задается матрицей  $C$  размерности  $2 \times 2$  ( $C[i, j]$  – плотность связей между нейронами типа  $i$  и нейронами типа  $j$ , где тип 1 – подавляющий, тип 2 – возбуждающий). Возможные значения матрицы  $C$ :

$$C = \begin{bmatrix} 0.4 & 0.4 \\ 0.2 & 0.4 \end{bmatrix}, C = \begin{bmatrix} 0.1 & 0.4 \\ 0.2 & 0.3 \end{bmatrix} \quad (2.10)$$

На основании значений  $n_{nrn}, n_{vh}, p_{vh}, p_{inh}, \lambda$  и формулы 2.8 случайным образом генерируется структура РНС, содержащая информацию о наличии/отсутствии связей между входами и нейронами и между нейронами. Формально структуру можно описать с помощью матриц  $H_{vh}, H_{int}$ :  $H_{vh}[i, j] = 1$ , если связь между  $i$ -м входом и  $j$ -м нейроном есть;  $H_{vh}[i, j] = 0$ , если эта связь отсутствует;  $H_{int}[i, j] = 1$ , если связь между  $i$ -м и  $j$ -м нейроном есть;  $H_{int}[i, j] = 0$ , если эта связь отсутствует.

Тип нейронов. В качестве нейронов для простых задач следует использовать нейроны типа «интегрирование и возбуждение», а для более сложных

задач – модели Ижикевича, Ходжкина-Хаксли, Морриса-Лекара. Выбор более сложной модели нейрона позволяет увеличить память резервуара за счет более длительной и уникальной реакции в ответ на входной изменяющийся сигнал.

При использовании *нейронов* типа «интегрирование и возбуждение» следует инициализировать их базовые параметры следующими значениями:  $v_{rest} = v_{reset} = 0$ ,  $\theta = 15$  мВ,  $T_{refrac} = 3$  мс,  $\tau = 30$  мс, утечка есть.

При использовании *нейронов Ижикевича* в качестве возбуждающих нейронов следует использовать модель RS с параметрами:  $a = 0.02$ ,  $b = 0.2$ ,  $c = -65$ ,  $d = 8$ , а в качестве подавляющих нейронов модель FS с параметрами:  $a = 0.1$ ,  $b = 0.2$ ,  $c = -65$ ,  $d = 2$ .

*Тип связей* определяется в первую очередь формой входного сигнала – для передачи непрерывных сигналов используются электрические синапсы, а для передачи импульсных – химические синапсы. В базовом варианте следуют используются статические химические синапсы. Для увеличения вычислительных возможностей (нелинейность, глубина памяти) следует использовать динамические синапсы с кратковременной памятью. Для адаптации РНС к входному импульсному сигналу используются синапсы с пластичностью.

*Сила связей* для всех синапсов вначале может быть задана детерминированной.

*Сила связей между входами и нейронами для электрических синапсов* задается вектором  $W_{vh(el)}$  из двух значений (1-е – для подавляющих нейронов, 2-е – для возбуждающих нейронов). Для нейронов типа «интегрирование и возбуждение» возможные значения  $W_{vh(el)}$  следующие:

$$W_{vh(el)} = \begin{bmatrix} 0.01 & 0.01 \end{bmatrix}, \quad W_{vh(el)} = \begin{bmatrix} 0.03 & 0.03 \end{bmatrix}, \quad (2.11)$$

а для нейронов Ижикевича:

$$W_{vh(el)} = \begin{bmatrix} 0.005 & 0.005 \end{bmatrix}, \quad W_{vh(el)} = \begin{bmatrix} 0.03 & 0.03 \end{bmatrix}, \quad (2.12)$$

При этом значения непрерывного входного сигнала должны быть нормализованы и приведены к диапазону от 0 до 1.

*Сила связей между входами и нейронами для химических синапсов* задается вектором  $W_{vh(chem)}$  из двух значений (1-е – для подавляющих нейронов, 2-е

– для возбуждающих нейронов). Для нейронов «интегрирование и возбуждение» возможные значения  $W_{vh(chem)}$  следующие:

$$W_{vh(chem)} = \begin{bmatrix} 0.03 & 0.03 \end{bmatrix}, \quad (2.13)$$

для нейронов Ижикевича:

$$W_{vh(chem)} = \begin{bmatrix} 0.01 & 0.01 \end{bmatrix}, \quad (2.14)$$

Сила связей между нейронами (для химических синапсов) задается матрицей  $W_{int}$  размерности  $2 \times 2$  ( $W_{int}[i,j]$  – сила связи между нейроном типа  $i$  и нейроном типа  $j$ , где тип 1 – подавляющий, тип 2 – возбуждающий). Для нейронов «интегрирование и возбуждение» матрица  $W_{int}$  задается следующим образом:

$$W_{int} = \begin{bmatrix} 0.02 & 0.01 \\ 0.01 & 0.05 \end{bmatrix}, \quad (2.15)$$

для нейронов Ижикевича возможные значения матрицы  $W_{int}$  приведены ниже:

$$W_{int} = \begin{bmatrix} 0.001 & 0.01 \\ 0.01 & 0.015 \end{bmatrix}, \quad W_{int} = \begin{bmatrix} 0.005 & 0.005 \\ 0.005 & 0.005 \end{bmatrix}. \quad (2.16)$$

В дальнейшем силы связей можно сделать *случайными* – распределенными нормально с математическими ожиданиями (МО), равными приведенным выше значениям и средне-квадратическими отклонениями (СКО), равными 10-30% от соответствующих значений математических ожиданий. При этом необходимо учитывать, что значения силы связей должны быть положительными.

