

Нейроинформатика, её приложения и анализ данных

XXIX Всероссийский семинар

**Красноярск
2021**

Министерство науки и высшего образования РФ
Сибирское отделение РАН
Российская ассоциация нейроинформатики
Институт вычислительного моделирования СО РАН

НЕЙРОИНФОРМАТИКА, ЕЁ ПРИЛОЖЕНИЯ И АНАЛИЗ ДАННЫХ

МАТЕРИАЛЫ
ДВАДЦАТЬ ДЕВЯТОГО ВСЕРОССИЙСКОГО СЕМИНАРА
24 сентября – 26 сентября 2021 года

Красноярск 2021

УДК 007.52 (042.3)

Н 43

Нейроинформатика, её приложения и анализ данных: Материалы XXIX Всероссийского семинара, 24 сентября – 26 сентября 2021 года / Под ред. М.Г. Садовского, отв. за вып. М.Ю. Сенашова; – Красноярск: Институт вычислительного моделирования СО РАН, 2021. – 131 с.

В сборнике представлены материалы XXIX Всероссийского семинара «Нейроинформатика, её приложения и анализ данных», проходившей в городе Красноярске 24 сентября – 26 сентября 2021 года.

Основной задачей конференции является всесторонний и высококвалифицированный обмен новейшими достижениями в различных областях нейроинформатики (как теории нейросетей, так и в области различных практических приложений), а также в области нелинейного статистического анализа многомерных данных, обладающих нетривиальными структурами.

Большое внимание уделено анализу областей применимости и точности методов обработки многомерных данных, анализу устойчивости различных новых (нелинейных) методов кластеризации, разбор большого числа конкретных случаев, иллюстрирующих эти проблемы и достижения.

Материалы предназначены для научных работников, преподавателей, студентов и аспирантов соответствующих специальностей.

Конференция проводится при поддержке Красноярского математического центра, финансируемого Минобрнауки РФ в рамках мероприятий по созданию и развитию региональных НОМЦ (Соглашение 075-02-2021-1384).

Редакционная коллегия:

Садовский Михаил Георгиевич – ответственный редактор

Сенашова Мария Юрьевна – ответственный за выпуск

© ИВМ СО РАН, 2021

© Коллектив авторов, 2021

ISBN 978-5-6043558-2-4



9 785604 355824

ПРИМЕНЕНИЕ МОДЕЛЕЙ YOLOV4 В ЗАДАЧАХ КИНЕМАТИКИ ЧЕЛОВЕКА В ОБЛАСТИ СПОРТИВНОЙ МЕДИЦИНЫ

Алехина А.Е.¹, Доррер М.Г.¹, Садовский М.Г.^{2,3}, Феллер А.А.³

¹Сибирский государственный университет имени М.Ф. Решетнева, Красноярск
mdorrer@mail.ru

²Институт вычислительного моделирования СО РАН, Красноярск

³Федеральный Научно-Клинический Центр ФМБА России, Красноярск
msad@icm.krasn.ru, felleraa96@mail.ru

1. Введение

Изучение кинематики тела человека является актуальной задачей во множестве направлений медицины. Авторы выделяют два из них:

- Диагностика неврологических заболеваний (болезни Паркинсона и Альцгеймера) на основании походки пациента
- Анализ адаптации тела человека к различным видам спорта в рамках спортивной медицины.

В качестве инструмента изучения кинематики тела человека выбран механизм компьютерного зрения.

Данная статья посвящена решению задачи подготовки данных для анализа кинематики тела человека на основе видеозаписей пациентов при помощи глубоких сверточных сетей. Была выполнена подготовка дополнительных обучающих материалов для нейронных сетей, позволяющих решить ряд промежуточных задач в интересах конечного результата – диагностики изменений кинематики тела человека под влиянием заболеваний или занятий различными видами спорта.

Описаны следующие результаты, полученные на настоящий момент:

1. Исследуемые видеофайлы движения человека (вид сбоку) нормализованы путем приведения к временному интервалу от нулевой точки цикла (начало шага) до конечной точки (конец шага) с помощью применения окна интереса.
2. Класс person взят из модели YOLOv4, обученной на датасете VsCOCO 2020. Дополнительно используется метод Deepsort. Высоко классифицированный движущийся объект класса person вырезается по координатам определенных границ.
3. Полученные выборки класса person группируются в три группы: общий здоровый обычный, общий здоровый спорт, общий больной. Изображения подготовлены для решения в последующих работах задачи обучения моделей генеративно-состязательных сетей (GAN).
4. Подготовлена учебная выборка групп мышц человека, модель классификации YOLOv4 обучена распознаванию групп мышц на теле человека в реальном времени в видеопотоке.

2. Связанные работы

Задачи исследования кинематики тела человека при помощи различных аппаратных и программных методов привлекают большое внимание ученых. Работа [1] посвящена рассмотрению истории и методологии изучения биомеханики движений человека, а также теоретическим и экспериментальным методам, разработанным для изучения движений человека. В работе [2] Wada et al. описали базовую процедуру

анализа движения человека с помощью комбинации видеозаписи и данных акселерометров. В работе [3] Olagu предложил подход к построению 3D-модели человеческого скелета, который можно использовать для оценки асимметрии путем определения человеческого силуэта в 3D, положения ключевых точек и суставов человеческого тела.

Работа [4] посвящена распознаванию человеческой активности у пожилых людей на основе сверточной нейронной сети. В работе [5] Dorschky et al. предложили метод оценки биомеханики ходьбы и бега в сагиттальной плоскости на с использованием сверточных нейронных сетей на основе измеренных и смоделированных данных инерционных датчиков.

Для задач анализа движения активно используются архитектуры сверточных нейронных сетей. В статье [6] предлагается метод с помощью архитектуры YOLO. Сочетание архитектуры YOLO с применением метода RCNN для детекции движущихся объектов описано в работе [7].

Авторы настоящей работы также сталкивались в своей работе с применением как методов R-CNN, так и с архитектурой YOLO различных версий, в том числе и в медицинских приложениях. Так, в работе [8] метод Mask-CNN использовался для детекции клеток на микрофотографиях. В работе [9] рассматривалась задача, подобная рассмотренной в статье [7] – отслеживание шайбы в игре. Работа [10] посвящена сравнительному анализу эффективности аппаратных платформ для задач видеодетекции при помощи решений на базе архитектуры YOLO.

Таким образом, данная задача востребована, и ее дальнейшая разработка представляет интерес как с точки зрения различных отраслей медицины, так и с точки зрения методов искусственного интеллекта.

3. Материалы и методы

3.1. Область исследования

Видеоизображения исследуемых походок людей были получены из центра Восстановительной медицины СНКЦ ФМБА, город Красноярск. Время сбора данных с исследования проходили с апреля 2021 года. Исследования движения человека проходят несколько видов пациентов, такие как: здоровые офисные люди, которые не имеют явных нарушений в здоровье, среднестатистические здоровые спортсмены, занимающиеся определенным видом спорта, а также больные пациенты, которые имеют явные внешние повреждения в кинематике. Во время сеанса пациент надевает на себя фотоэлементы и совершает несколько проходов вдоль всей комнаты, наступая на подвижные платформы, с которых снимают числовые данные с различных датчиков. Также в комнате вдоль стены находятся две камеры, установленные на штативы на высоте примерно 50 см. Освещение может быть естественным или искусственным теплый желтый свет и возможна комбинация этих двух типов освещений. В помещении также могут присутствовать посторонние люди, например лечащий врач, тренер, сопровождающий. Во время проведения сеанса съемки пациента посторонние люди не перемещаются по комнате (Рисунок 1-2). Разрешение одного кадра составляет 644×484 пикселей, средний fps 25 кадров в секунду




Рис. 1. Схема расположения камер в комнате.



Рис. 2. Примеры получаемых изображений с камер (боковая камера, фронтальная камера, естественное освещение, искусственное освещение, комбинированное освещение).

3.2. Учебные выборки

Группировка типов походок людей

Вручную, с помощью экспертов, выборка видеоматериалов была разбита на три группы походок (Таблица 1)

Таблица 1.

Описание свойств данных в классификации

Название класса	Описание класса	Тип аномалий	Требование к подгруппам
Общая здоровая обычная	В данный класс входят фрагменты людей офисного типа, кто не страдает серьезным отклонением в походке, а также не занимается профессиональным видом спортом и/или не имеет явных деформации в шаге.	Нормальное состояние	Нет
Общая здоровая	В данный класс входят фрагменты людей, которые занимаются	Нормальное состояние	Да (Вид спорта N)

спортивная	профессиональным видом спорта, имеют присущие аномалии шага, но не имеют травмы, меняющие специфику походки		
Общая больная	В данный класс входят фрагменты пациентов, после заболевания и/или получившие травмы, меняющие специфику походки	Аномалия	Да (Вид болезни N)

На рисунке показаны примеры фрагментов движущихся пациентов, распределенные в определенное множество (Рисунок 3)




Рис. 3. Пример группировки походок людей и смоделированные модели скелета человека.

Вырезанные фрагменты стандартизированы под обучение моделей генеративно-состязательных нейросетей (GAN) размером 64x64 пикселей.

Группы мышц

Для решения задачи классификации группы мышц было принято решение разбить человеческое тело на несколько групп главных мышц по примеру иллюстрации анатомического атласа (Рисунок 4)




Рис. 4 Пример анатомического описания крупных групп мышц

В качестве материала для обучающей выборки использовались открытые материалы натуралистов, специализированных для художественных учебных заведений. (Рис. 5)




Рис. 5. Пример разметки групп мышц человека

По результатам ручной разметки по примеру выше приведенного изображения анатомического атласа мы получили следующую выборку (Таблица 2)

Таблица 2.

Распределение количества образцов в учебной выборке

Наименование класса	Группа выделенных мышц	Количество образцов (тренировочная выборка)	Количество образцов (тестовая выборка)
Neck	Область шеи	768	153
Deltas	Зона дельт	1314	262
Shoulder	Плечевые мышцы (бицепс, трицепс)	1446	289
Forearms	Мышцы предплечья	1423	284
Breast	Грудные мышцы	621	124
Press	Мышцы пресса (косой, поперечный)	550	110
Hips	Бедра (трицепс, бицепс бедра)	1742	348
Buttocks	Ягодичные мышцы	665	133

The calf muscle	Икроножные мышцы	1725	345
Back	Спина	505	101
Итого:		10759	2149

Из таблицы 2 видно, что по первоначально созданному датасету классификации групп мышц выборка неоднородна, двойные элементы (руки, ноги) по умолчанию будут превышать одиночные элементы тела (шея, торс). Для того, чтобы сбалансировать учебную выборку, необходимо в следующей итерации добавить неуверенно определяющиеся моделью области тела и добавить объем экземпляров для соответствующих классов.

3.3 Архитектура сверточных нейронных сетей YOLOv4




Рис. 6 – Архитектура YOLOv4.

Модель YOLO [11] определяет пять параметров для задачи object detection (1):

$$\begin{aligned}
 b_x &= \delta(t_x) + c_x \\
 b_y &= \delta(t_y) + c_y \\
 b_w &= p_w e^{t_w} \\
 b_h &= p_h e^{t_h} \\
 Pr(object) * IOU(b, object) &= \sigma(t_o)
 \end{aligned} \tag{1}$$

где t_x, t_y, t_w, t_h – результат предсказания модели YOLO,
 c_x, c_y – координата верхней левой точки нужной области,
 p_w, p_h – ширина и высота определенной точки,
 b_x, b_y, b_w, b_h – параметры для предсказанного bounding box,
 $\sigma(t_o)$ – искомый confidence score.

Задача YOLO — максимально точно предсказать эти параметры, что должно обеспечить наилучшую детекцию объект на изображении. Confidence score, который определяется для каждого предсказанного bounding box, является фильтром, отсеивающим заведомо неточные предсказания. Для каждого предсказанного bounding box его значение IoU умножается на вероятность того, что это определенный объект

(вероятностное распределение рассчитывается во время обучения нейронной сети), затем производится выбор лучшей вероятности из всех возможных, и если число после умножения превышает определенный порог, то модель принимает решение оставить этот предсказанный bounding box на картинке.

YOLOv4 осуществляет предсказание на изображениях 3-х разных разрешений. Изображение делится на 64 клеток (grid cells), на 256 клеток и на 1024 клетки, чтобы также видеть маленькие объекты. Для каждой группы клеток алгоритм повторяет вышеописанные необходимые действия во время предсказания/обучения. В YOLOv4 по сравнению с версией YOLOv3 используется большое количество методов увеличения точности модели без существенной потери скорости. Однако, для самого предсказания слой Dense Prediction сохранен таким же, как и у YOLOv3.

3.4 Метод object tracking Deepsort

Deepsort является совокупностью результатов работы следующих алгоритмов: фильтр Калмана (2) и расстояние Махалонобиса (3) для переноса информации от одного кадра к другому, и добавляет новую метрику, под названием arrearance.

Фильтр Калмана состоит из трех этапов:

1. Усиление Калмана

$$KG = \frac{E_{EST}}{E_{EST} + E_{MEA}} \quad (2)$$

2. Оценка значения нужной выделенной области на этом этапе, с учетом рассчитанного усиления Калмана

$$EST_t = EST_{t-1} + KG(MEA - EST_{t-1}) \quad (3)$$

3. Оценка новой неопределенности

$$E_{EST_t} = \frac{E_{MEA} * E_{EST_{t-1}}}{E_{MEA} + E_{EST_{t-1}}} = (1 - KG) * E_{EST_{t-1}} \quad (4)$$

$$D_M(x) = \sqrt{(x - \mu)^T S^{-1} (x - \mu)}$$

где, $(x - \mu)$ - разница векторов между новой точкой и средними значениями для каждой переменной, а S – это ковариационная матрица (4)

Поскольку в датасете количество переменных больше двух, вместо корреляции в задаче отслеживания объекта используется ковариационная матрица, показанная в таблице 3.

DeepSORT позволяет улучшить точность определения и уменьшить количество переключений между объектами, когда, допустим, один человек на кадре загоразивает ненадолго другого, и теперь человек, которого загорозили, считается новым объектом.

Таблица 3.
Ковариационная матрица модели Deepsort

	x1	x2	x3
x1	cov(x1,x1)	cov(x1,x2)	cov(x1,x3)
x2	cov(x2,x1)	cov(x2,x2)	cov(x2,x3)
x3	cov(x3,x1)	cov(x3,x2)	cov(x3,x3)

3.4 Область интересов ROI

ROI [12], [13] представляет собой образцы в наборе данных, определенные для определенной цели. Концепция ROI обычно используется во многих прикладных областях. В географических информационных системах (ГИС) ROI можно воспринимать буквально как полигональную выборку на 2D-карте. В компьютерном зрении и оптическом распознавании символов ROI определяет границы рассматриваемого объекта. Во многих приложениях для компактного описания ее содержимого к ROI добавляются символьные (текстовые) метки. В пределах области интереса могут находиться отдельные точки интереса (POI).

В задачах ROI используются следующие принципы разметки данных:

1. 1D набор данных: временной или частотный интервал на графике функции.
2. 2D набор данных: границы объекта на изображении.
3. Набор 3D-данных: контуры или поверхности, очерчивающие объект (иногда известный как интересующий объем (VOI)) в объеме.
4. Набор данных 4D: контур объекта в определенный промежуток времени или в течение определенного интервала времени в пространственном объеме.