*Постоянная времени затухания*  $\tau_{syn}$  импульсного тока задается для химических синапсов от входов и возбуждающих нейронов равной 3 мс и для подавляющих нейронов – 6 мс.

*Задержки*  $\tau_{delay}$  для химических синапсов задаются равными 1 мс. Для получения полихронных режимов (групп) необходимо задать задержки случайными, например, распределенными дискретно и равномерно от 1 мс до 10 мс с шагом 1 мс. Задержки должны быть кратны периоду моделирования  $T_{step}$  импульсной РНС.

Параметры *динамических синапсов* задаются следующим образом:

- коэффициент использования синапса в покое  $U = 0.5$ ;
- постоянная времени восстановления  $D = 10$  мс;
- постоянная времени разгрузки  $F = 50$  мс.

Возможно задание параметров динамических синапсов  $U$ ,  $D$ ,  $F$  случайными значениями (по аналогии с силой синапсов), например, распределенными нормально с МО, равным приведенным значениям и СКО, равным 10-30 % от МО. Значения  $U$ ,  $D$ ,  $F$  должны быть положительными.

Параметры *синапсов с пластичностью* задаются следующими значениями:

- максимальная по модулю сила синапса  $w_{max} = 0.2$ ;
- минимальное приращение силы синапса  $\Delta w_{min} = 0.0001$ ;
- постоянная времени забывания приращения силы синапса  $\Delta T_{forget} = 5$  с;
- период обучения  $T_{learn} = 1$  с.

Параметры *экспоненциальной функции обучения* задаются следующими значениями:

- максимальное положительное приращение  $X_{0LTP} = 0.0004$ ;
- минимальное отрицательное приращение  $X_{0LTD} = 0.0002$ ;
- постоянная времени положительного приращения  $T_{LTP} = 10$  мс;
- постоянная времени отрицательного приращения  $T_{LTD} = 10$  мс;

Параметры *пороговой функции обучения* задаются следующими значениями:

- максимальное положительное приращение  $A_{max} = 0.0004$ ;
- минимальное отрицательное приращение  $A_{min} = 0.0004$ ;
- порог для максимального приращения  $\Delta T_{max} = 10$  мс;
- порог для минимального приращения  $\Delta T_{min} = 10$  мс.

В конечном итоге в соответствии с рекомендуемыми значениями параметров формируется резервуар – импульсная РНС, на вход которого будут подаваться входные сигналы. Далее в РНС может быть выполнена процедура адаптации параметров на основе синаптической пластичности (в этом случае как раз и будут использоваться заданные выше параметры функций обучения). Данная процедура по своей сути является одной из вариаций обучения без учителя.

Основная процедура обучения с учителем в соответствии с парадигмой резервуарных вычислений осуществляется не в РНС, а в специальных устройствах - считывателях, о которых пойдет речь в следующем подразделе.

### 2.4.3. Выбор считывающих модулей

После формирования резервуара необходимо выбрать набор считывающих модулей, которые должны будут на основании состояния резервуара выдавать на выходе желаемый выходной сигнал. Предполагается, что желаемый выходной сигнал представлен в непрерывной форме, т.к. в большинстве случаев это именно так (довольно редко обучающая выборка содержит данные, представленные в форме точных значений моментов появления импульсов на выходах).

Последовательность выбора считывателей можно представить следующим образом:

- *определение времени считывания* – наилучшие результаты достигаются в большинстве случаев при времени считывания, соответствующем  $3/4$  времени подачи образа (то есть если образ длится 0.2 с, начиная с момента времени 1 с, то время считывания следует выбрать равным  $t_{readout} = 1 + 0.2 \cdot 0.75 = 1.15$  с);
- выбор алгоритма преобразования из импульсной формы в непрерывную – наиболее простые и эффективные варианты – преобразование каждого импульса в экспоненциально затухающий сигнал с постоянной времени  $\tau_{window} = 5 \div 20$  мс или подсчет числа импульсов на временном промежутке длительностью  $\tau_{window}$  до момента считывания, конкретные значения  $\tau_{window}$  подбираются исходя из плотности импульсов на выходе РНС.
- выбор алгоритма сокращения размерности числа признаков – требуется при высокой размерности РНС ( $n_{nrn} > 1000$ ), могут быть использованы методы проекции признаков (PCA, LDA, ISOMAP) [2.10; 2.60], а также методы выбора подмножества признаков, итоговая размерность не должна превышать 100, как правило 5-20 признаков; для визуализации можно взять 2-3 признаков в новом пространстве;

– выбор алгоритма решения целевой задачи распознавания – в случае классификации могут быть применены нейронные сети (НСПР, вероятностная нейронная сеть, LVQ-НС, СМАС), метод k ближайших соседей, машины опорных векторов и др.; в случае аппроксимации – нелинейные регрессоры, нейронные сети (НСПР, РБФ-НС); в случае кластеризации – метод k-средних (k-means), модели гауссовых смесей (GMM), иерархическая кластеризация и др [2.22; 2.48; 2.60].

По сути на данном этапе для решения поставленной задачи применяются известные методы машинного обучения. Для этого в случае задачи классификации или регрессии используется обучающая выборка, состоящая из пар "входное значение - желаемое выходное значение" (для классификации желаемые значения представлены метками классов, а для регрессии - числами в некотором непрерывном диапазоне).

РНС работает как преобразователь сигналов или как система выделения признаков из динамического сигнала. Фактически же обучение осуществляется на уровне считывателей. Но за счет того, что РНС разделяет входные последовательности в своем внутреннем состоянии задача обучения считывателей значительно упрощается. Обучать РНС долго, сложно и не всегда приводит к положительному результату [2.22], а в данном варианте подбирается РНС с определенными заданными свойствами (затухающая память, разделение входных последовательностей) и по сути ее можно и не обучать. Выше были упомянуты подходы автоподстройки РНС на основе синаптической пластичности. Также в некоторых исследованиях используются глобальные обратные связи со считывателей на РНС [2.43] и альтернативные варианты синаптической пластичности [2.55; 2.63].

Существует определенная сложность, связанная с использованием моделей импульсных нейронных сетей - в альтернативных моделях (ESN, Эволюно) [2.32] на основе обычных РНС предложено ряд моделей и алгоритмов обучения РНС [2.32; 2.39; 2.59]. Но преимуществом данного подхода является большая биологическая ориентированность и правдоподобность [2.14].

В дальнейшем планируется расширять класс типов входных данных, набор конфигураций РНС, считывателей, а также различных модификаций с тем, чтобы можно было охватить как можно более широкий диапазон решаемых



емых задач и для каждой из таких задач иметь набор для выбора предпочтительных конфигураций МНС.

#### ***2.4.4. Оценка качества распознавания***

После завершения всех предыдущих шагов можно приступить непосредственно к решению поставленной задачи распознавания динамических образов и оценивать качество распознавания. Для этого лучше всего подходит процедура кросс-валидации (cross-validation) или бутстрэп-оценивание [2.10; 2.60]. При кросс-валидации исходная выборка разбивается на несколько непересекающихся подвыборок и затем по очереди одна из подвыборок выбирается как тестовая, а все остальные - как обучающая. Для каждого такого разбиения вычисляется показатель качества, после чего результаты усредняются по всем разбиениям. В случае бутстрэп оценивания из исходной выборки формируются обучающие и тестовые подвыборки методов извлечения с повторением. Особенность данного подхода в том, что одни и те же обучающие примеры в полученных подвыборках могут содержаться по несколько раз. Затем по аналогии с кроссвалидацией для каждой подвыборки вычисляются показатели и затем все усредняется.

Выбор показателей качества зависит от решаемой задачи:

- для задачи классификации вычисляется матрица неточностей и по ней определяются ошибки первого, второго рода, усредненные, максимальные ошибки и другие показатели, учитывающие стоимость определенных ошибок [2.16];
- для задачи регрессии (аппроксимации), когда выходные данные являются не дискретными, а непрерывными (например, предсказание, идентификация параметров, создание модели объекта, управление) вычисляется средняя абсолютная или относительная ошибка. ;
- при решении задачи кластеризации качество кластеризации анализируется с помощью специальных показателей – индекса Дэвиса-Болдуина, индекса Дана и др. [2.10; 2.21]; важно понимать, что не существуют строгих критериев, по которым можно было бы оценивать качество кластеризации.

В случае, если полученное качество распознавания не удовлетворительное, то можно вернуться на один из предыдущих этапов и увеличить количество обучающих примеров, повысить их репрезентативность, изменить способ подачи, представления, предобработки входных данных, сгенерировать новый резервуар или изменить параметры считывателей. В итоге выполнения всех шагов и рекомендаций задача распознавания динамических образов будет решена с требуемым качеством.

В случае изменения резервуара он может быть сгенерирован еще раз с теми же параметрами или с другими параметрами в соответствии с набором рекомендуемых конфигураций РНС.

В случае изменения считывателей необходимо руководствоваться известными правилами классической теории машинного обучения. Например, при использовании для классификации обычных нейронных сетей следует подобрать такое число скрытых слоев и нейронов, чтобы с одной стороны не было переобучения (НС не входила в режим запоминания), а с другой стороны чтобы у НС хватало степеней свободы для разделения входных примеров на классы. Точно также при использовании методов непараметрического ядерного оценивания (kernel density estimation) необходимо подобрать ядра и их параметры так, чтобы они наиболее точно подходили под распределение имеющихся данных. Как правило, точного оптимального решения не существует - есть некоторые формулы, дающие начальное приближение и работающие при некоторых допущениях (нормальное распределение, линейно разделимые образы и др.). Этап точной подстройки всегда уникальней и сложно поддается автоматизации.

## **2.5. Пример применения методики синтеза импульсных РНС к решению задачи классификации ЭКГ**

Один из примеров сложной задачи распознавания динамических образов является анализ *электрокардиограмм* (ЭКГ) [2.19] и выявление различных патологий (аритмий). Эта задача была выбрана для апробации разработанной методики синтеза импульсных РНС в составе МНС. Помимо настройки РНС были выполнены и все остальные шаги, связанные с определением формата

представления входных данных, выбором и обучением считывателей и оценкой качества распознавания.