3.5 Аппаратная платформа и результаты численного эксперимента

Модель была обучена и протестирована в операционной системе Ubuntu 16.04.6 LTS с графическим процессором (GPU) NVIDIA GeForce GTX 1060 и платформой параллельных вычислений CUDA 10.1. Входные изображения были уменьшены до 416x416 пикселей, чтобы соответствовать входному слою обучающей модели. Мы использовали глобальную скорость обучения 0,001, и десять классов имеют 30000 итераций для максимальных пакетов. Во время тренировки использовались стандартизированные методы увеличения, где распад 0,0005, насыщенность 1,5, экспозиция 1,5, в качестве аугментации использовался метод мозаики [14].

Функция ошибки для каждой из моделей YOLO рассчитывалась следующим образом (5):

$$\begin{aligned}
 & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(x_i - x_j)^2 + (y_i - y_j)^2 \right] + \\
 & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(\sqrt{w_i} - \sqrt{w_j})^2 + (\sqrt{h_i} - \sqrt{h_j})^2 \right] + \\
 & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(C_i - C_j)^2 \right] + \\
 & \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{noobj} \left[(C_i - C_j)^2 \right]
 \end{aligned} \tag{5}$$

где 1_{ij}^{obj} — выходная карта характеристик всех ячеек сетки, B — количество ограничивающих рамок для каждой сетки, i — i -я сетка, j — j -й предсказанный прямоугольник этой сетки, x_i и y_i — расположение центроида якорного бокса, w_i и h_i — ширина и высота якоря бокса, C_i — объектность со средним значением, мера вероятности того, что объект существует в предлагаемой области интереса, является вероятностью реального класса бокса. вероятность предсказания класса бокса, обозначает, появляется

ли объект в ячейке i , определяет, отвечает ли j -й бокс в i -й сетке за это предсказание, и являются ли весовыми коэффициентами.

Время обучения для каждой модели YOLO v3 заняло 45 часов и была остановлена на значение mAP 82.7 % и средним loss 1.70.




Рис. 7 – График Loss (синий график), График mAP (красный график) обучения модели YOLOv4 на классификации групп мышц

3.6 Метрика точности модели классификации группы мышц

Для измерения точности обнаружения объектов используется показатель качества ранжирования MAP (средняя точность). Это интегральный параметр: средняя AP (средняя точность) [15] для каждого класса из обучающей выборки. (5)

$$AP = \frac{1}{11} \sum_{r \in (0,01 \dots 1)} P(r) \quad (6)$$

Основными показателями оценки являются точность и чувствительность, которые основаны на матрице смежности (таблица 1).

Таблица 4

Матрица смежности как пример разбора mAP

	Class A predicted: Yes	Class A predicted: No
Class A: Yes	True positive	False positive
Class A: No	False negative	True negative

- TP - истинно положительный, классификатор правильно отнес объект к рассматриваемому классу;
- TN - истинно отрицательный, классификатор правильно констатирует, что объект не принадлежит к рассматриваемому классу;

- FP - ложное срабатывание, классификатор неверно отнес объект к рассматриваемому классу;
- FN - ложноотрицательный, классификатор неверно констатирует, что объект не принадлежит к рассматриваемому классу.

Таким образом, на основе матрицы смежности можно рассчитать точность, которая показывает, насколько точны прогнозы, то есть процент правильно предсказанных классов (7) и полноты, которая представляет собой долю объектов, принадлежащих найденному классу. по сети относительно всех объектов этого класса в примере (8):

$$Precision = TP / (TP + FP) \quad (7)$$

$$Recall = TP / (TP + FN) \quad (8)$$

Другой индикатор — IoU (Intersection over Union), который позволяет измерить покрытие двух границ: предсказываемых классификатором и реальной, которая обрамляет объект на изображении (9):

$$IoU = (area\ of\ overlap) / (area\ of\ union) \quad (9)$$

Оценка F1 может быть интерпретирована как средневзвешенное значение точности и отзыва, где оценка F1 достигает своего лучшего значения при 1 и худшего значения 0. Относительный вклад точности и отзывчивости в оценку F1 равен (10).

$$F_{1-score} = \frac{2 * (precision * recall)}{(precision + recall)} \quad (10)$$

В случае с несколькими классами и несколькими метками это средний балл F1 каждого класса с взвешиванием, зависящим от среднего параметра.

4. Результаты

Значения метрик качества обучения, описанные выше, полученные в результате расчета тестовых примеров приведены в таблице 5 и в таблице 6.

Таблица 5
Метрики точности определения классов

№ класса	Название	Average precision, %	TP	FP
0	Neck	99.58	748	23
1	Deltas	98.46	1250	68
2	Breast	99.82	605	11
3	Press	99.23	529	19
4	Foreams	98.60	1366	47
5	Hips	98.92	1709	19
6	The_calf_muscle	99.55	1706	18
7	Back	99.61	493	11

- 3) Решение задачи поиска и классификации аномалий кинематики тела человека
- 4) Формирование общей рекомендательной системы реабилитации для аномальных областей мышечного аппарата.
- 5) Балансировка обучающей выборки для классификации групп мышц с помощью полуавтоматической разметки с применением созданной модели, зашумление текущих данных с помощью искусственно внесенных шумов и артефактов для стабилизации классификации на видео с разрешением 640×480 пикселей.

Список литературы

1. Lu T.-W., Chang C.-F. Biomechanics of human movement and its clinical applications // Kaohsiung J. Med. Sci. 2012. Vol. 28, № 2, Supplement. P. S13–S25.
2. Wada Y. et al. Kinematic analysis of human body motion // International Conference on Experimental Mechanics: Advances and Applications / ed. Chau F.S., Lim C.T. SPIE, 1997. Vol. 2921. P. 610–615.
3. Ganea D., Mereuta E., Mereuta C. Human Body Kinematics and the Kinect Sensor // Modeling and Optimization of the Aerospace, Robotics, Mechatronics, Machines-Tools, Mechanical Engineering and Human Motricity Fields. Trans Tech Publications Ltd, 2014. Vol. 555. P. 707–712.
4. Hend B. et al. LAHAR-CNN: Human Activity Recognition from one image using Convolutional Neural Network Learning Approach // Int. J. Biom. 2020.
5. Dorschky E. et al. CNN-Based Estimation of Sagittal Plane Walking and Running Biomechanics From Measured and Simulated Inertial Sensor Data // Front. Bioeng. Biotechnol. 2020. Vol. 8. P. 604.
6. Salomon G., Laroca R., Menotti D. Deep Learning for Image-based Automatic Dial Meter Reading: Dataset and Baselines. 2020.
7. Deepa R. et al. Comparison of Yolo, SSD, Faster RCNN for Real Time Tennis Ball Tracking for Action Decision Networks // 2019 International Conference on Advances in Computing and Communication Engineering (ICACCE). IEEE, 2019. P. 1–4.
8. Yakimov A. et al. The use of convolutional neural networks to identify artifacts of cells micrographs in biomedical research // Journal of Physics: Conference Series. 2019. Vol. 1399, № 3.
9. Tolmacheva A.E., Ogurcov D.A., Dorrer M.G. Puck tracking system for aerohockey game with YOLO2 // Journal of Physics: Conference Series. 2019. Vol. 1399, № 3.
10. Tolmacheva A.E., Ogurtsov D.A., Dorrer M.G. Justification for choosing a single-board hardware computing platform for a neural network performing image processing // IOP Conference Series: Materials Science and Engineering. 2020. Vol. 734, № 1.
11. Redmon J. et al. You Only Look Once: Unified, Real-Time Object Detection. 2015.
12. Li T. et al. Research on ROI Algorithm of Ship Image Based on Improved YOLO // 2019 International Conference on Artificial Intelligence and Advanced Manufacturing (AIAM). IEEE, 2019. P. 130–133.
13. Chen C.H., Pau L.F., Wang P.S.P. Handbook of Pattern Recognition and Computer Vision. WORLD SCIENTIFIC, 1993.
14. Bochkovskiy A., Wang C.-Y., Liao H.-Y.M. YOLOv4: Optimal Speed and Accuracy of Object Detection. 2020.
15. Padilla R., Netto S., da Silva E. A Survey on Performance Metrics for Object-Detection Algorithms. 2020.

О РОБАСТНОСТИ ДАННЫХ БОТУЛИНОТЕРАПИИ СПАСТИКИ У БОЛЬНЫХ С ПОСЛЕДСТВИЯМИ ОСТРОГО ОЧАГОВОГО ПОРАЖЕНИЯ ГОЛОВНОГО МОЗГА

А.Г. Арутюнян¹, К.О. Туценко³, А.А. Хорошавина³, Д.В. Похабов^{3,4}, В.Г. Абрамов⁴,
М.Е. Туник^{3,4}, М.Г. Садовский^{2,3,4}

¹КМК БСМП им. Н.С. Карповича, г.Красноярск, artem.a.arm@mail.ru

²Институт вычислительного моделирования СО РАН, msad@icm.krasn.ru

³Красноярский государственный медицинский университет имени профессора
В. Ф. Войно-Ясенецкого МЗ РФ, horoshavina-lina-yan@yandex.ru;
kseniamkib@gmail.com

⁴СНКЦ ФМБА России, г. Красноярск, excalibr@mail.ru, neurodmit@mail.ru

Введение.

Развитие современных средств и техник статистического анализа многомерных данных, обусловленное соответствующим развитием вычислительной техники, ставит новые задачи и позволяет отвечать на вопросы, на которые классическая статистика ответить не могла. Ярким примером таких данных, имеющих сложную внутреннюю структурированность, которую невозможно выявить классическими методами статистики, являются многомерные медицинские данные. В работе [1] показано, что данные по влиянию ботулотоксина на больных со спастикой обладают такой внутренней структурированностью и современные методы статистики (метод упругих карт, если быть точным) способны эту структурированность выявить.

Актуальность такого анализа обусловлена тем, что позволяет в полной мере решить целый ряд задач необходимых для проведения корректной обработки полученных результатов со сложной структурированностью. В ходе исследования, с учетом полученных данных и с последующим их анализом выявлены статистически значимые различия между исследуемыми группами. Благодаря новому методу обработки данных стало возможным наглядно представить полученные показатели пациентов на разных этапах исследования. Таким образом, используя новый подход к анализу данных в работе [1] доказана и наглядно представлена эффективность нового метода лечения спастичности. Учитывая все вышесказанное, можно утверждать, что данный метод анализа данных приемлем и может использоваться во множестве медицинских исследованиях.

В целом, новый подход к анализу данных лежит в русле исследований, называемых Big Data анализ. Такой подход подразумевает наличие весьма большого объема данных, однако это предположение выполняется далеко не всегда, особенно для медицинских данных. Иными словами, подходы, специфичные для больших объемов данных, применяются для анализа весьма умеренных по своему объему массивов данных. В этой ситуации встает задача проверки устойчивости той внутренней структурированности, которая наблюдается в этих массивах малой мощности. Именно этой задаче — проверке робастности (устойчивости) результатов анализа описанных выше медицинских данных — и посвящена настоящая работа.

Поясним суть проблемы. В работе [1] показано, что статистически значимые различия между опытной и контрольной группами имеются при оценке мышечного тонуса с помощью модифицированной шкалы Эшворта и модифицированной шкалы

Тардые — во всех исследуемых частях верхней конечности на втором и третьем этапе исследования, при оценке объема активных движений — в плечевом, локтевом и лучезапястном суставе, а также пальцах кисти (за исключением большого пальца) на втором этапе обследования и во всех исследуемых частях верхней конечности на третьем этапе. Однако число и больных, прошедших лечение, и здоровых было весьма невелико. В такой ситуации всегда возникает вопрос о том, не являются ли полученные результаты артефактом: возможна случайная комбинация данных, которая обеспечивает такую кластеризацию. Тем самым, возникает задача проверки надёжности полученной кластеризации. Решению именно этой задачи и посвящена настоящая работа.




Рис. 1 Упругая карта распределения контрольной (зелёный цвет) и опытной (синий цвет) группы

Для проверки устойчивости (робастности) результата, показанного на Рис.1 (здесь мы цитируем работу [1]) множества реальных больных, получавших лечение ботулинотерапией и контрольной группы были искусственно увеличены. Для этого к ним были добавлены суррогатные пациенты (и здоровые люди из контрольной группы), чьи показатели были установлены случайным образом, с различной степенью размаха. В исследовании принимали участие две группы: опытная и контрольная, в каждую из которых входило по 10 человек. Контрольная группа включала 4 мужчин и 6 женщин, средний возраст которых составил 59 ± 12 лет, из них 8 пациентов — с ОНМК и 2 пациента — с ЧМТ. Опытная группа состояла из 6 мужчин и 4 женщин, средний возраст которых составил 41 ± 13 , из них 7 пациентов — с ОНМК и 3 пациента — с ЧМТ. Пациенты были распределены по группам случайно. В обеих исследуемых группах

проводилась нейрореабилитация, однако в опытной группе дополнительно применялся ботулотоксин типа А. Исследуемые, которые вошли в контрольную группу, инъекций ботулотоксина не получали. Все полученные данные были внесены в базу и описаны с помощью методов описательной статистики в программе Microsoft Excel. Анализ данных классическими методами статистики проводился с использованием программы IBM SPSS Statistics 23. Описание полученных данных и результаты классического статистического анализа опубликованы в статье [1].

Выборки обследуемых, вошедших в исследование, численно малы, необходимо проверить устойчивость полученных результатов с помощью искусственного увеличения количества пациентов. Так называемые суррогатные выборки (искусственно созданные пациенты с такими же параметрами, как первоначальные выборки) были созданы с помощью генератора случайных чисел Microsoft Excel. Суррогатные выборки были сгенерированы с заданными средним и стандартным отклонением для каждого из показателей в каждой группе отдельно. Данные показатели были равны соответствующим параметрам, вычисленным по каждому показателю в каждой из исследуемых групп. Сгенерированные данные подчинялись нормальному закону распределения. Важно, что для определения устойчивости необходимо было установить, в какой именно момент различные группы начнут плохо отделяться друг от друга на упругой карте. Для этого были сгенерированы различные выборки суррогатных пациентов: выборка, где стандартное отклонение равно стандартному отклонению в первоначальной выборке, затем в 2 раза меньше и в 2 раза больше первоначального. Все полученные данные были обработаны нелинейным методом упругих карт в программе VidaExpert.

При построении упругой карты по всем полученным показателям исследуемых пациентов (рисунок 1) выделилось 2 кластера, первый кластер состоит из пациентов опытной группы, второй — из людей контрольной группы. Один из представителей контрольной группы на упругой карте попал в кластер опытной группы. Это может быть связано с многочисленными факторами, например: возраст пациента; характер, локализация и степень поражения головного мозга; слабовыраженная спастичность на момент осмотра (по mMAS < 16); эффективность комплексного консервативного метода лечения спастики; малое количество предикторов спастичности и т.д.




Рис. 2. Упругая карта сгенерированных выборок контрольной (зелёный цвет) и опытной (синий цвет) группы с $(0,5 \times \sigma)$ (А), $(1 \times \sigma)$ (Б), $(2 \times \sigma)$ (В)

Для проверки устойчивости полученных кластеров было проведено генерирование данных для суррогатных пациентов. С помощью генератора случайных чисел Excel были сгенерированы суррогатная контрольная ($n = 100$) и опытная группы ($n = 100$). Выборки генерировались с заданным средним значением и стандартным отклонением, найденным по выборкам, полученным естественным путём. Затем искусственно созданная суррогатная выборка соединялась с естественно полученной, далее строились упругие карты. Для проверки устойчивости кластеров были сгенерированы выборки с 0,5 стандартного отклонения ($0,5 \times \sigma$), 1 стандартным отклонением ($1 \times \sigma$) и 2 стандартными отклонениями ($2 \times \sigma$) исходной выборки (рисунок 2).