В качестве исходных данных использовался набор баз данных аритмий MIT-BIH [2.47], свободно распространяемый в рамках проекта PhysioNet [2.53]. Одна из задач, представленная в базе данных SVDB (Supraventricular Arrhythmia Database) - выявление суправентрикулярной аритмии. Эта база данных содержит 94 30-минутных записей ЭКГ (с двух датчиков) с аннотациями биений и их свойств (норма, аритмия).

Для решения тестовой задачи в рамках предлагаемой методики синтеза был предложен подход, состоящий из нескольких шагов.

### ***2.5.1. Выбор способа подачи данных на вход резервуара***

*Размерность.* Данные ЭКГ снимаются с двух каналов, поэтому исходная размерность входного сигнала также равна двум:  $n_{in} = 2$ .

*Обучающие и тестовые примеры.* Для задачи классификации, был подготовлен набор обучающих и тестовых примеров. Для этого из разных ЭКГ были взяты фрагменты – биения, соответствующие разным классам – нормальных биений и биений с аритмией. Было взято по 100 примеров каждого типа.

*Нормализация во временном диапазоне.* Средняя длительность одного биения – 1 секунда. Глубина памяти импульсной РНС меньше, поэтому вначале была произведена нормализация входного сигнала во временном диапазоне. В результате все примеры были нормализованы во временном диапазоне так, чтобы каждый из них длился  $t_{norm} = 0.3$  с.

*Преобразование в импульсную форму.* Для подачи примеров на вход импульсной РНС они были преобразованы из непрерывной формы в импульсную. В качестве алгоритма преобразования лучше всего подошел пространственно-временной алгоритм на основе рецептивных полей с параметрами  $k_x = 8, T_{min} = 1$  мс [2.11]. Пример такого преобразования был приведен ранее на рисунке 2.9.

### ***2.5.2. Синтез резервуара***

В результате предварительно анализа имеющихся данных из обучающей выборки и на основе их анализа, приведенного в [2.51], было принято реше-

ние о том, что решаемая задача выявления аритмии является сложной в смысле определения, данного в конце подраздела 2.4.1. Это связано и с плохой различимостью примеров, относящихся к различным классам, их сильной коррелированностью. Поэтому в соответствии с методикой было предложено использовать резервуар из нейронов Ижикевича:

- возбуждающие нейроны – типа RS;
- подавляющие нейроны – типа FS;
- количество нейронов в резервуаре  $n_{nrn} = 125$  (решетка  $5 \times 5 \times 5$ );
- $\lambda = 2$ ;
- $p_{inh} = 20\%$  нейронов подавляющие,  $p_{ex} = 80\%$  – возбуждающие;
- $C = \begin{bmatrix} 0.4 & 0.4 \\ 0.2 & 0.4 \end{bmatrix}$ ,  $W_{int} = \begin{bmatrix} 0.001 & 0.01 \\ 0.01 & 0.015 \end{bmatrix}$ ;
- каждый из  $n_{vh} = 16$  входов случайно связан с  $p_{vh} = 10\%$  нейронов;
- силы химических синапсов от входов к подавляющим и возбуждающим нейронам равны  $w_{vh(chem)}^i = w_{vh(chem)}^e = 0.01$ ;
- постоянная времени равна  $\tau_{syn} = 3$  мс для всех химических синапсов кроме синапсов от подавляющих нейронов – для них она равна  $\tau_{syn} = 6$  мс;
- задержка во всех химических синапсах одинакова и равна  $\tau_{delay} = 1$  мс.

### 2.5.3. Выбор считывающих модулей

Время считывания было выбрано равным моменту времени, соответствующему окончанию подачи двух третей образа, т.е.  $t_{readout} = 100$  мс. Алгоритм преобразования из импульсной формы в непрерывную выбран на основе преобразования каждого импульса в затухающую экспоненту с постоянной времени  $\tau_{window} = 10$  мс. Были рассмотрены два варианта сочетания алгоритма сокращения размерности и классификатора:

- алгоритм PCA,  $n_{comp} = 2(3)$  компоненты и байесовский классификатор;
- классификатор k-NN без сокращения размерности.

### 2.5.4. Исследование и оценка качества распознавания

В ходе проверки работы МНС образы подавались по очереди (нормальный и с аритмией) в 2 цикла. На рисунке 2.29 показана реакция на 4 первых

образа (нормальный, с аритмией, нормальный, с аритмией). Видно, что реакция РНС на 1-й и 3-й образы похожа, на 2-й и 4-й тоже похожа, а на 1-й и 2-й отличается.

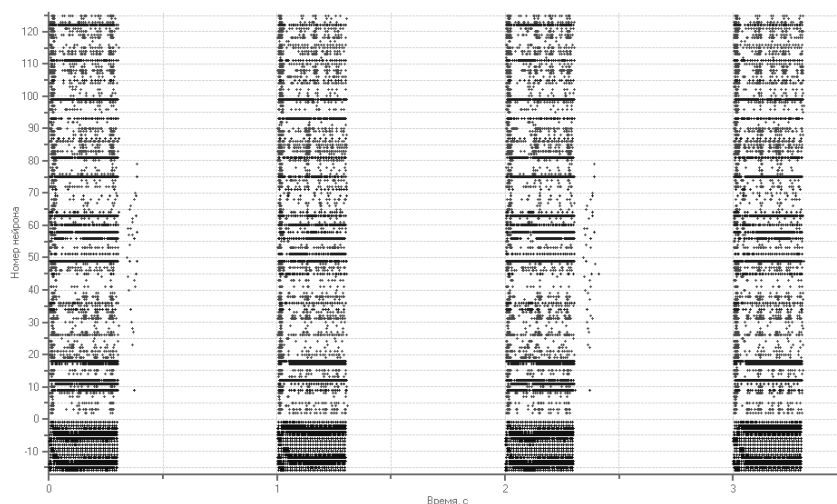


Рис. 2.29. Реакция РНС на 4 первых образа (нормальный, с аритмией, нормальный, с аритмией)