Обратимся к Рисунку 2. На рисунке 2А и 2Б кластеры показывают хорошую устойчивость, при построении упругой карты с 2 стандартными отклонениями (рисунок 2 В) уже можно наблюдать некоторое ухудшение разделения, но при этом всё ещё наблюдается деление на 2 кластера, что говорит о высокой устойчивости кластеризации. Представленные здесь результаты свидетельствуют о том, что кластеризация реальных данных является устойчивой и не представляет собой артефакта либо случайно полученного феномена в распределении данных.

Список литературы

1. Арутюнян А. Г., Туник М. Е., Абрамов В. Г., Туценко К. О., Хорошавина А. А., Похабов Д. В. Новые подходы к лечению и профилактике спастичности у больных в остром периоде очаговых поражений головного мозга с использованием ботулинического токсина типа А // Сибирское медицинское обозрение, 2020, № 4, с.84 – 91.
- 2.

СЕГМЕНТНАЯ СПАЙКОВАЯ МОДЕЛЬ НЕЙРОНА В ЗАДАЧЕ КЛАССИФИКАЦИИ ПАТТЕРНОВ ИМПУЛЬСОВ

Л.А.Астапова¹, А.М.Корсаков¹, А.В.Бахшиев², Е.А.Ерёменко², Е.Ю.Смирнова¹

¹Центральный научно-исследовательский и опытно-конструкторский институт
робототехники и технической кибернетики (ЦНИИ РТК), *l.astapova@rtc.ru*,
a.korsakov@rtc.ru, *eus@rtc.ru*

²Санкт-Петербургский политехнический университет Петра Великого, Институт
машиностроения, материалов и транспорта, Высшая школа автоматизации и
робототехники, *alexab@rtc.ru*, *elizaveta.yeremenko@gmail.com*

Введение

Моделирование нейроморфных архитектур стимулировано желанием понять и технически воплотить такие ключевые особенности нейронных структур мозга, как низкое энергопотребление, быстроедействие, высокая производительность, масштабируемость, способность иметь дело с параллельным и распределенным способом обработки информации, а также адаптивность к изменяющейся среде и обучаемость. Эти преимущества чрезвычайно перспективны для создания систем управления, основанных на поведенческих моделях.

Как известно, биологические нейронные сети обладают свойством пластичности и способностью к непрерывному обучению, дополнению и корректировке существующих знаний, на основе новой поступившей информации. Проблема пластичности к существенным изменениям среды функционирования в нервной системе решается гибкостью в первую очередь в рамках возможностей по структурной адаптации как топологии нейронных структур, так и дендритных деревьев отдельных нейронов. Нейрогенез, как один из механизмов пластичности мозга, заключающийся в появлении новых нейронов, структурной перестройке связей между ними, образовании новых синапсов и изменении синаптической передачи, важен для процессов обучения и памяти.

В рамках большинства архитектур искусственных нейронных сетей не рассматривается вопрос пластичности топологии сети и структурной перестройки. Более того, топология сети фиксирована в рамках конкретной архитектуры, а искусственные формальные нейроны не учитывают структурно сложное строение нейронов и особенности механизмов нейронного взаимодействия.

В рамках высокоэффективного нейроморфного подхода наибольшее развитие получили спайковые (импульсные) нейронные сети (СНС). Их относят к третьему поколению нейронных сетей, в которых, в отличие от распространённых искусственных нейронных сетей на формальных нейронах, информация кодируется дискретными импульсами (спайками) [1]. При обучении спайковых нейронных сетей, недифференцируемая функция пороговой активации не позволяет применять стандартные методы обучения искусственных нейронных сетей. Поэтому исследования в этой области направлены на адаптацию методов искусственных нейронных сетей (ИНС) к СНС, а именно на решение проблемы недифференцируемости, а также на разработку биологически подобных алгоритмов основанных на пластичности, зависящей от времени импульса [2 – 5].

Существующие простейшие модели спайкового нейрона [6 – 8] реализуют основные нейронные операции, но также, как и формальные нейроны, не учитывают особенности строения биологического нейрона (дендритное дерево, сома, синапсы). Поэтому, для повышения биологического правдоподобия сети, используют так называемые сегментные модели нейронов [9, 10]. А также разрабатываются архитектуры нейронных сетей, позволяющих осуществлять обучение в динамике (онлайн). Биологические принципы работы головного мозга вдохновили исследователей на создание спайковых динамически развивающихся нейронных сетей, способных работать в реальном времени. Для большинства спайковых нейронных сетей создана традиционная стратегия развития, которая не фиксирует структуру, а регулирует количество нейронов в процессе обучения, а также в динамическом режиме адаптирует веса нейронов [11 – 15].

В этой работе для задачи классификации используется не параметрическая, а именно структурная адаптация сети на уровне усложнения модели каждого узла путем перехода к сегментным моделям нейронов.

Используемая модель нейрона

В основу настоящей работы положена сегментная спайковая модель нейрона с возможностью структурной адаптации, ранее предложенная авторами [15]. В данной модели предполагается, что на входы нейрона поступают импульсные потоки, которые преобразуются в синапсах в аналоговые величины, описывающие процессы выделения и распада медиатора в синаптической щели. Входные и выходные сигналы нейрона равны нулю в отсутствии импульса, и константе на время действия импульса.

Особенностями предложенной модели нейрона, играющими существенную роль при решении задачи разработки алгоритмов структурного обучения модели нейрона, являются:

- возможность создания произвольного числа сегментов тела нейрона. С точки зрения решаемой в настоящей работе задачи, это означает возможность изменять размерность входного паттерна импульсов,
- возможность независимого наращивания длин дендритов. Так как на дендритах осуществляется пространственное и временное суммирование сигналов на значительных интервалах времени, увеличение длины дендрита приводит к временной задержке сигнала и к уменьшению его амплитуды,
- возможность добавления произвольного числа синапсов на произвольном участке мембраны (теле, дендрите). Добавление синапса приводит к увеличению амплитуды сигнала,
- возможность произвольной организации связей (как возбуждающих, так и тормозных) между отдельными элементами.

Всё вышеперечисленное позволяет посредством структурного реконфигурирования (адаптации) модели нейрона синхронизировать (путём изменения времени прихода одиночного импульса с каждого из дендритов на сому нейрона) и нормализовать сигнал (путём изменения его амплитуды). Выходной сигнал генерируется в низкопороговой зоне нейрона (генератор потенциала действия) и представляет собой одиночный импульс, либо серию импульсов единичной амплитуды, формируемых при превышении величиной потенциала порога. Само же значение потенциала внутри низкопороговой зоны нелинейно связано с суммой сигналов,

пришедших на вход нейрона, поэтому для преодоления порога и генерации потенциала действия нам необходимо максимизировать сумму вкладов в потенциал внутри низкопороговой зоны от всех дендритов, что достигается путём синхронизации действий входных сигналов нейрона и компенсации потерь амплитуды потенциала отдельным дендритом при наращивании его длины.

Таким образом, динамически адаптирующиеся модели нейронов способны обучаться путём автоматического подбора параметров модели нейрона, таких как размер сомы, длина дендритов и количество синапсов на каждом из дендритов для того, чтобы вызвать временной отклик на выходе в зависимости от входного паттерна, закодированного с использованием временного окна и временных задержек в вектор одиночных спайков, поступающих на отдельный дендрит нейрона. Разработанный алгоритм структурной организации моделей нейрона в спайковую нейронную сеть позволяет распознавать произвольные паттерны импульсов, путём введения тормозных синапсов между обученными моделями нейронов.

Экспериментальные исследования и результаты

Для моделирования использовалась ранее предложенная авторами программная платформа [16].

Разработанный алгоритм распознавания паттернов оценивался на задаче классификации набора данных Iris [17] с четырьмя обучающими примерами из каждого класса.

Перед подачей входных данных в сеть необходимо закодировать числовые признаки в значения временных задержек. Пусть входной набор данных $X = \{(x_1^1; x_2^1; \dots; x_N^1; y^1), (x_1^2; x_2^2; \dots; x_N^2; y^2), \dots, (x_1^M; x_2^M; \dots; x_N^M; y^M)\}$, где M – общее количество входных данных, N – размерность пространства признаков. Согласно [18] задержку n -ого признака m -ого примера входных данных X можно вычислить как

$$d_n^m = \frac{x_n^m - x_{\min}^n}{x_{\max}^n - x_{\min}^n} \cdot T,$$

где $x_{\min}^n$ и $x_{\max}^n$ соответственно минимальное и максимальное значение n -ого признака по всему набору данных, T – ширина временного окна.

Особенностью входных паттернов импульсов является то, что они отличаются лишь относительным временем спайков, т.е. важна лишь разница между всеми задержками временного паттерна. Сдвиг всего паттерна на любое число даст тот же паттерн. Поскольку в рассматриваемой задаче, помимо относительных, значимы и абсолютные величины времени спайков, необходимо зафиксировать паттерн импульсов относительно некоторого постоянного элемента – калибровочного элемента, значение которого равно ширине временного окна. Таким образом, при добавлении калибровочного элемента во входной вектор размерность пространства признаков становится равной $N+1$, а соответствующий добавленному признаку дендрит становится базовой моделью дендрита, начальный экстремум кривой потенциала которого фиксируется с наибольшим запаздыванием.

Набор данных содержит примеры, принадлежащие K ($K = 3$) классам. Из каждого класса были выбраны по P ($P = 4$) примеров. Для классификации данных Iris по четырём

обучающим примерам из каждого класса, описанные ранее входные спайковые нейроны $\text{NeuronTrainer}(k, p)$, соответствующие классу $k = 1..K$ и обучающему примеру $p = 1..P$, были организованы в соответствии со схемой, представленной на рис. 1. Генерация входных импульсов осуществляется генераторами $\text{Source}(n)$, где $n = 1..N+1$. Нейроны $\text{OrNeuron}(k)$, соответствующие k -ому классу, принимают на вход все сигналы нейронов $\text{NeuronTrainer}(k, p)$, осуществляя логическую операцию «ИЛИ», т.е. генерируя выходной сигнал при поступлении на вход сигнала хотя бы от одного $\text{NeuronTrainer}(k, p)$ k -ого класса. Введение тормозных связей между нейронами $\text{OrNeuron}(k)$ приводит к генерации выходного сигнала тем нейроном $\text{OrNeuron}(k)$, на один из входов которого сигнал поступил раньше. Генерация спайка на выходе низкопороговой зоны нейронов $\text{OrNeuron}(k)$ и является результатом классификации.

Стоит отметить возможность генерации спайков несколькими нейронами $\text{OrNeuron}(k)$, если сигналы поступили на их входы в пределах одного временного дискрета. Такой случай будем называть «неуверенным распознаванием».




Рис. 1. Схема организации сегментных моделей нейронов для решения задачи классификации набора данных Iris

По диаграмме, представленной на рис. 2, можно заметить, что уверенно классифицированные примеры образовали отдельные кластеры вокруг обучающих примеров, линейно отделимые друг от друга. Неуверенное и неверное распознавание можно видеть в области пересечения классов, т. к. примеры в этой области схожи. Некоторые примеры, от которых геометрическое расстояние до любого из обучающих примеров достаточно велико, не были распознаны ни одним нейроном. Это объясняется

способностью предложенной модели нейрона отвечать на паттерны импульсов лишь до некоторого предела отличные, чем паттерн импульсов, которому данная модель нейрона обучалась.




Рис. 2. Результаты классификации всего набора данных Iris

Количественная оценка точности классификации набора данных Iris организованной группой спайковых сегментных нейронов представлена в табл. 1.

Таблица 1

Точность классификации набора данных Iris

Класс	Уверенное распознавание		Неверное распознавание		Неуверенное распознавание		Отсутствие распознавания	
	Кол-во	%	Кол-во	%	Кол-во	%	Кол-во	%
1	50	100,0	0	0,0	0	0,0	0	0,0
2	46	92,0	1	2,0	3	6,0	0	0,0
3	29	58,0	4	8,0	15	30,0	2	4,0
Итог	125	83,3	5	2,0	18	12,0	2	1,3

Сравнение разработанной спайковой нейронной сети с существующими решениями представлено в табл. 2.

Таблица 2

Сравнительная таблица существующих алгоритмов на наборе данных Iris

	Метод	Точность, %
Машинное обучение и многослойный перцептрон	MLP (50-10-3)	95,7
	kNN	92,0
	SVM	96,0
	DBSCAN[19]	80,7
Спайковые нейронные сети	ReSuMe [3]	88,0
	Tempotron [4]	86,6
	SpikeProp (50-10-3) [2]	96,1

	SWAT (16-208-3) [5]	95,3
Динамически развивающиеся спайковые нейронные сети	Belatreche 2012[14]	90,3
	SRESN [11]	97,0
	Wang 2014 [13]	86,1
	SpikeCD [18]	98,0
SNN with compartment neurons	Предложенная сеть	83,3

Заключение

С использованием разработанного алгоритма для СНС на сегментных моделях нейрона данные были разделены на отдельные непересекающиеся кластеры. Учитывая тот факт, что в эксперименте в данной работе было использовано для обучения лишь четыре примера из каждого класса, можно говорить о многообещающих перспективах применения СНС на сегментных моделях нейрона в задачах классификации.

Недостатком данного подхода является то, что результат вычислений зависит от конкретно выбранных для обучения примеров. Кроме того, большая вычислительная сложность предложенной сети обуславливается высокой вычислительной сложностью модели спайкового нейрона.

Преимущество предложенного подхода заключается в использовании сегментной модели нейрона как альтернативной стратегии построения спайковой нейронной сети с учётом особенностей строения биологического нейрона (дендритное дерево, сома, синапсы). Предложенная модель не требует настройки внутренних параметров в процессе функционирования, все изменения функциональности определяются модификацией структурной организации. В дальнейших исследованиях планируется обучение на большой выборке, реализация инкрементного обучения с динамическим добавлением нейронов в сеть и изменением топологии сети. Также многообещающим направлением развития работ по данной тематике является исследование глубоких спайковых нейронных сетей и различных методов обучения, включая биологически подобное правило обучения без учителя STDP (Spike-Timing-Dependent Plasticity) и, в дальнейшей перспективе, – реализация на нейроморфном оборудовании.

Благодарности

Работа проводилась в рамках выполнения государственного задания Минобрнауки России № 075-00913-21-01 «Методы автоматического синтеза оптимального управления поведением группы роботов на основе ситуационного анализа с применением семантических технологий» от 29.04.2021.

Список литературы

1. James C.D. et al. A historical survey of algorithms and hardware architectures for neural-inspired and neuromorphic computing applications // Biologically Inspired Cognitive Architectures. 2017. Vol. 19. P. 49–64.
2. Bohte S.M. Error-backpropagation in temporally encoded networks of spiking neurons / S.M.Bohte [et al.] // Neurocomputing. – 2002. – 48(1). – P. 17 – 37.
3. Ponulak F. Supervised learning in spiking neural networks with ReSuMe: sequence learning, classification, and spike shifting / F.Ponulak, A.Kasiński // Neural Computation. – 2010. – 22(2). – P.467 – 510.