Вначале решалась простая задача с 12-ю вариантами ЭКГ.  $k$ -NN-классификатор, используя в качестве обучающих первые два образа, успешно распознал все следующие 10 образов. Также без ошибок справился с задачей и обычный байесовский линейный классификатор при использовании 2-х главных компонент (125 сигналов с нейрона использовать нельзя в силу очевидных причин невозможности получить удовлетворительную ковариационную матрицу). Оба эти классификатора являются статистическими: байесовский классификатор является параметрическим и использует гипотезу о нормальном распределении классов, а классификатор  $k$ -NN является непараметрическим и неявно на основе обучающих примеров строит вероятностные распределения классов.

После этого решалась задача со всеми 200 образами. В качестве классификатора использовался  $k$ -NN классификатор. 70 % образов ( $n_{train} = 140$ ) были случайно выбраны обучающими, а остальные 30 % ( $n_{test} = 60$ ) – тестовыми. Качество распознавания оценивалось с помощью вероятностей правильного распознавания для каждого из классов. Поскольку в решаемой за-

даче всего два класса, то это вероятности правильного распознавания нормального биения  $p_{r_2}^{norm}$  и аритмии  $p_{r_2}^{arythm}$ . Они элементарно вычисляются как отношение количества правильно распознанных примеров соответствующего класса  $N_{rec}^{class}$  и общего числа примеров  $N_{all}^{class}$  этого же класса. По своей сути они противоположны вероятностям ошибок второго рода (пропуска события)  $p_{e_2}^{class}$ :

$$p_{r_2}^{norm} = 1 - p_{e_2}^{norm} = \frac{N_{rec}^{norm}}{N_{all}^{norm}}, \quad p_{r_2}^{arythm} = 1 - p_{e_2}^{arythm} = \frac{N_{rec}^{arythm}}{N_{all}^{arythm}}. \quad (2.17)$$

В таблице 2.3 приведены результаты качества распознавания исследуемой системы с помощью МНС и при применения классических подходов [2.51]. В качестве классических подходов приведены результаты применения методов статистического и структурного распознавания, представленные в [2.51]. Как известно, статистические подходы к распознаванию явно или неявно пытаются сформировать вероятностные распределения классов в пространстве некоторых выбранных признаков, причем признаки рассматриваются как набор значений, никак не связанных друг с другом. В отличие от статистических структурные (синтаксические) подходы пытаются сформировать более сложные описания образов в виде графов, кодов, схем и затем использовать эти описания при принятии решений. В [2.51] для статистического распознавания вначале осуществлялось выделение признаков, в качестве признаков использовался как сам сигнал, так и его преобразование Фурье или вейвлет-преобразования. Далее проводилась последующая классификация с помощью алгоритма CART на основе деревьев принятия решений. При структурном распознавании проводилось специальное преобразование сигнала ЭКГ в последовательность символов. В качестве символов использовались различные типы изменения сигнала на коротком участке (треугольный, в форме прямой, трапецеидальный). Затем результирующая последовательность символов преобразовывалась в цепной код (chain code) и выполнялась ее классификация.

Вероятности правильного распознавания приведены в форме  $MO \pm СКО$ .

Из таблицы следует, что лучше всего с поставленной задачей справилась система распознавания на основе МНС с резервуаром в форме импульсной РНС из нейронов Ижикевича. Качество распознавания нормальных биений

Таблица 2.3

## Сравнительный анализ качества распознавания ЭКГ

Алгоритм распознавания	$p_{r_2}^{norm}, \%$	$p_{r_2}^{arhythm}, \%$
Структурный	$85.9 \pm 3.6$	$74.5 \pm 6.5$
Статистический, признаки – сам сигнал	$78.2 \pm 0.0$	$76.1 \pm 0.0$
Статистические, признаки – быстрое преобразование Фурье	$84.4 \pm 2.4$	$74.5 \pm 5.0$
Статистический, признаки – вейвлеты	$87.1 \pm 2.6$	$72.3 \pm 3.3$
Статистический, с помощью резервуара - импульсной РНС из IaF нейронов	$85.4 \pm 2.2$	$75.8 \pm 1.2$
Статистический, с помощью резервуара – импульсной РНС из нейронов Ижикевича	$88.0 \pm 1.1$	$81.4 \pm 1.7$

выше классических методов на 1 %, а биений с аритмией – на 5 %. Это в свою очередь подтверждает правильность построенной в работе методики синтеза импульсной РНС в составе МНС.

На основании решенных в работе задач можно определить рекомендации и перспективы дальнейших исследований:

- использование разработанной методики для решения новых актуальных задач в нейро-управлении, идентификации и диагностике;
- исследование динамики МНС при использовании новых моделей нейронов, синапсов;
- исследование динамики МНС для новых способов формирования ее структуры, в том числе с адаптацией (самообучением) РНС в ходе ее функционирования;
- исследование возможностей МНС при введении обратной связи со считывателей;
- усовершенствование и разработка новых критериев выбора параметров РНС по ее динамике.