4. Gütig R. The tempotron: a neuron that learns spike timing-based decisions / R.Gütig, H.Sompolinsky // *Nature Neuroscience*. – 2006. – 9(3). – P. 420 – 428.
5. Wade J.J. SWAT: A Spiking Neural Network Training Algorithm for Classification Problems / J.J.Wade [et al.] // *IEEE Transactions on Neural Networks*. – 2010. – 21(11). – P.1817 – 1830.
6. Thorpe S. Spike-based strategies for rapid processing / S.Thorpe, A.Delorme, Van Rullen R. // *Neural Networks*. – 2001. – 14(6). – P.715 – 725.
7. Hodgkin A.L. A quantitative description of membrane current and its application to conduction and excitation in nerve / A.L.Hodgkin, A.F.Huxley // *The Journal of Physiology*. – 1952. – 117(4). – P.500 – 544.
8. Stein R.B. A Theoretical Analysis of Neuronal Variability / R.B.Stein // *Biophysical Journal*. – 1965. – 5(2). – P.173 – 194.
9. Yang S. Scalable Digital Neuromorphic Architecture for Large-Scale Biophysically Meaningful Neural Network With Multi-Compartment Neurons / S.Yang [et al.] // *IEEE Transactions on Neural Networks and Learning Systems*. – 2020. – 31(1). – P.148 – 162.
10. Yi G. Action potential initiation in a two-compartment model of pyramidal neuron mediated by dendritic Ca²⁺ spike / G.Yi [et al.] // *Sci Rep*. – 2017. – 7(45684).
11. Dora S. Development of a Self-Regulating Evolving Spiking Neural Network for classification problem / S.Dora [et al.] // *Neurocomputing*. – 2016. – 171. – P.1216 – 1229.
12. Kasabov N. Dynamic evolving spiking neural networks for on-line spatio- and spectro-temporal pattern recognition / N.Kasabov [et al.] // *Neural Networks*. – 2013. – 41. – P.188 – 201.
13. Wang J. An online supervised learning method for spiking neural networks with adaptive structure / J.Wang [et al.] // *Neurocomputing*. – 2014. – 144. – P.526 – 536.
14. Belatreche A. Dynamic cluster formation using populations of spiking neurons / A.Belatreche, R.Paul // *The 2012 International Joint Conference on Neural Networks (IJCNN)*. – 2012. – P.1 – 6.
15. Bakhshiev A.V. Mathematical Model of the Impulses Transformation Processes in Natural Neurons for Biologically In-spired Control Systems Development / A.V.Bakhshiev, F.V.Gundelakh // *CEUR Workshop Proceedings*. – 2015. – 1452. – P.1 – 12
16. Bakhshiev A.V. The architecture of a software platform for growing spiking neural networks simulator developing / A.V. Bakhshiev [et al.] // *J. Phys.: Conf. Ser. IOP Publishing*. – 2020. – 1679(042001).
17. UCI Machine Learning Repository: Iris Data Set [Электронный ресурс]. URL: <https://archive.ics.uci.edu/ml/datasets/iris>.
18. Lin P. SpikeCD: a parameter-insensitive spiking neural network with clustering degeneracy strategy / P.Lin [et al.] // *Neural Comput & Applic*. – 2019. – 31(8). – P.3933 – 3945.
19. Lai W. A New DBSCAN Parameters Determination Method Based on Improved MVO / W.Lai [et al.] // *IEEE Access*. – 2019. – 7. – P.104085 – 104095.

СОПОСТАВЛЕНИЕ МЕТОДОВ ИДЕНТИФИКАЦИИ СТИМУЛА, ПОЛУЧЕННОГО ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТЬЮ, ПО НЕЙРОННОЙ АКТИВНОСТИ¹

С.И.Барцев^{1,2}, Г.М.Маркова²

¹ Институт биофизики СО РАН –

обособленное подразделение ФИЦ КНИЦ СО РАН, bartsev@yandex.ru

² Сибирский федеральный университет, Красноярск, Россия

Восстановление информации, обрабатываемой мозгом, по сопутствующим паттернам нейронной активности – актуальная задача когнитивной нейронауки и концепции нейронных коррелятов в частности [1]. Для этого требуется оценить, являются ли паттерны, соответствующие одному и тому же содержанию, воспроизводимыми. Известно, что релевантная для текущей задачи информация представлена в рабочей памяти в динамичной форме [2-5], а паттерны нейронных ответов, связанных с идентичностью полученного стимула, весьма вариативны.

Вопрос о том, в каком виде сохраняется ли релевантная информация о поступившем в нейронную сеть стимуле, был исследован на рекуррентных искусственных нейронных сетях (РНС) [6]. Показано, что кодировка информации о внешнем стимуле, полученном в ходе теста отложенного сравнения с образцом (ОСО), является динамичной. Таким образом, закономерности, выявленные с помощью биологических нейронных сетей, были воспроизведены на искусственных нейронных сетях, что позволяет использовать их для моделирования нейронной активности.

Цель настоящей работы – сопоставить эффективность двух методов идентификации стимула, полученного простой РНС, по паттерну нейронной активности в период времени, когда РНС хранит информацию о данном стимуле в рабочей памяти. Рассматривались метод центроидов и метод нейросетевого декодирования.

РНС, обучавшиеся прохождению ОСО, имели два входа, два выходных нейрона и различное число внутренних нейронов (25, 30). Отклик РНС – $y_o^{(t)}$ в момент времени t вычислялся следующим образом:

$$\begin{aligned} y_h^{(t)} &= f_h(W_h \cdot y_h^{(t-1)} + W_i \cdot x^{(t)}) \\ y_o^{(t)} &= f_o(W_o \cdot y_h^{(t)}) \end{aligned} \quad (1)$$

где W_h , W_i , W_o – матрицы весовых коэффициентов внутренних нейронов, входов и выходных нейронов соответственно; $x^{(t)}$ – вектор входных сигналов в момент времени t ; векторы $y_h^{(t)}$ и $y_h^{(t-1)}$ – уровни возбуждения внутренних нейронов в моменты времени t и $t-1$. Функции активации внутренних и выходных нейронов представлены как $f_h(\cdot)$ и $f_o(\cdot)$ соответственно:

$$f_h(x) = \frac{1}{2} \left(\frac{x}{a + |x|} + 1 \right), \quad (2a)$$

¹ Работа выполнена при поддержке РФФИ-ККФН, проект 20-41-240003.

$$f_o(x) = \begin{cases} 0, & \text{if } x \leq 0 \\ b \cdot x, & \text{if } x > 0 \text{ \& } x < 1 \\ 1, & \text{if } x \geq 1 \end{cases} \quad (2b)$$

Обучение РНС проводилось с помощью алгоритма обратного распространения ошибки с глубиной распространения 6 тактов. Конкретный вид обучающего алгоритма в данном случае не имеет значения, поскольку предполагается рассмотрение нейронной активности уже обученных РНС, структура которых формируется независимо от способа обучения [7].

РНС обучались прохождению теста ОСО. Первым на вход поступал один из трех случайно выбранных стимулов – входных векторов: А – (01), В – (10) и С – (11). После паузы, продолжительность которой случайным образом варьировалась от 3 до 6 тактовых циклов, на вход поступал второй стимул, также выбранный случайно. На третьем шаге после предъявления второго стимула РНС вырабатывала на выходных нейронах сигнал (10), если эти стимулы совпадали, и (01) в противоположном случае. После этого цикл реакции повторялся.

РНС указанной конфигурации обучались прохождению теста ОСО. Поскольку период паузы между получением первого и второго стимулов варьировался по продолжительности, РНС хранили сведения о первом полученном стимуле, будучи готовыми использовать их в любой возможный момент появления второго стимула. Таким образом, представление сущности первого стимула во время паузы формировалось в паттернах нейронной активности РНС в виде динамического инварианта.

Метод центроидов [8] рассматривался как возможный метод для выделения данных инвариантов. Вид полученного РНС стимула определялся по минимальному значению расстояния между совокупным уровнем возбуждения нейронов РНС на данном такте и центроидами, соответствовавшими каждому из возможных стимулов. Результат декодирования стимулов, полученных тремя 25-нейронными и тремя 30-нейронными РНС в ходе теста ОСО, представлен в таблице. Здесь и далее при регистрации нейронной активности рассматривались уровни возбуждения нейронов РНС, обученных тесту ОСО со случайной продолжительностью паузы между стимулами, соответствующие четырем тактам перед предъявлением второго стимула.

Таблица

Применение метода центроидов для идентификации стимула, полученного 25-нейронными и 30-нейронными РНС

Номер такта	Входной стимул	Результат декодирования					
		25-нейронные РНС			30-нейронные РНС		
		Сеть 1	Сеть 2	Сеть 3	Сеть 1	Сеть 2	Сеть 3
3	А	А	А	А	В	В	А
4	А	В	В	А	А	В	А
5	А	А	А	А	А	С	А
6	А	А	А	А	А	С	В
3	В	В	В	В	В	В	А

4	В	С	С	В	С	В	А
5	В	В	В	В	А	С	В
6	В	В	В	В	А	С	В
3	С	В	В	С	В	В	А
4	С	С	С	А	С	С	С
5	С	С	С	С	С	С	С
6	С	В	В	С	А	С	В
Точность		67%	67%	92%	50%	42%	58%

Как показано в таблице, в среднем эффективность метода центроидов для идентификации полученного РНС стимула по нейронной активности для 25-нейронных РНС выше, чем для 30-нейронных.

Применение данного метода к случайно сгенерированным данным вместо нейронной активности РНС показало 25-50% «совпадений». Таким образом, эффективность метода центроидов при рассмотрении реальных данных по нейронной активности 30-нейронных сетей сопоставима с таковой для случайных чисел.

Низкая точность идентификации может объясняться высокой вариабельностью сигнала, кодирующего стимулы, а также тем фактом, что метод центроидов не учитывает индивидуальную динамику нейронов в составе РНС. Для более точного распознавания требуется метод, позволяющий выделить динамический инвариант представления полученного РНС стимула, в котором могла бы учитываться индивидуальная динамика каждого нейрона. Таковым является метод нейросетевого декодирования.

В качестве декодера применялись однослойные нейронные сети (ДН), состоящие из трех нейронов с линейной функцией активации (2b), связанных с каждым из входов. Количество входов соответствовало количеству нейронов РНС, нейронная активность которых использовалась для декодирования. Входными данными для ДН служили уровни возбуждения нейронов РНС в период паузы между поступлением стимулов (3-6 такты включительно). Для обучения ДН использовался алгоритм обратного распространения ошибки.

Данный метод показал 100%-ную эффективность: ДН обучились безошибочному распознаванию стимула, сведения о котором хранились в паттерне нейронной активности РНС, как для 25-нейронных, так и для 30-нейронных РНС. Также были выделены наиболее значимые нейроны РНС, уровни возбуждения которых представляли исчерпывающие сведения для реконструкции стимула. Для этого проводилась редукция структуры ДН: синапсы с наименьшими по модулю значениями, связывавшие нейроны с одним из выходов, приравнивались нулю, после чего проходило дообучение ДН до исходного качества функционирования. Процедура повторялась до выявления минимально допустимого количества входов с ненулевыми синапсами, при котором было возможно функционирование с требуемой эффективностью. Использовались данные по нейронной активности трех 25-нейронных и трех 30-нейронных РНС, для каждой были обучены по три ДН. С помощью редукции для 25-

нейронных РНС было выявлено 7 ± 1 значимых нейронов, для 30-нейронных 9 ± 2 нейронов.

Для иллюстрации задачи, которую решали ДН, на рисунке приведены уровни возбуждений наиболее значимых нейронов 30-нейронной РНС, соответствующие хранению информации о стимулах А и В.




Рис. Активность нейронов 30-нейронной РНС, наиболее значимых для декодирования стимулов А и В. Вид полученного стимула указан в скобках. Подписи в легенде – порядковые номера выделенных нейронов РНС.

Предложенный в работе метод нейросетевого декодирования позволил идентифицировать конкретный вид стимула, полученного рекуррентной нейронной сетью и хранящегося в динамическом паттерне ее нейронной активности. С помощью метода центроидов стимулы, полученные нейронными сетями в ходе прохождения теста отложенного сравнения с образцом, были реконструированы в среднем с точностью 75%

для 25-нейронных сетей и 50% для 30-нейронных, в то время как эффективность метода нейросетевого декодирования составила 100% для сетей обоих размеров. Преимущества данного метода – учет индивидуальных паттернов возбуждения для каждого нейрона исходной сети, а также возможность выделения минимально необходимого подмножества нейронов, обеспечивающих кодирование полученного сетью стимула. Ориентация на выявление минимального набора нейронов, чья активность лежит в основе того или иного явления, свойственна концепции нейронных коррелятов [1], что позволяет отнести предложенный метод к данному подходу.

Список литературы

1. Crick F. A framework for consciousness / F.Crick, C.Koch // *Nature Neuroscience*. – 2003. – Vol.6. – № 2. – P.119–126.
2. Meyers E.M. Dynamic population coding and its relationship to working memory / E.M.Meyers // *Journal of Neurophysiology*. – 2018. – Vol.120. – №. 5. – P.2260-2268.
3. Meyers E.M. Dynamic population coding of category information in inferior temporal and prefrontal cortex / E.M.Meyers, D.J.Freedman, G.Kreiman, E.K.Miller, T.Poggio // *Journal of neurophysiology*. – 2008. – Vol.100. – № 3. – P.1407-1419.
4. Barak O. Neuronal population coding of parametric working memory / O.Barak, M.Tsodyks, R.Romo // *Journal of Neuroscience*. – 2010. – Vol.30. – P.9424–9430.
5. Stokes M.G. Dynamic coding for cognitive control in prefrontal cortex / M.G.Stokes, M.Kusunoki, N.Sigala, H.Nili, D.Gaffan, J.Duncan // *Neuron*. – 2013. – Vol.78. – № 2. – P.364-375.
6. Miconi T. Biologically plausible learning in recurrent neural networks reproduces neural dynamics observed during cognitive tasks / T.Miconi // *Elife*. – 2017. – Vol.6. – P.e20899.
7. Барцев С.И. Симметрии структуры и эквивиальность эволюционных исходов в простых нейросетевых моделях / С.И.Барцев, О.Д.Барцева // *Доклады Академии наук*. – 2002. – Т.386. – №. 1. – С.114-117.
8. Crowe D.A. Rapid sequences of population activity patterns dynamically encode task-critical spatial information in parietal cortex / D.A.Crowe, B.B.Averbeck, M.V.Chafee // *Journal of Neuroscience*. – 2010. – Vol.30. – № 35. – P.11640-11653.

КЛАССИФИКАЦИЯ ЗВЕЗД ПО НАЛИЧИЮ ЭКЗОПЛАНЕТ ИЗ КАТАЛОГА GAIA DR2

Р.В. Бикмурзин, Д.П. Федченко

Сибирский федеральный университет, bikmurzin.sfe@gmail.com, fdp@bk.ru

Космический телескоп «Кеплер», предназначенный для поиска экзопланет (ЭП) транзитным методом, был запущен NASA 7 марта 2009 года. В результате своей миссии спутник обнаружил более двух тысяч ЭП, которые были подтверждены, и еще около двух тысяч находятся в списке ожидания для подтверждения.

Другой телескоп «Гайя» (Gaia), похожий на большую дамскую шляпу, был запущен европейским космическим агентством 19 декабря 2013 года. Находясь все время в тени Земли, во второй точке Лагранжа, спутник прикрыт от яркого света Солнца и имеет возможность постоянно вести наблюдение за всей поверхностью неба. Миссия была рассчитана на 5 лет, но космическая обсерватория продолжает функционировать уже более 7 лет. В 2018 году был выпущен второй релиз Gaia DR2, содержащий более чем 1,7 млрд. космических объектов.

Для открытия у звезды ЭП транзитным методом необходимо постоянно вести периодические наблюдения за большим количеством звезд. В нашей галактике находится от 200 до 400 млрд. звезд, следовательно, выбор объекта наблюдений может играть одну из ключевых ролей для успешного результата исследований. В данной работе предлагается метод построения классификатора, который на основе звездного каталога Gaia DR2 и подтвержденных ЭП выбирает звезды с возможным нахождением ЭП.

Пусть X — множество звезд, $Y = \{0,1\}$ — множество меток классов (класс определяет наличие планеты на орбите звезды, 0 — нет, 1 — да), $\hat{y}: X \rightarrow Y$ — целевая функция, известная только на объектах обучающей выборки $X^l = (x_i, y_i)_{i=1}^l$, $y_i = \hat{y}(x_i)$. Требуется построить алгоритм классификации $a: X \rightarrow Y$, аппроксимирующий $\hat{y}$ на всем множестве X .

При использовании виртуального планетария Stellarium было отмечено, что на относительно небольшом участке неба (рис. 1) космический телескоп «Кеплер» открыл достаточно большое количество экзопланетарных систем, чтобы можно было с применением методов машинного обучения попытаться создать классификатор звезд по наличию ЭП. Скажем, что звезды, находящиеся в поле зрения «Кеплера» и имеющие на своей орбите ЭП, принадлежат классу 1, а звезды, у которых на данный момент не было обнаружено (или подтверждено) наличие ЭП принадлежат классу 0.

Чтобы построить классификатор звезд на наличие ЭП подобный классификаторам, делящим пациентов на здоровых и больных, или транзакции в банковской сфере на мошеннические и легитимные, необходимо на этом ограниченном участке неба определить звезды с ЭП. Для этого воспользуемся звездным каталогом и каталогом экзопланет. Звездный каталог GAIA DR2 (<http://www.esa.int/science/gaia>) предоставит информацию о всех имеющихся звездах с их характеристиками, а каталог ЭП (<https://exoplanetarchive.ipac.caltech.edu>) позволит добавить к звездному каталогу дополнительную метку наличия на орбите звезды подтвержденных ЭП.

На основе границ поля зрения телескопа «Кеплер» (рис. 1), мы выбрали прямоугольный участок неба в границах координат $Ra = (283,5^\circ; 298,1^\circ)$ и $Dec = (39,2^\circ; 49,5^\circ)$ (Ra/Dec — прямое восхождение/склонение). Соотношение количества звезд с ЭП и без ЭП составляет $892/457868 = 0,001948$. Количество звезд без ЭП — 99,81%, а с ЭП — 0,19% (рис. 2).

Проблема при построении классификатора с большим дисбалансом данных (один класс составляет доли процента от другого) заключается в том, что модель может отнести все объекты к численно превосходящему классу, показывая высокую точность определения, и допуская при этом ошибки только на малочисленном классе. Смысл в работе данного классификатора теряется, т.к. зачастую требуется правильно определять объекты, относящиеся к более малочисленному классу, допуская при этом как можно меньше ложноположительных ошибок. Среди способов решения проблемы с балансировкой данных существует несколько наиболее популярных: случайное удаление примеров мажоритарного класса, дублирование примеров миноритарного класса, алгоритм создания синтетических объектов SMOTE, немного отличающийся алгоритм ASMO, поиск связей Томека и другие [1, 2]. Таким образом, задача выявления звезд с ЭП сводится к поиску модели, которая обнаруживает наибольшее количество звезд с ЭП при минимальном количестве звезд, где ЭП не обнаружены, но были ошибочно отнесены к классу 1.




Рис.1. Выбранный прямоугольный участок неба (зеленые метки — ЭП).




Рис.2. Баланс классов.

При работе с файлами звездного каталога была использована отечественная СУБД ClickHouse. Для ограниченного по координатам участка неба из базы данных был экспортирован csv-файл космических объектов (5 173 467).

В файле каталога ЭП необходимо было выделить только те звезды с ЭП, которые находились на изучаемом нами участке неба. Учитывая, что около одной звезды возможно нахождение нескольких ЭП и то, что в каталоге ЭП не было идентификатора для звезд, который позволил однозначно сопоставить звезды из каталога GAIA, пришлось сопоставить координаты звезд из каталога ЭП с координатами звездного каталога. В результате был получен файл со всеми характеристиками звезды каталога GAIA с дополнительной меткой наличия ЭП.

После предварительного анализа данных, содержащихся в каталоге GAIA, были выбраны 5 столбцов описывающие наблюдательные и теоретические характеристики звезды (parallax, phot_g_n_obs, phot_g_mean_mag, teff_val, lum_val).

Следующим шагом была проверка данных на пропущенные значения в ячейках. Если звезды содержали пропуски по какому-либо признаку или имели отрицательный параллакс, то они удалялись из выборки.

В итоге, после предварительной чистки данных, на исследуемом участке неба осталось 458 760 объектов, удовлетворяющих всем нашим критериям. Из них 892 звезды с ЭП и 457 868 без.

Для оценки предсказывающей способности классификатора в качестве тестовой выборки случайно взяли 30% объектов из очищенного набора данных. Таким образом в тренировочной части осталось 321 132 объекта (из которых с ЭП 624 звезды), а в тестовой выборке 137 628 звезд (268 с ЭП). Разделение на тренировочную и тестовую выборки было проведено, чтобы отношение числа звезд с ЭП и без оставалось одинаковым в обоих случаях.

С помощью предложенной идеи были построены 3 вида классификаторов, на основе логистической регрессии, случайного леса и нейронной сети. Лучшие результаты

продемонстрировали модели случайного леса и нейронной сети. Для оценки качества классификаторов использовалась матрица ошибок (рис. 3), которая представляет собой сводную таблицу действительных значений меток классов и значений меток, предсказанных моделью классификатора.

		Predicted class	
		<i>P</i>	<i>N</i>
Actual Class	<i>P</i>	True Positives (TP)	False Negatives (FN)
	<i>N</i>	False Positives (FP)	True Negatives (TN)

Рис.3. Матрица ошибок.

С помощью логистической регрессии мы смогли построить модели классификаторов с показателями TP и TN, которые одновременно превышают значение 0,7. При подборе порога отсечки модели идентифицируют 90% объектов 1-класса (звезд с ЭП), но при этом для 0-класса правильно определяются только 67% звезд. Таким образом на одну обнаруженную звезду приходится от 149 до 190 звезд, ошибочно идентифицированных как 1-класс (ложноположительная ошибка).

Используя случайный лес для построения классификатора, отношение ложноположительных ошибок (FP) к правильно определенным объектам с ЭП (TP) удалось снизить до 135, но доля верно классифицированных звезд с ЭП (1-класс) снизилась до 72%.

Выбрав для пробы несложную архитектуру нейронной сети, как на рис. 4, классификатор показал почти такие же результаты, что и случайный лес, но коэффициент отношения правильно определенных объектов к ложноположительным был немного улучшен. На одну звезду, правильно классифицированную как звезда с ЭП, приходится 133 звезды без подтвержденных ЭП. Модель нейросети была записана, и ее можно применять к другим объектам.

После применения классификатора на основе нейронной сети к 24.698.432 звездам в радиусе 1000 св. лет от Земли из каталога GAIA DR2, была получена выборка из 1.877.009 звезд, у которых классификатор определил возможное наличие экзопланет.

тип слоя	размерность слоя
входящий вектор	5
полносвязный слой	10
tanh	
Dropout (0.1)	
полносвязный слой	10
ReLU	
Dropout (0.1)	
полносвязный слой	2
tanh	

Рис.4. Архитектура нейронной сети.

Дальнейшее изучение данной темы возможно относительно улучшения эффективности показателей классификаторов, т.к. на тестовой выборке на одну звезду с ЭП, классификаторы находят еще дополнительные 133 звезды (ложноположительная ошибка). Такое относительно большое ложное срабатывание можно уменьшить, используя другую архитектуру нейронной сети и уточнив гиперпараметры. Учитывая, что в данной работе, на обучающей выборке вводилось предположение отсутствия экзопланеты из факта отсутствия данной звезды в каталогах экзопланет, то и среди ложноположительных результатов возможно наличие звезд с планетами на орбите.

This work has made use of data from the European Space Agency (ESA) mission Gaia (<https://www.cosmos.esa.int/gaia>), processed by the Gaia Data Processing and Analysis Consortium (DPAC, <https://www.cosmos.esa.int/web/gaia/dpac/consortium>). Funding for the DPAC has been provided by national institutions, in particular the institutions participating in the Gaia Multilateral Agreement.

Список литературы

1. Шолле Ф. Глубокое обучение на Python / Ф. Шолле. – Санкт-Петербург: Питер, 2018. – 400 с.
2. Nitesh V. SMOTE: Synthetic Minority Over-sampling Technique / V. Nitesh, Chawla, Kevin W. Bowyer, Lawrence O. Hall, W. Philip Kegelmeyer // Journal of Artificial Intelligence Research. 2002. Vol. 16. Issue 1. P. 321–357.

ВЛИЯНИЕ ПСИХОТЕХНИК НА ИЗМЕНЕНИЕ РИТМОВ МОЗГА И ТЕМПЕРАТУРЫ ЛИЦА

Н.М. Богатов, А.Н. Богатова, С.А. Сухих, Л.Р. Григорьян, М.С. Коваленко,
А.А. Носаль, Д.А. Щетинин

Кубанский государственный университет, *bogatov@phys.kubsu.ru*

Введение

Современный ритм жизни приводит к возрастающим психофизиологическим нагрузкам. В результате повышаются биоэнергетические затраты организма, что способствует истощению его ресурсов, появлению хронической усталости, хронического стресса, различных психологических и соматических расстройств. Специализированные программы и психотехнические процедуры, использующие методики саморегуляции, разрабатываются для улучшения в условиях стресса физиологического состояния людей и их психического здоровья [1]. Представление организма целостной системой является теоретической основой этих методик [2]. Важнейшим фактором достижения физиологической, психологической и социальной адаптации служат процессы регуляции организма, реализующиеся как на уровне отдельных функциональных систем, так и посредством их взаимодействия [3]. Нейрогуморальные реакции играют важнейшую роль в этих процессах [4]. Положительное влияние психотехник на саморегуляцию функциональных состояний человека продемонстрировано в работах [5 – 8]. Способность к саморегуляции посредством управления психоэнергетическим потенциалом является индивидуальной характеристикой человека.

Биологическая и психическая энергия, обеспечивающая адаптационные процессы человека, необходима для активной умственной деятельности. В процессе умственной работы существуют внешние и внутренние причины расхода энергии. Эти причины способствуют возникновению хронической усталости и хронического стресса как угрозы здоровью [9].

В данной работе развивается концепция, согласно которой воздействие сознания субъекта изменяет энергоинформационный обмен в организме, отражающийся в функционировании его органов и систем [10 – 12].

Целью является доказательство объективными методами влияния воздействия сознания субъекта на изменение ритмов мозга и температуры тела.

Методика исследований

В исследовании приняли участие 100 человек в возрасте 20 – 25 лет. Методика исследования включала три этапа: 1 – определение начального функционального и психоэмоционального состояния испытуемых, 2 – методически организованный сеанс саморегуляции, 3 – определение функционального и психоэмоционального состояния испытуемых после сеанса саморегуляции. Длительность сеансов саморегуляции составляла 20 ÷ 30 минут. Применялись следующие психотехники, использующие концентрацию сознания и дыхание: «Абдоминальное дыхание», «Концентрация на

второй чакре», «Кокон», «Дыхание в мозг», «Великая очищающая мантра», «Дыхание с помощью программного приложения Every Day» и другие.

На первом и третьем этапах функциональное состояние организма испытуемых оценивалось методами функциональной диагностики: 1 – с помощью аппаратно-программного комплекса (АПК) SilverStep Pulse методом, основанным на анализе вариабельности сердечного ритма, 2 – с помощью АПК Testo 885-2 методом, основанным на анализе изменения радиационной температуры поверхности тела. Экспериментальные данные обрабатывались с помощью табличного процессора Microsoft Excel.

Анализ влияния психотехник на активность головного мозга

Из всех показателей функционального состояния организма, определяемых АПК SilverStep Pulse, выбраны показатели активности мозга: дельта-, тета-, альфа-, бета-, гамма-ритмов. На Рис.1, Рис.2 продемонстрировано влияние психотехник «Кокон» и «Великая очищающая мантра», в результате которых показатели интенсивности альфа-, бета- и гамма-ритмов возросли у большинства испытуемых. Красным цветом показана доля испытуемых (в процентах), у которых активность ритма возросла, а синим – уменьшилась. Различие между красным и синим значениями более чем на 15% считается значимым.




Рис.1. Изменение ритмов мозга после психотехники «Кокон».

Альфа-ритм характеризует способность к абстрактному мышлению, сосредотачиваться на решении умственной проблемы. Увеличение бета активности характеризует эффективность работы мозга, способность к усвоению и обработке информации. Гамма-ритм характеризует способность к концентрации, к решению задач, требующих максимального сосредоточения внимания. Гамма волны отражают быстрые процессы в сознании, переход информации из кратковременной в долговременную

память. Активизация альфа-, бета- и гамма- ритмов характеризует повышение познавательных способностей за счет активизации когнитивных функций.




Рис.2. Изменение ритмов мозга после «Великой очищающей мантры».

После выполнения психотехники «Абдоминальное дыхание» увеличился показатель альфа-ритма у 73%, бета-ритма у 64% испытуемых, а уменьшился показатель дельта-ритма у 79%, тета-ритма у 67%, гамма-ритма у 67% испытуемых. После выполнения психотехники «Дыхание в мозг» увеличился показатель бета-ритма у 70%, гамма-ритма у 70%, а уменьшился показатель дельта-ритма у 59% испытуемых. Активизация бета- и гамма- ритмов характерна для напряженной умственной работы, требующей внимания, концентрации, эмоционального возбуждения. Психотехника «Дыхание с помощью Every Day» привела к уменьшению показателя дельта-ритма у 81% и тета-ритма у 71% испытуемых. Эта психотехника подходит для отдыха и релаксации. Психотехника «Концентрация на второй чакре» не дала преимущественного повышения активности ритмов у большинства испытуемых.

Анализ влияния психотехник на изменение температуры лица

При изменении функционального состояния органов и систем организма человека происходит изменение интенсивности инфракрасного излучения поверхности тела, обусловленное изменением интенсивности микроциркуляции кровотока и окислительных процессов в областях биологически активных точек, рефлекторно-сегментарно связанных с исследуемыми органами и системами. Таким образом, изменение радиационной температуры поверхности тела в результате сеансов саморегуляции характеризует изменение энергетического баланса организма [10].

На Рис.3, Рис.4 продемонстрированы результаты анализа изменения радиационной температуры в результате сеансов саморегуляции с применением психотехник «Кокон» и «Великая очищающая мантра». Выбраны четыре области на лице: глаза, нос, губы, в которых по термограмме определялась максимальная температура. Красным цветом показана доля испытуемых (в процентах), у которых

температура в выбранных областях возросла, а синим – уменьшилась. Значимым считаем различие между красным и синим значениями более 15%.




Рис.3. Изменение температуры после психотехники «Кокон».

Психотехники «Кокон» и «Великая очищающая мантра» вызвали повышение температуры во всех исследуемых областях лица у большинства испытуемых, что может быть следствием активизации энергоинформационного обмена мозга. Психотехники «Абдоминальное дыхание» и «Дыхание в мозг» не привели к преобладающему повышению температуры лица во всех областях, что свидетельствует о меньших затратах энергетических ресурсов испытуемых. Следует отметить повышение температуры в области губ после «Абдоминального дыхания». После психотехники «Дыхание в мозг» у большинства испытуемых температура в области глаз, носа и губ уменьшилась.

Результаты воздействия сеансов саморегуляции на функциональное состояние организма зависят от физиологических и психологических особенностей испытуемых, от их подготовленности к выполнению психотехник. Испытуемые не проходили специальной подготовки по концентрации сознания.