## Выводы

В связи с необходимостью выполнения большого количества экспериментов с моделью МНС потребовалась среда моделирования импульсных РНС. Анализ существующих сред моделирования выявил множество их недостатков, которые затрудняют или не позволяют полноценно выполнять исследование модели импульсной РНС. Поэтому было принято решение о разработке среды моделирования импульсных РНС.

На основании требований была построена функциональная декомпозиция проектируемой среды моделирования и с ее помощью получена модель взаимодействия между системами и подсистемами среды, которая легла в основу интерфейса и программного кода. Для обеспечения универсальности среды моделирования РНС из произвольных нейронов, синапсов с учетом временных задержек, шума, возможности обучения был разработан специальный алгоритм моделирования импульсных РНС. Для обеспечения универсальности среды в смысле подачи на вход произвольных входных данных, была разработана унифицированная структура данных. Анализ возможностей разработанной среды моделирования подтвердил ее соответствие выдвинутым требованиям и еще раз подтвердил правильность решения о создании собственной среды моделирования.

Затем было выполнено исследование подсистем, составляющих модель — нейронов, синапсов, обучающей системы, определены диапазоны рабочих значений параметров. Для нейронов IaF было получено несколько аналитических характеристик. Была произведена настройка параметров алгоритмов преобразования информации из непрерывной формы в импульсную. Также было исследовано влияние параметров на генерируемую случайную структур РНС, рассмотрен вопрос визуализации матриц связности пространственных структур.

Все результаты исследования легли в основу разработанной методики синтеза импульсных РНС в составе МНС. Она отличается от известных подходов системностью, универсальностью, большей детализацией, что позволяет проводить целенаправленный синтез резервуара с требуемыми показателями, снизить трудоемкость разработки систем распознавания динамических



образов и использовать новую модель МНС в системах резервуарных вычислений для задач распознавания динамических образов.

Для проверки правильности методики была применена при решении практических задач распознавания динамических образов. В качестве образов использовались записи ЭКГ с биениями сердца. Рассматривались биения с суправентрикулярной аритмией и нормальные биения. В соответствии с методикой вначале были сформированы обучающие примеры в непрерывной форме. Далее была произведена нормализация входных сигналов во временной области так, чтобы память импульсной РНС была не меньше времени представления образа. Был синтезирован резервуар из нейронов Ижикевича и выбраны считывающие модули –нелинейный классификатор k-NN. В результате проведенного экспериментального исследования были получены показатели качества распознавания и сравнены с имеющимися данными по качеству распознавания с помощью классических методов распознавания – статистического и структурного. Было проведено сравнение, которое показало, что система распознавания на основе МНС с резервуаром Ижикевича по качеству распознавания превосходит все рассмотренные нами классические методы – на 1-2 % при распознавания нормальных биений, на 5 % при распознавании биений с аритмией.

Полученные результаты подтверждают правильность построенной в работе методики синтеза импульсной РНС в составе МНС.

### **Библиографический список**

- 2.1. A Digital Liquid State Machine With Biologically Inspired Learning and Its Application to Speech Recognition / Y. Zhang [et al.] // IEEE Trans Neural Netw Learn Syst. — 2015. — Vol. 26, no. 11. — P. 2635–2649.
- 2.2. A Unified Framework for Reservoir Computing and Extreme Learning Machines based on a Single Time-delayed Neuron / S. Ortín [et al.] // Scientific Reports. — 2015. — Vol. 5.

- 2.3. *Aoun M. A., Boukadoum M.* Chaotic Liquid State Machine // International Journal of Cognitive Informatics and Natural Intelligence. — 2015. — Vol. 9, no. 4. — P. 1–20.
- 2.4. *Arbib M., Erdi P., Szentagothai J.* Neural organization: structure, function, and dynamics. — A Bradford Book, 1997. — 407 p.
- 2.5. *Auer P.* The p-Delta Rule for Parallel Perceptrons // Neural Computation. — 2002. — Vol. 11. — P. 1213–1232.
- 2.6. *Benderskaya E., Nikitin K.* Analysis of a spiking recurrent neural network as a part of the liquid state machine // Neurocomputers. — Moscow, 2014. — Vol. 1. — P. 17–22. — (In Russian).
- 2.7. *Benderskaya E., Nikitin K.* Specificities of computer simulation of spiking recurrent neural networks // Neurocomputers. — Moscow, 2014. — Vol. 2. — P. 54–65. — (In Russian).
- 2.8. *Benderskaya E., Nikitin K.* Using Spiking Recurrent Neural Networks for ECG Analysis // Information and Control Systems. — Saint-Petersburg, 2015. — Vol. 1. — P. 85–91. — (In Russian).
- 2.9. *Bertschinger N., Natschläger T.* Real-Time Computation at the Edge of Chaos in Recurrent Neural Networks // Neural Computation. — 2004. — Vol. 16, no. 7. — P. 1413–1436.
- 2.10. *Bishop C. M.* Pattern Recognition and Machine Learning. — Springer, 2011. — 738 p.
- 2.11. *Bohte S. M., La Poutré J. A., Kok J. N.* Unsupervised clustering with spiking neurons by sparse temporal coding and multi-layer RBF networks // IEEE Transactions on Neural Networks. — 2002. — Vol. 13, no. 2. — P. 426–435.
- 2.12. *Bozhkov L., Koprinkova-Hristova P., Georgieva P.* Reservoir computing for emotion valence discrimination from EEG signals // Neurocomputing. — 2017. — Vol. 231, no. C. — P. 28–40.
- 2.13. *Brunel N., Van Rossum M. C.* Lapicque’s 1907 paper: from frogs to integrate-and-fire // Biological Cybernetics. — 2007. — Vol. 97. — P. 337–339.