Заключение

Саморегуляция как методика управления своим психофизиологическим состоянием может достигаться посредством воздействия индивида на самого себя при помощи слов - аффирмаций, мыслеобразов, регулирования мышечного тонуса и дыхания. В процессе сеансов саморегуляции происходят целенаправленные трансформации отдельных функций психики и нервно-психических реакций. Эти процессы реализуются через специфические взаимодействия подкорковых и префронтальных отделов коры головного мозга, что направляет деятельность организма на решение функциональных задач. Результатами саморегуляции являются устранение

эмоционального напряжения, снятие утомления, активизация способностей и другие эффекты.




Рис.4. Изменение температуры после «Великой очищающей мантры».

Полученные результаты показывают, что использование психотехник, основанных на воздействии сознания на энергоинформационный обмен в организме, активизирует работу мозга, чем повышает познавательные способности субъекта. Повышение интенсивности альфа-, бета- и гамма-ритмов у большинства испытуемых достигнуто с помощью психотехник «Кокон» и «Великая очищающая мантра». Активизация энергоинформационного обмена мозга в этом случае подтверждается повышением температуры лица. Психотехники «Абдоминальное дыхание» и «Дыхание в мозг» не привели к повышению температуры во всех областях лица, поэтому считаем их менее энергозатратными. Психотехнику «Дыхание с помощью Every Day» можно использовать для отдыха и релаксации.

Список литературы

1. Леонова А.Б. Психологические технологии управления состоянием человека / А.Б. Леонова, А.С. Кузнецова. — М.: НПФ «Смысл». — 2015. — 380 с.
2. Павлов И.П. Поли. собр. соч.: В 6 т., Т. 2, кн. 2 / И.П.Павлов. — М.-Л.: Издательство АН СССР. — 1951. — 592 с.
3. Анохин П.К. Очерки по физиологии функциональных систем / П.К. Анохин. — М.: Медицина. — 1975. — 448 с.
4. Данилова Н.Н. Физиология высшей нервной деятельности / Н.Н. Данилова, А.Л. Крылова. — Ростов н/Д: «Феникс». — 2005. — 478 с.
5. Богатов Н.М. Исследование процессов саморегуляции организма тепловизионным методом / Н.М. Богатов, А.Н. Богатова, С.А. Сухих // Нейроинформатика, её приложения и анализ данных: Материалы XXIV Всероссийского семинара, 30

- сентября – 2 октября 2016 г. Красноярск. — Красноярск: Институт вычислительного моделирования СО РАН. — 2016. — С.9 – 12.
6. Богатов Н.М. Влияние техник саморегуляции на показатели здоровья студентов / Н.М. Богатов, А.Н. Богатова, В.С. Лахин, С.А. Сухих // Нейроинформатика, её приложения и анализ данных: Материалы XXV Всероссийского семинара, 29 сентября – 1 октября 2017 г. Красноярск. — Красноярск: Институт вычислительного моделирования СО РАН. — 2017. — С.27 – 30.
 7. Богатов Н.М. Влияние психотехник на саморегуляцию функционального состояния человека / Н.М. Богатов, А.Н. Богатова, С.А. Сухих // Коллективная монография. Выпуск 5. Современные проблемы физики, биофизики и инфокоммуникационных технологий. — Краснодар: ЦНТИ. — 2016. — С.5 – 16.
 8. Богатов Н.М. Снижение напряжения функциональных систем организма с помощью саморегуляции / Н.М. Богатов, А.Н. Богатова, С.А. Сухих, В.В. Филимонов // Нейроинформатика, её приложения и анализ данных: Материалы XXVI Всероссийского семинара, 28 сентября – 30 сентября 2018 г. Красноярск. — Красноярск: Институт вычислительного моделирования СО РАН. — 2018. — С.16 – 22.
 9. Sukhih S.A. Psychophysiological self-regulation in subject's bioenergetic safety / S.A. Sukhih, A.N. Bogatova, N.M. Bogatov // Приоритетные научные направления в XXI веке (том 5). Материалы Международной научно-практической конференции, 5 октября 2016 года г. Прага, Чехия. — Прага: Vydavatel «Osviceni», Нефтекамск: РИО НИЦ «Мир науки». — 2016. — С.46 – 53.
 10. Богатов Н.М. Определение состояния биологически активных точек тепловизионным методом / Н.М. Богатов, А.Н. Богатова, С.А. Сухих // Коллективная монография. Выпуск 8. Современные проблемы физики, биофизики и инфокоммуникационных технологий. — Краснодар: ЦНТИ. — 2019. — С.122 – 134.
 11. Bogatov N.M. Influence of organism regulation process on the condition of biologically active points / N.M. Bogatov, A.N. Bogatova, L.R. Grigoryan, M.S. Kovalenko, A.S. Sinitsyn, S.A. Sukhih // Medical Research Archives. — 2020. — V.8. — I.7. — P.1 – 15.
 12. Богатов Н.М. Анализ влияния психотехник на особенности энергоинформационного обмена организма / Н.М. Богатов, А.Н. Богатова, Н.М. Ерохин, А.А. Носаль, С.А. Сухих, М.О. Херсонец, Д.А. Щетинин // Коллективная монография. Выпуск 10. Современные проблемы физики, биофизики и инфокоммуникационных технологий. — Краснодар: ЦНТИ. — 2021. — С.68 – 80.

МОДЕЛИРОВАНИЕ РАСЧЕТА ПОЖАРНЫХ РИСКОВ ЭЛЕКТРОУСТАНОВОК АГРАРНО-ПРОМЫШЛЕННОГО КОМПЛЕКСА

М.А. Габова

Алтайский государственный технический университет им. И.И.Ползунова,
gabova_ma@mail.ru

Значительное число пожаров на производственных объектах аграрно-промышленного комплекса происходит по причинам, связанным с нарушением правил устройства и эксплуатации электрооборудования, согласно [1] их количество увеличилось с 2019 года на 4,6% и составило 51 930 пожаров.

Исследование пожарных ситуаций в электроустановках, анализ и прогнозирование риска возникновения пожара продолжает оставаться значимой социальной задачей. При анализе риска пожара R_f , предлагается использовать различные его трактовки, среди которых наиболее целесообразным будет рассмотрение его в форме человеко-машинной системы «Человек-Электроустановка-Среда» [2], принимая что каждый из критериев оказывает влияние на итоговое значение пожарного риска.

Основываясь на [3] была доработана система критериев оценки пожарного риска электроустановок, в которую вошли 42 показателя, разделенные на 3 рискообразующих компонента: Человек, Электроустановка, Среда. Показатели представлены в таблице 1.

Таблица 1
Критерии оценки пожарного риска электроустановок

Компонента «Человек»	Компонента «Электроустановка»	Компонента «Среда»
1. Физические данные 2. Состояние здоровья 3. Возраст 4. Психэмоциональное состояние 5. Самообладание в экстремальных ситуациях 6. Способность к принятию самостоятельных решений 7. Бдительность на рабочем месте 8. Знание и выполнение должностных инструкций 9. Фиксирование технологических нарушений	1. Степень износа токопроводящих элементов 2. Степень износа изоляционных элементов 3. Степень износа конструктивных элементов 4. Функциональная (частичная) отказоустойчивость электрической сети, электропроводки 5. Функциональная (частичная) отказоустойчивость технологического оборудования	1. Частота возникновения пожаров 2. Степень опасности последствий пожаров 3. Уровень профилактических мероприятий и диагностики пожарной опасности 4. Перепады температур 5. Уровень влажности

10. Выполнение должностных обязанностей в соответствии с должностными инструкциями 11. Качество и периодичность инструктажа 12. Наличие профильного образования 13. Опыт и стаж работы Повышение квалификации	6. Функциональная (частичная) отказоустойчивость щитов управления, КИПиА, коммутационной аппаратуры 7. Структурная отказоустойчивость электрической сети, электропроводки 8. Структурная отказоустойчивость технологического оборудования 9. Структурная отказоустойчивость щитов управления, КИПиА, коммутационной аппаратуры 10. Количество потенциально опасных для персонала зон 11. Возможность вынужденного или случайного нахождения в опасной зоне 12. Длительность вынужденного нахождения в опасных зонах 13. Эффективность активных средств электрической защиты Эффективность пассивных средств электрической защиты	6. Наличие биологических организмов 7. Соблюдение ГОСТов, требований МЭК 8. Уровень соответствия нормативно-техническим и санитарным нормам 9. Соблюдение законодательства 10. Экономическая стабильность предприятия 11. Достаточность финансирования 12. Наличие системы планирования и контроля 13. Внедрение нового оборудования 14. Ведение НИОКР
---	--	--

Анализ пожарной безопасности электроустановок должен проводиться в рамках отдельной отрасли (в нашем случае это агропромышленный комплекс), потому как в различных отраслях и даже специализациях одни и те же факторы имеют разное значение, соответственно различные веса, правила и интерпретации.

Результирующий фактор можно описать как функцию от нескольких переменных:

$$R^F = F^y(R_h, R_{EI}, R_E),$$

где показатель R_h - Человек, R_{EI} - Электроустановка, R_E - Среда.

Диапазон значений критериев определялся экспертами согласно концепции приемлемого риска [4], в соответствии с которой индивидуальный пожарный риск R_f должен составлять не более $1 \cdot 10^{-6}$. Было выделено три группы рисков, приемлемый риск ($[<=1 \cdot (10^{-6})]$), допустимый ($[1 \cdot (10^{-4}-10^{-5})]$), неприемлемый ($[1 \cdot (10^{-2}-10^{-3})]$). Каждому из них было поставлено в соответствие значение 1 – неприемлемый риск, 2 – допустимый, 3 – неприемлемый. После чего эксперт проставлял обобщенную оценку пожарной безопасности каждой электроустановки.

В качестве метода расчета было принято решение использовать нейронные сети, так как они позволяют эффективно решать задачи при неявных закономерностях.

На основе этих данных была сформирована обучающая выборка, состоящая из 42 входных параметров, характеризующих 31 электроустановку предприятия агропромышленного комплекса Алтайского края. Количество входных параметров составило 42 показателя, для качественного обучения нейросети нужно более 1000 обучающих примеров, получение такого количества данных об электроустановках одного предприятия агропромышленного комплекса является крайне трудоемкой задачей, в связи с чем принято решение использовать методы, которые позволяют сократить мощность базы до приемлемого количества критериев.

Одним из классических методов математической статистики является коэффициент корреляции. Для определения уровня значимости входных параметров были рассчитаны коэффициенты корреляции между входными параметрами и выходным. Наибольшее значение коэффициента корреляции по модулю у входов, приведенных в таблице 2.

Таблица 2

Коэффициенты корреляции показателей с наибольшим значением

Показатель	Коэффициент корреляции	Название параметра
x33	0.479564	3.1.2.2. «Уровень влажности»
x21	0.482243	2.2.2.1 «Структурный (полный) отказ» «Электрическая сеть, электропроводка»
x7	0.484178	1.2.4. Бдительность на рабочем месте
x9	0.487510	1.3.2. Фиксирование технологических нарушений
x18	0.574705	2.2.1.1. «Функциональный (частичный) отказ» «Электрическая сеть, электропроводка»

Из 42 показателей были выбраны 5 самых значимых параметров, имеющих наибольшую корреляцию с результирующим значением.

Далее было проведено несколько экспериментов по обучению нейронных сетей и определению класса риска электрооборудования путем последовательного добавления входных параметров к обучающей выборке, начиная с наиболее значимых, и заканчивая менее значимыми. Результаты оценки ошибок при различных вариациях входных параметров представлены в таблице 3

Таблица 3

Значение средних ошибок при различных наборах входных параметров

Набор входных параметров	Обучающие		Тестовые		Средняя ошибка на обучающем и тестовом множествах
	Среднее	Макс.	Среднее	Макс.	
x18	0,05	0,30	0,34	0,56	0,19
x18 x9	0,02	0,08	0,02	0,04	0,02
x18 x9 x7	0,01	0,07	0,01	0,01	0,01
x18 x9 x7 x21	0,01	0,07	0,10	0,17	0,05
x18 x9 x7 x21 x33	0,01	0,07	0,08	0,16	0,05

Наименьшее значение средней ошибки на обучающем и тестовом множествах получилось при наборе параметров x18, x9, X7, следовательно, в итоге можно сказать, что самыми значимыми факторами являются:

2.2.1.1. «Функциональный (частичный) отказ» «Электрическая сеть, электропроводка»

1.3.2. Фиксирование технологических нарушений

1.2.4. Бдительность на рабочем месте

Средняя ошибка 0,01 свидетельствует о достаточной адекватности модели оценки класса риска электрооборудования.

Для сравнения и выбора методики, дающей наиболее оптимальные результаты, рассмотрим применение метода главных компонент.

С его применением для той же выборки входных данных, характеризующей электроустановки предприятия аграрно-промышленного комплекса были рассчитаны главные компоненты в количестве 2-10 шт.

На основе полученных данных было проведено несколько экспериментов по обучению нейронных сетей и определению класса риска электрооборудования путем обучения нейронной сети на выборках, входными параметрами которых являлись 2, 3...10 главных компонент, а выходным результирующее значение.

Результаты обучения представлены в таблице 4.

Таблица 4

Значения ошибок обучения нейросети по выборке, сформированной на основе метода главных компонент

Количество входных главных компонент	Обучающие		Тестовые		Среднеарифметическое значение ошибки на обучающем и тестовом множествах
	Среднее	Макс.	Среднее	Макс.	
2	0,008	0,083	0,076	0,118	0,042
3	0,006	0,099	0,059	0,115	0,032

4	0,005	0,096	0,052	0,101	0,028
5	0,002	0,039	0,065	0,092	0,033
6	0,003	0,047	0,036	0,039	0,019
7	0,003	0,066	0,084	0,105	0,044
8	1,472	2,612	0,228	0,438	0,850
9	4,033	9,102	0,364	0,424	2,198
10	3,939	8,430	0,377	0,424	2,181

Оставляя результирующую функцию неизменной, было проведено обучение нейронной сети для каждого из вновь сгенерированных наборов компонент.

Как видно из таблицы 2, наименьшие значения ошибок на обучающей и тестовой выборках получились при использовании 5 главных компонент.

Сравнение наименьших значений обучающей и тестовой ошибок методов корреляции и главных компонент показывает незначительное отличие, однако то, что метод главных компонент позволяет в расчетах принимать во внимание все исходные параметры, делает его более предпочтительным для применения. Так как, учитывая неопределенность, в условиях которой ведутся расчеты, более предпочтительным является возможное ложно-положительное срабатывание системы, чем пропуск события, который может повлечь за собой пожароопасную ситуацию.