- 2.14. *Buonomano D. V., W. M.* State-dependent computations Spatiotemporal processing in cortical networks // *Neuroscience*. — 2009. — Vol. 10, no. 2. — P. 113–125.
- 2.15. *Dayan P., Abbott L. F.* Theoretical neuroscience: computational and mathematical modeling of neural systems. — Cambridge: MIT Press, 2005. — 460 p.
- 2.16. *Duda R. O., Hart P. E., Stork D. G.* Pattern Classification. — 2nd ed. — Wiley, 2000. — 680 p.
- 2.17. *Gallicchi C., Micheli A., Pedrelli L.* Deep reservoir computing: A critical experimental analysis // *Neurocomputing*. — 2017. — Vol. 268, no. 13. — P. 87–99.
- 2.18. *Gerstner W., Kistler W. M.* Spiking Neuron Models. Single Neurons, Populations, Plasticity. — Cambridge: Cambridge University Press, 2002. — 480 p.
- 2.19. *Goldman M. J.* Principles of Clinical Electrocardiography. — 12th ed. — Los Altos: Lange Medical Publications, 1986. — 450 p.
- 2.20. *Goodfellow I., Bengio Y., A. C.* Deep Learning. — 2nd ed. — The MIT Press, 2016. — 775 p.
- 2.21. *Hastie T., Tibshirani R., Friedman J.* The Elements of Statistical Learning: Data Mining, Inference, and Prediction. — 2nd ed. — Springer, 2016. — 745 p.
- 2.22. *Haykin S.* Neural Networks and Learning Machines. — 3rd ed. — Pearson, 2011. — 936 p.
- 2.23. High-Density Liquid-State Machine Circuitry for Time-Series Forecasting / J. L. Rosselló [et al.] // *Int J Neural Syst*. — 2016. — Vol. 26, no. 5.
- 2.24. *Hines M., Carnevale N.* Discrete event simulation in the NEURON environment // *Neurocomputing*. — 2004. — Vol. 58. — P. 1117–1122.
- 2.25. *Hodgkin A. L., Huxley A. F.* A quantitative description of membrane current and its application to conduction and excitation in nerve // *The Journal of physiology*. — 1952. — Vol. 117, no. 4. — P. 500–544.

- 2.26. *Hopfield J. J., D. B. C.* What is a moment Transient synchrony as a collective mechanism for spatiotemporal integration // PNAS. — 2001. — Vol. 98, no. 3. — P. 1282–1287.
- 2.27. *Huang J., Wang Y., Huang J.* The Separation Property Enhancement of Liquid State Machine by Particle Swarm Optimization // ISSN 2009: Advances in Neural Networks – ISSN 2009. / ed. by W. Yu, H. He, N. Zhang. — Springer, 2009. — P. 67–76. — (Ser.: LNCS; 5553).
- 2.28. Isolated word recognition using liquid state machine: a case study / D. Verstraeten [et al.] // Information Processing Letters. — 2005. — Vol. 95. — P. 521–528.
- 2.29. *Izhikevich E. M.* Dynamical systems in neuroscience: the geometry of excitability and bursting. — Cambridge: The MIT Press, 2007. — 505 p.
- 2.30. *Izhikevich E. M.* Which model to use for cortical spiking neurons? // IEEE Transactions on Neural Networks. — 2004. — Vol. 15, no. 5. — P. 1063–1070.
- 2.31. *Izhikevich E.* Polychronization Computation with Spikes // Neural Computation. — 2006. — Vol. 18. — P. 245–282.
- 2.32. *Jaeger H.* The «echo state» approach to analyzing and training recurrent neural networks: tech. rep. / German National Research Center for Information Technology. — St. Augustin, 2001. — 43 p. — No. 148.
- 2.33. *Jaeger H.* Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the "echo state network" approach: tech. rep. / German National Research Center for Information Technology. — St. Augustin, 2002. — 48 p. — No. 159.
- 2.34. *Jin Y., Li P.* Performance and robustness of bio-inspired digital liquid state machines // Neurocomputing. — 2017. — Vol. 226, no. C. — P. 145–160.
- 2.35. *Kasabov N., Capecchi E.* Spiking neural network methodology for modelling, classification and understanding of EEG spatio-temporal data measuring cognitive processes // Information Sciences: an International Journal. — 2015. — Vol. 294, no. C. — P. 565–575.

- 2.36. *Kuhn M.* Applied Predictive Modeling. — 2nd ed. — Springer, 2016. — 600 p.
- 2.37. *Legenstein R., Maass W.* What makes a dynamical system computationally powerful? // New directions in statistical signal processing: from systems to brains / ed. by S. Haykin [et al.]. — Cambridge: The MIT Press, 2007. — P. 127–154.
- 2.38. Liquid state machines and cultured cortical networks: the separation property / K. P. Dockendorf [et al.] // Biosystems. — 2009. — Vol. 95. — P. 90–97.
- 2.39. *Løkse S., Bianchi F., Jessen R.* Training echo state networks with regularization through dimensionality reduction // Cogn. Comput. — 2017. — Vol. 9. — P. 364–378.
- 2.40. Long short-term memory and learning-to-learn in networks of spiking neurons / G. Bellec [et al.] // NIPS 2018. — Montreal, Canada, 2018.
- 2.41. *Lucosevius M., H. J.* Overview of Reservoir Recipes: tech. rep. / School of Engineering; Science, Jacobs University. — Bremen, 2007. — 26 p.
- 2.42. *Maass W.* Computation with spiking neurons // The Handbook of Brain Theory and Neural Networks / ed. by M. A. Arbib. — 2nd ed. — Cambridge: The MIT Press, 2003. — P. 1080–1083.
- 2.43. *Maass W., Joshi P., Sontag E. D.* Principles of real-time computing with feedback applied to cortical microcircuit models // Advances in Neural Information Processing Systems. — 2006. — Vol. 18. — P. 835–842.
- 2.44. *Maass W., Natschläger T.* Emulation of Hopfield networks with spiking neurons in temporal coding // Proc. of the 6-th annual conf. on Computational Neuroscience: trends in Research. — 1998. — P. 221–226.
- 2.45. *Maass W., Natschläger T., H. M.* Real-time computing without stable states: a new framework for neural computations based on perturbations // Neural Computation. — 2002. — Vol. 11. — P. 2531–2560.
- 2.46. *Markram H., Wang Y., Tsodyks M.* Differential signaling via the same axon of neocortical pyramidal neurons // PNAS. — 1998. — Vol. 95. — P. 5323–5328.

- 2.47. *Moody G. B., Mark R. G.* The MITBIH Arrhythmia Database on CDROM and Software for Use with it // *Computers in Cardiology*. — 1990. — Vol. 17. — P. 185–188.
- 2.48. *Murphy K. P.* *Machine Learning: A Probabilistic Perspective*. — The MIT Press, 2011. — 1104 p.
- 2.49. *Nikitin K. V.* Application of spiking recurrent neural networks for dynamic pattern recognition problem: diss. ... / Nikitin K. V. — Saint-Petersburg: St. Petersburg State Polytechnical University, 2013. — (In Russian).
- 2.50. *Nikitin K., Benderskaya E.* New approach to applying recurrent neural networks to pattern recognition problem solution // *St. Petersburg State Polytechnical University Journal. Computer Science. Telecommunication and Control Systems*. — Saint-Petersburg, 2014. — Vol. 4, no. 2. — P. 85–92. — (In Russian).
- 2.51. *Olszewski R. T.* Generalized Feature Extraction for Structural Pattern Recognition in Time-Series Data: diss. ... / Olszewski R. T. — Pittsburgh, 2001. — 125 p.
- 2.52. *Pantic L., Torres J. J., Kappen H.* Associative memory with dynamical synapses // *Neural Computation*. — 2002. — Vol. 14. — P. 2903–2923.
- 2.53. PhysioNet: The Research Resource for Complex Physiological Signals. — URL: <http://www.physionet.org> (visited on 09.01.2018).
- 2.54. *Polepalli A., Soures N., Kudithipudi D.* Reconfigurable Digital Design of a Liquid State Machine for Spatio-Temporal Data // *Proceedings of the 3rd ACM International Conference on Nanoscale Computing and Communication*. — New York, NY, USA, 2016.
- 2.55. *Roy S., Basu A.* An online structural plasticity rule for generating better reservoirs // *Neural Computation*. — 2016. — Vol. 28, no. 11. — P. 2557–2584.
- 2.56. *Schrauwen B., Verstraeten D., Campenhout J. V.* An overview of reservoir computing theory, applications and implementations // *Proc. of the 15th European Symposium on ANN*. — 2007. — P. 471–482.

- 2.57. Simulation of networks of spiking neurons: a review of tools and strategies / R. Brette [et al.] // Journal of computational neuroscience. — 2007. — Vol. 23, no. 3. — P. 349–398.
- 2.58. *Smith E., Lewicki M. S.* Efficient coding of time-relative structure using spikes // Neural Computation. — 2004. — Vol. 17. — P. 19–45.
- 2.59. *Steil J.* Backpropagation-decorrelation: recurrent learning with  $O(N)$  complexity // 2004 IEEE International Joint Conference on Neural Networks. Vol. 1. — Budapest, Hungary: IEEE, 2004. — P. 843–848.
- 2.60. *Theodoridis S., Koutroumbas K.* Pattern recognition. — 4th ed. — San Diego: Academic Press, 2009. — 961 p.
- 2.61. *Trappenberg T. P.* Fundamentals of computational neuroscience. — New York: Oxford University Press, 2002. — 338 p.
- 2.62. *Wojcik G. M., M. W.* Bray-Curtis Metrics as Measure of Liquid State Machine Separation Ability in Function of Connections Density // Procedia Computer Science. — 2015. — Vol. 51, no. C. — P. 2979–2983.
- 2.63. *Yousefi A., Dibazar A., Berger T.* Synaptic dynamics: linear model and adaptation algorithm // Neural Netw. — 2014. — Vol. 56. — P. 49–68.