Список литературы

1. Государственный доклад «О состоянии защиты населения и территорий Российской Федерации от чрезвычайных ситуаций природного и техногенного характера в 2020 году» / - М.: МЧС России. ФГБУ ВНИИ ГОЧС (ФЦ), 2021, 264 с.
2. Теория и практика управления техногенными рисками: учеб. пособие для студ. высш. учеб. заведений / О. К. Никольский, Н. П. Воробьев, Т. В. Еремина, А. Ф. Костюков, А. Ф. Калинин, А. Н. Тушев. Барнаул: Изд-во АлтГТУ, 2015. 219 с.
3. Никольский О. К., Шлионская Ю. Д., Шаныгин И. А. Моделирование техногенных рисков электроустановок производственных объектов на основе анализа человеко-машинных систем // Электротехника. 2018. № 12. С. 37–44.
4. О пожарной безопасности: федеральный закон от 21.12.1994 № 69 (ред. от 22.12.2020).
5. Габова М.А., Никольский О.К. Оценка пожарных рисков электроустановок АПК на основе нейронных сетей//Высокопроизводительные вычислительные системы и технологии. 2021 т. 5, №1. С. 217-221

ОСЛОЖНЕНИЯ ИНФАРКТА МИОКАРДА: ОЦЕНКА ЗНАЧИМОСТИ ВХОДНЫХ ПАРАМЕТРОВ ПРИ ПРОГНОЗИРОВАНИИ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

С.Е. Головенкин¹, С.Ю. Никулина¹, Ю.В. Орлова¹, Е.Ю. Пелипецкая¹, Т.Д.
Верещагина¹, М. Г. Доррер²

¹Красноярский государственный медицинский университет имени профессора
В.Ф.Войно-Ясенецкого
gse2008@mail.ru

²Сибирский государственный университет науки и технологий им. М.Ф. Решетнева,
dorrer_mg@sibsau.ru

Введение

Сердечно-сосудистые заболевания являются ведущей причиной смерти в большинстве экономически развитых стран мира [1]. Примерно половина из них – обусловлена ишемической болезнью сердца. Инфаркт миокарда – наиболее грозное проявление ИБС нередко приводящее к летальному исходу. В связи с этим во всем мире постоянно совершенствуются методы оказания помощи этой категории больных. Важнейшими направлениями в этой работе является прогнозирование течения инфаркта миокарда, совершенствование первичной профилактики, улучшение медикаментозного лечения, внедрение в работу высокотехнологичных методов оказания помощи [2], [3], [4]. При прогнозировании, как правило, используется накопленная ранее информация о течении заболевания, сконцентрированная в электронной таблице – базе данных. В базе данных содержится информация о возрасте, поле пациента, локализации и глубине инфаркта миокарда, наличии в анамнезе ишемической болезни сердца, нарушениях ритма и проводимости, артериальной гипертензии и некоторой другой патологии. Кроме того включена информация об электролитном и ферментном составе крови, данных электрокардиограммы, а также особенностях клиники в первые часы заболевания. Это, так называемые входные параметры, характеризующие течение патологического процесса. Кроме того, есть и выходные параметры – информация о наличии или отсутствии осложнений во время течения заболевания. Выявление значимости входных параметров позволяет их минимизировать и создать сбалансированный набор признаков, позволяющий прогнозировать течение заболевания. Поэтому совершенствование методов, позволяющих выявлять значимость входных параметров базы данных, является крайне актуальной задачей.

Связанные работы

Попытки применения нейронных сетей для предсказания хода течения и последствий сердечно-сосудистых заболеваний предпринимаются начиная с начала 90-х годов (А. Zelicoff [5], D. Rossiev et al. [6], A. Gorban et al. [7]).

Важные предложения по выявлению и интерпретации значимых связей нейронных сетей были предложены в работе Mirkes et al. [8].

Подобные задачи решались в работе [9] для глубоких нейронных сетей.

В работе [10] Chen et al. выполняли анализ чувствительности для уменьшения дублирования функций в обучении ИНС.

В работе [11] предлагается использовать нейронные сети для формирования локальных моделей пониженной размерности.

Laksana et al. в работе [12] решали задачу определения степени влияния входных параметров нейронных сетей на качество прогнозирования клинических исходов.

Авторы данной статьи также предпринимали попытку оценить влияние исключения разреженных столбцов входных данных на качество прогноза осложнений инфаркта миокарда в работах [13], [14].

Применяемые методы исследования и экспериментальные данные

В качестве экспериментальных данных, использующихся для обучения искусственной нейронной сети, в данной работе взята база данных осложнений инфаркта миокарда [15].

Оценку важности входных параметров предполагалось осуществлять на базе программных моделей искусственных нейронных сетей с варьированием набора входных сигналов и сравнительной оценкой значений качества диагностики для каждой из анализируемых архитектур.

Исследуемые архитектуры нейронных сетей моделировались с использованием языка программирования Python и нейросетевой библиотеки Keras [16], представляющей собой надстройку над фреймворком TensorFlow [17].

Используется модель нейронной сети Sequential, полносвязные слои Dense и вспомогательные слои Dropout [18] и BatchNormalization [19].

Примерная архитектура сети, показанная при помощи функции model.summary() показана на рис. 1.

Layer (type)	Output Shape	Param #
=====		
dense_01 (Dense)	(None, 64)	5952
batch_normalization_01 (Batch Normalization)	(None, 64)	256
dropout_01 (Dropout)	(None, 64)	0
dense_02 (Dense)	(None, 32)	2080
batch_normalization_02 (Batch Normalization)	(None, 32)	128
dropout_02 (Dropout)	(None, 32)	0
dense_03 (Dense)	(None, 16)	528
batch_normalization_03 (Batch Normalization)	(None, 16)	64
dropout_03 (Dropout)	(None, 16)	0

dense_04 (Dense) (None, 1) 17

=====
Total params: 9,025

Trainable params: 8,801

Non-trainable params: 224

Рис 1. Пример архитектуры нейронной сети, используемой для прогноза.

С целью повышения эффективности использования данных используемой базы данных обучение производилось методом «скользящего окна». Данный метод заключается в исключении из обучающей выборки лишь одного примера исходной базы данных и тестировании обученной нейронной сети на исключенном примере. Таким образом, для одного сеанса необходимо обучение числа нейронных сетей, равного числу примеров обучающей выборки.

Качество предсказания нейросетью последствий инфаркта миокарда оценивалось стандартными показателями, предназначенными для оценки эффективности диагностических методик [20] – общая точность предсказания (accuracy), точность (precision), полнота (recall), специфичность (TNR-ratio).

Алгоритмы исключения избыточных столбцов данных

В данной работе мы будем рассматривать 2 метода снижения размерности пространства входных признаков. Для каждого из методов будет проводится усредненная оценка показателей качества предсказания на всей выборке методом скользящего окна.

1. Выделение наименее значимых входов по весам синапсов нейронов первого слоя. В этом случае сначала производится обучение нейронной сети по полной выборке, а затем рассчитывается сумма модулей весов синапсов между каждым входным сигналом и нейронами первого слоя нейронной сети. Предполагается, что сигналы с меньшими значениями весов менее значимы для результата.
2. Выделение наименее значимых входов по разреженности исходных данных. В этом случае для каждого столбца входных данных подсчитывается количество ненулевых сигналов. Предполагается, что сигналы с наименьшим количеством ненулевых значений менее значимы для результата.

Полученные результаты

В таблице 1 приведены метрики качества диагностики для соответствующих экспериментов.

Таблица 1

Исключение входов с минимальной суммой модулей весов синапсов.

№№	Количество оставшихся наиболее значимых входных сигналов	Метрика		
		Accuracy	Precision	Recall
1.	115	90,19%	7,92%	8,02%
2.	104	81,24%	4,50%	12,59%

3.	93	81,67%	9,27%	28,02%
4.	82	86,16%	5,39%	9,75%
5.	71	75,68%	5,88%	23,95%
6.	60	78,92%	3,70%	11,91%
7.	49	75,21%	6,27%	26,42%
8.	38	60,89%	5,26%	37,53%
9.	27	85,25%	12,99%	31,36%

Динамику показателей с исключением выходных сигналов можно видеть на диаграмме, представленной на рис. 2




Рис 2. Изменение метрик точности с исключением сигналов с минимальной суммой модулей весов синапсов.

Таблица 2

Исключение наиболее разреженных входов.

№№	Количество оставшихся наиболее значимых входных сигналов	Метрика		
		Accuracy	Precision	Recall
1.	115	93,95%	6,06%	0,99%
2.	104	85,06%	4,07%	8,09%
3.	93	75,39%	4,00%	15,86%
4.	82	85,83%	5,21%	9,75%
5.	71	72,87%	4,38%	19,81%
6.	60	84,71%	4,44%	9,20%
7.	49	88,99%	10,67%	14,63%
8.	38	90,27%	7,35%	7,22%
9.	27	93,58%	6,78%	1,67%




Рис 3. Изменение метрик точности с исключением наиболее разреженных сигналов.

Обсуждение и выводы

Наилучшее сочетание показателей accuracy и precision в соответствии с таблицей 1 показала сеть, обучающаяся на основе базы данных [15], в которой был сохранен набор входных сигналов, показанный в табл.3. Следует отметить, что по показателю точности (precision) эта сеть дает более точные прогнозы, чем сеть, обученная на полном наборе данных.

Таблица 3

Набор входных сигналов, обеспечивший наилучшее сочетание метрик диагностики.

ID	Наименование поля данных	Описание поля данных
13	nr_11	Нарушения ритма в анамнезе, не уточнено какие именно
22	nr_05	Блокада передней ветви левой ножки пучка Гиса в анамнезе
24	nr_08	Полная блокада левой ножки пучка Гиса в анамнезе
25	nr_09	Неполная блокада правой ножки пучка Гиса в анамнезе
29	endocr_03	Тиреотоксикоз в анамнезе
30	zab_leg_01	Хронический бронхит в анамнезе
31	zab_leg_02	Обструктивный хронический бронхит в анамнезе
32	zab_leg_03	Бронхиальная астма в анамнезе
43	GT_POST	Пароксизм желудочковой тахикардии в момент поступления в ОРИТ, (или на догоспитальном этапе)
48	post_im	Наличие инфаркта задней стенки левого желудочка
52	ritm_ecg_p_04	Ритм по ЭКГ при поступлении - предсердный
55	ritm_ecg_p_08	Ритм по ЭКГ при поступлении - синусовый с ЧСС менее 60 в мин.
61	n_r_ecg_p_06	Постоянная форма фибрилляции предсердий на ЭКГ при поступлении

70	n_p_ecg_p_07	Блокада передней ветви левой ножки пучка Гиса на ЭКГ при поступлении
75	n_p_ecg_p_12	Полная блокада правой ножки пучка Гиса на ЭКГ при поступлении
76	fibr_ter_01	Проведение фибринолитической терапии целиазой 750 тыс. ЕД
84	K_BLOOD	Содержание калия в сыворотке крови
89	KFK_BLOOD	Содержание КФК в крови
95	TEMPER_3_n	Температура тела на третьи сутки госпитального периода
97	R_AB_2_n	Рецидивирование ангинозных болей во вторые сутки госпитального периода
98	R_AB_3_n	Рецидивирование ангинозных болей в третьи сутки госпитального периода
99	NA_KB	Применение наркотических анальгетиков кардиобригадой
102	NITR_S	Применение жидких нитратов в ОРИТ
104	NA_R_2_n	Применение наркотических анальгетиков в ОРИТ во вторые сутки госпитального периода
105	NA_R_3_n	Применение наркотических анальгетиков в ОРИТ в третьи сутки госпитального периода
107	NOT_NA_2_n	Применение ненаркотических анальгетиков в ОРИТ во вторые сутки госпитального периода
110	B_BLOK_S_n	Применение бета-блокаторов в ОРИТ

Полученные результаты подбора минимально эффективного набора входных сигналов для прогнозирования осложнений инфаркта миокарда (таблицы 1, 2) показывают, что часть сетей показали более высокие показатели общей точности (accuracy) и точности (precision), отличие от худших образцов составило почти 20% для первого показателя и 8,5% для второго показателя, однако графики изменения показателей не позволяют выявить устойчивой тенденции их изменения.

Перспективы дальнейшей работы заключаются в следующем:

- Следует детализировать оценку значимости параметров сетей, перейдя от усредненных метрик диагностики по всем диагнозам к оценке значимости входных сигналов для метрик качества диагностики по каждому из диагнозов в базе данных [15]
- Для более точного выявления набора входных признаков необходимо применить более избирательные методы снижения размерности пространства входных сигналов, например, метод главных компонент, линейный дискриминантный анализ и автокодировщики (autoencoders).

Список литературы

1. Townsend N. et al. Cardiovascular disease in Europe: epidemiological update 2016 // Eur. Heart J. 2016. Vol. 37, № 42. P. 3232–3245.
2. The Demographic Yearbook of Russia. 2015: Statistical Handbook. Moscow: Rosstat, 2015.

3. Boytsov, S. Samorodskaya, I. Starinskaya, M. Semenov, V. Kakorina E. Analysis of structure and dynamics of indicators of mortality from cardiovascular diseases in Russia in 2006 and 2014 // *Russ. J. Prev. Med.* 2016. Vol. 19 (2). P. 11–12.
4. Boytsov, S. Deev, A. Shalnova S. Mortality and risk factors for non-communicable diseases in Russia: Specific features, trends, and prognosis // *Ter. Arkh.* 2017. Vol. 89, № 1. P. 5–13.
5. Zelicoff A.P. Myocardial infarction prediction by artificial neural networks. // *Annals of internal medicine.* United States, 1992. Vol. 116, № 8. P. 701; author reply 702.
6. Rossiev D.A. et al. Neural networks for forecasting of myocardial infarction complications // *The Second International Symposium on Neuroinformatics and Neurocomputers.* IEEE. P. 292–298.
7. Gorban A.N. et al. Medical, psychological and physiological applications of MultiNeuron neural simulator // *International RNNS/IEEE Symposium on Neuroinformatics and Neurocomputers.* 1995.
8. Gorban A., Mirkes E., Tsaregorodtsev V. Generation of explicit knowledge from empirical data through pruning of trainable neural networks. 1999. Vol. 6. P. 4393–4398 vol.6.
9. Montavon G., Samek W., Müller K.-R. Methods for interpreting and understanding deep neural networks // *Digit. Signal Process.* 2018. Vol. 73. P. 1–15.
10. Chen S. et al. Sensitivity analysis to reduce duplicated features in ANN training for district heat demand prediction // *Energy AI.* 2020. Vol. 2. P. 100028.
11. Daniel T. et al. Model order reduction assisted by deep neural networks (ROM-net) // *Adv. Model. Simul. Eng. Sci.* 2020. Vol. 7, № 1. P. 16.
12. Laksana E. et al. The impact of extraneous features on the performance of recurrent neural network models in clinical tasks // *J. Biomed. Inform.* 2020. Vol. 102. P. 103351.
13. Dorrer M.G. et al. Using artificial intelligence to predict the human body's response to cardiovascular disease // *J. Phys. Conf. Ser. {IOP} Publishing,* 2020. Vol. 1679. P. 42012.
14. Golovenkin S.E. et al. Evaluation of the effectiveness of using artificial intelligence to predict the response of the human body to cardiovascular diseases // *J. Phys. Conf. Ser. {IOP} Publishing,* 2020. Vol. 1679. P. 42017.
15. Golovenkin S.E. et al. Myocardial infarction complications Database. University of Leicester, 2020.
16. Keras [Electronic resource]. URL: <https://keras.io/>.
17. TensorFlow [Electronic resource]. URL: <https://www.tensorflow.org/>.
18. Hinton G.E. et al. Improving neural networks by preventing co-adaptation of feature detectors. 2012.
19. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. 2015.
20. Ohsaki M. et al. Confusion-Matrix-Based Kernel Logistic Regression for Imbalanced Data Classification // *IEEE Trans. Knowl. Data Eng.* 2017. Vol. 29, № 9. P. 1806–1819.

ПОДБОР ПРОЦЕДУР ДОПОЛНЕНИЯ ДАННЫХ, АРХИТЕКТУРЫ И АЛГОРИТМА ОБУЧЕНИЯ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ ТЕЧЕНИЯ ИНФАРКТА МИОКАРДА

М. Г. Доррер¹, С.Е. Головенкин², С.Ю. Никулина², Ю.В. Орлова², Е.Ю. Пелипецкая²

¹Сибирский государственный университет науки и технологий им. М.Ф. Решетнева,

dorrer_mg@sibsau.ru

²Красноярский государственный медицинский университет имени профессора

В.Ф.Войно-Ясенецкого

gse2008@mail.ru

Введение

Заболевания сердца и сосудов являются главной причиной смерти в большинстве экономически развитых стран мира. Ежегодно около 17 миллионов человек умирают этой патологией [1]. В России на протяжении нескольких десятилетий сердечно-сосудистые заболевания, также, как и в других странах – основная причина смертности населения (50,1 %). [2], [3], [4]. Это заставляет искать новые подходы к диагностике, лечению, профилактике и реабилитации пациентов с данной патологией. Одним из вариантов решения этой проблемы является совершенствование прогнозирования течения и исходов заболеваний сердца. Наибольший эффект можно получить, совершенствуя прогнозирование течения инфаркта миокарда как наиболее грозного заболевания сердечно-сосудистой системы.

Связанные работы

Зачастую для прогноза течения ИМ используются клинические данные, обработанные с помощью различных математических методов.

А. Peel [5] и R.Norris [6] использовали методы прогнозирования с вычислением прогностических индексов. В работе [7] J.Willems использовал методы дискриминантного анализа.

Вместе с тем, целый ряд проблем, связанных с применением для прогноза течения ИМ классических статистических методов, обусловили интерес к применению для предсказания последствий инфаркта миокарда искусственных нейронных сетей.

В числе авторов, которые занимались решением задачи прогноза последствий инфаркта миокарда с помощью ИНС были А. Zelicoff [8], D. Rossiev et al. [9], А. Gorban et al. [10], А. Borisov et al. [11]. Такие работы продолжаются и в настоящее время такими авторами, как Eggers K. et al. [12], Nag P. et al. [13], N. Strodthoff [14].

Авторы данной работы также неоднократно обращались к теме прогноза последствий инфаркта миокарда при помощи искусственных нейронных сетей [15], [16].

Экспериментальные данные

В качестве исходных данных для обучения нейронной сети использовалась база данных осложнений инфаркта миокарда [17]. Эта база содержит данные историй болезней больных, перенесших инфаркт миокарда с различными осложнениями. База собрана в 1992-1995 гг. в Красноярске и снабжена соответствующим описанием.

Ставилась задача предсказания следующих исходов заболевания, закодированных в полях базы данных [14]:

1. A_V_BLOK – (Third-Degree Atrioventricular Block ECG);
2. DRESSLER – Синдром Дресслера (Dressler syndrome);
3. FIBR_JELUD – Фибрилляция желудочков (Ventricular fibrillation);
4. FIBR_PREDS – Мерцательная аритмия (Atrial fibrillation);
5. JELUD_TAH – Желудочковая тахикардия (Ventricular tachycardia);
6. LET_IS – Смертельный исход (Lethal outcome);
7. OTEK_LANC – Отек легких (Pulmonary edema);
8. P_IM_STEN – Постинфарктная стенокардия (Post-infarction angina);
9. PREDS_TAH – Суправентрикулярная тахикардия (Supraventricular tachycardia);
10. RAZRIV – Разрыв миокарда (Myocardial rupture);
11. REC_IM – Рецидив инфаркта миокарда (Relapse of the myocardial infarction);
12. ZSN – Хроническая сердечная недостаточность (Chronic heart failure).

Поле LET_IS в исходном варианте базы данных [17] кодируется цифрами от 1 до 7 (в зависимости от причины смертельного исхода):

1. кардиогенный шок;
2. отек легких;
3. разрыв миокарда;
4. прогрессирование застойной сердечной недостаточности;
5. тромбоэмболия;
6. асистолия;
7. фибрилляция желудочков.

Для более структурной классификации диагнозов каждый из этих вариантов летального исхода вынесен в отдельный столбец по признаку наличия или отсутствия у пациента соответствующего варианта летального исхода, таким образом вместо поля LET_IS вводятся поля с LET_IS_1 по LET_IS_7.

Применяемые методы исследования

Предсказание диагнозов предполагалось осуществлять при помощи программных моделей искусственных нейронных сетей с варьированием архитектуры по количеству слоев и по количеству нейронов в слоях.

Исследуемые архитектуры нейронных сетей моделировались с использованием языка программирования Python и нейросетевой библиотеки Keras [18]. Keras представляет собой открытую библиотеку, написанная на языке Python и обеспечивающая взаимодействие с искусственными нейронными сетями. Она представляет собой надстройку над фреймворком TensorFlow [19].

Используется модель нейронной сети Sequential, полносвязные слои Dense и вспомогательные слои Dropout и BatchNormalization.

Полносвязный слой Dense реализует операцию: $output = activation(dot(input, kernel) + bias)$, где активация — это функция активации по элементам, переданная в качестве аргумента активации, kernel — это матрица весов, созданная слоем, а bias — это вектор смещения, созданный слоем (применимо только в случае, если use_bias — True).

Слой BatchNormalization обеспечивает повышение производительности и стабильность работы искусственных нейронных сетей за счет того, что некоторым слоям нейронной сети на вход подаются данные, предварительно обработанные и имеющие нулевое математическое ожидание и единичную дисперсию [20].

Слой Dropout применяется в нейронных сетях для решения проблемы переобучения. Для этого он случайным образом выбирает часть нейронов (их доля определяется параметром dropout_rate) и при каждом обновлении обнуляет их значения [21].

Примерная архитектура сети, показанная при помощи функции model.summary() показана на рис. 1.

Layer (type)	Output Shape	Param #
=====		
dense_01 (Dense)	(None, 64)	5952

batch_normalization_01 (Batch Normalization)	(None, 64)	256

dropout_01 (Dropout)	(None, 64)	0

dense_02 (Dense)	(None, 32)	2080

batch_normalization_02 (Batch Normalization)	(None, 32)	128

dropout_02 (Dropout)	(None, 32)	0

dense_03 (Dense)	(None, 16)	528

batch_normalization_03 (Batch Normalization)	(None, 16)	64

dropout_03 (Dropout)	(None, 16)	0

dense_04 (Dense)	(None, 1)	17
=====		
Total params: 9,025		
Trainable params: 8,801		
Non-trainable params: 224		

Рис 1. Пример архитектуры нейронной сети, используемой для прогноза.

Используемые метрики точности диагноза

Как правило, результаты решения проблемы двоичной классификации помечены как положительные и негативные. Эти решения могут быть представлены в матрице ошибок (Confusion Matrix) (рис. 2), которая содержит 4 ячейки [22].

- Истинно-положительные (TP), объекты, которые были классифицированы как положительные и действительно являются положительными (принадлежащими к данному классу);
- Верно-отрицательные (TN) объекты, которые были классифицированы как отрицательные и действительно отрицательные (не принадлежат к данному классу);
- Истинно-положительные (FP) объекты, которые были классифицированы как положительные, но фактически отрицательные;
- Ложно-отрицательные (FN) объекты, которые были классифицированы как отрицательные, но фактически положительные;

Категория i		Экспертная оценка	
		Положительная	Отрицательная
Оценка системы	Положительная	TP	FP
	Отрицательная	FN	TN

Рис 2. Матрица ошибок

На основе матрицы ошибок и её значений, рассчитываются различные метрики классификационной способности алгоритма. Для различных классификационных задач, включая диагностику заболеваний, используются следующие метрики: Общая точность предсказания (accuracy), Точность (precision), Полнота (recall), Специфичность (TNR-ratio).

Общая точность предсказания (accuracy) – отношение всех правильных прогнозов к общему числу всех предсказанных образцов. В ряде задач accuracy может являться неинформативной.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Точность (precision) – доля прогнозируемых положительных результатов, которые являются действительно истинно-положительными результатами для всех положительно предсказанных объектов.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

Полнота (recall) – пропорция всех истинно-положительно предсказанных объектов к общему количеству действительно положительных.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

Этой же формулой оценивается такая метрика, как чувствительность (sensitivity), общее название для этих метрик – True positive rate или TPR (оценка истинно положительных) и Probability of detection (вероятность выявления).

Специфичность (TNR-ratio) – отношение между верно классифицированных негативных экземпляров к числу всех негативных экземпляров.

$$TNR - ratio = \frac{TN}{TN + FP} \quad (4)$$

Постановка диагноза нейросетью определялась следующим образом. Поскольку наличие соответствующего диагноза в истории болезни кодировалось в базе значением «1», а отсутствие диагноза – значением «0», принималось что, если выходной сигнал нейрона превышал значение «0.5», то диагноз считался поставленным, а если не превышал – то принималось, что соответствующий диагноз отсутствует.

Дополнение и балансировка базы данных

С целью повышения эффективности использования данных используемой базы данных обучение производилось методом «скользящего окна». Данный метод заключается в исключении из обучающей выборки лишь одного примера исходной базы данных и тестировании обученной нейронной сети на исключенном примере. Таким образом, для одного сеанса необходимо обучение числа нейронных сетей, равного числу примеров обучающей выборки.

Специфика базы данных [17] заключается в том, что по данные по каждому из диагнозов являются достаточно разреженными – в среднем из 1700 записей в базе данных каждый из диагнозов ставится 90 раз. Такая ситуация существенно затрудняет обучение нейронных сетей с учителем, вызывая эффект «переучивания», когда сеть обучается на наиболее часто встречающийся ответ – отсутствие диагноза. Для преодоления данной проблемы в части экспериментов была применена процедура дополнения данных. Она заключалась в том, что для каждого диагноза выполнялась процедура, показанная на рис. 3 и обеспечивающая для каждого диагноза равное количество строк с наличием и с отсутствием данного диагноза.




Рис 3. Процедура балансировки базы данных для каждого диагноза (BPMN)

При этом очевидно, что использовать непосредственно расширенную выборку не следует из-за того, что в ней будет значительное количество примеров, совпадающих с тестовым. Для того, чтобы решить эту проблему обучение методом скользящего окна производится по процедуре, показанной на рис. 4.




Рис 4. Процедура обучения по методу «скользящего окна» (BPMN)

Процедуры, показанные на рис. 3 и 4 производятся для каждого выходного столбца базы данных [17]. Таким образом, для каждой проверяемой архитектуры нейронной сети формируется матрица размером $[1700 \times 18]$, в которой строки соответствуют прогнозным диагнозам пациентов по строкам базы данных [17].

Применяющиеся архитектуры нейронных сетей

В процессе экспериментов по обучению нейронных сетей производилось постепенное наращивание сложности нейронной сети для получения лучших значений метрик, описанных в соответствующих пунктах.

1. Сеть, предсказывающая диагнозы по одному, состоящая из одного полносвязного слоя в 64 нейрона и одного выходного нейрона, отвечающего за постановку диагнозов. Использована исходная несбалансированная выборка объемом в 1700 записей. Обучение в течении 100 эпох (эксперимент «Dense_64_1_100ep»).
2. Сеть, предсказывающая диагнозы по одному, состоящая из одного полносвязного слоя в 64 нейрона и одного выходного нейрона, отвечающего за постановку диагнозов. Выборка сбалансирована. Обучение в течении 100 эпох (эксперимент «Dense_64_1_augment_100ep»).
3. Сеть, предсказывающая диагнозы по одному, состоящая из двух полносвязных слоев в 64 и 32 нейрона и одного выходного нейрона, отвечающего за постановку диагнозов. Выборка сбалансирована. Обучение в течении 100 эпох (эксперимент «Dense_64_32_1_augment_100ep»).
4. Сеть, предсказывающая диагнозы по одному, состоящая из трех полносвязных слоев в 64, 32 и 16 нейронов и одного выходного нейрона, отвечающего за постановку диагнозов. При этом между скрытыми слоями Dense установлены вспомогательные слои Dropout и BathNormalization. Выборка сбалансирована. Обучение в течении 100 эпох (эксперимент «Dense_64_32_16_DA_BN_augment_100ep»).
5. Сеть, предсказывающая диагнозы по одному, состоящая из трех полносвязных слоев в 64, 32 и 16 нейронов и одного выходного нейрона, отвечающего за постановку диагнозов. При этом между скрытыми слоями Dense установлены вспомогательные слои Dropout и BathNormalization.

Выборка сбалансирована. Обучение в течении 200 эпох (эксперимент «Dense_64_32_16_DA_BN_augment_200ep»).

6. Сеть, предсказывающая диагнозы по одному, состоящая из трех полносвязных слоев в 100, 50, 25 и 12 нейронов и одного выходного нейрона, отвечающего за постановку диагнозов. При этом между скрытыми слоями Dense установлены вспомогательные слои DropOut и BathNormalization. Выборка сбалансирована. Обучение в течении 200 эпох (эксперимент «Dense_100_50_25_12_DA_BN_augment_200ep»).
7. Предиктор, работающий по принципу голосованию консилиума из трех сетей. Архитектура каждой сети – предиктор со скалярным выходом, предсказывающий диагнозы по одному, состоящий из трех полносвязных слоев в 64, 32 и 16 нейронов и одного выходного нейрона, отвечающего за постановку диагнозов. При этом между скрытыми слоями Dense установлены вспомогательные слои DropOut и BathNormalization. Выборка сбалансирована. Обучение в течении 100 эпох (эксперимент «Consilium_Dense_64_32_16_DA_BN_augment_100ep»).
8. Сеть, предсказывающая диагнозы по одному, состоящая из трех полносвязных слоев в 100, 50, 25 и 12 нейронов и одного выходного нейрона, отвечающего за постановку диагнозов. При этом между скрытыми слоями Dense установлены вспомогательные слои DropOut и BathNormalization. Выборка сбалансирована. Обучение в течении 100 эпох. В данных исключены столбцы, содержащие не более 40 ненулевых значений. (эксперимент «Contrast_Dense_64_32_16_DO_BN_augment_100ep»).
9. Предиктор, работающий по принципу голосованию консилиума из трех сетей. Архитектура каждой сети – предиктор со скалярным выходом, предсказывающий диагнозы по одному, состоящий из трех полносвязных слоев в 64, 32 и 16 нейронов и одного выходного нейрона, отвечающего за постановку диагнозов. При этом между скрытыми слоями Dense установлены вспомогательные слои DropOut и BathNormalization. Выборка сбалансирована. Обучение в течении 100 эпох (эксперимент «Contrast_Consilium_Dense_64_DO_BN_augment_100ep»).

Результаты

В таблице 1 приведены метрики качества диагностики для соответствующих экспериментов.

Таблица 1

Сравнительные показатели метрик качества диагностики для экспериментов.

№ №	Эксперимент	Метрика		
		Accurac y	Precisio n	Recall
10.	Dense_64_1_100ep	64,64%	4,35%	0,06%
11.	Dense_64_1_augment_100ep	65,31%	6,13%	38,77%

12.	Dense_64_32_1_augment_100ep	66,21%	5,59%	33,89%
13.	Dense_64_32_16_DO_BN_augment_100ep	72,14%	6,09%	29,57%
14.	Dense_64_32_16_DO_BN_augment_200ep	75,02%	5,86%	24,69%
15.	Dense_100_50_25_12_DO_BN_augment_200ep	74,09%	5,71%	25,12%
16.	Consilium_Dense_64_32_16_DO_BN_augment_100ep	76,65%	5,69%	21,91%
17.	Contrast_Dense_64_32_16_DO_BN_augment_100ep	76,98%	6,54%	25,19%
18.	Contrast_Consilium_Dense_64_DO_BN_augment_100ep	83,94%	5,44%	12,41%

На примере одного из экспериментов рассмотрим детализацию метрик качества диагностики в разрезе диагнозов базы данных

Таблица 2

Качество диагностики по диагнозам на примере эксперимента
Dense_64_32_16_DA_BN_augment_100ep.

Диагноз	Метрики качества диагностики						
	TP	TN	FP	FN	Accuracy	Precision	Recall
FIBR_PREDS	52	1157	373	118	71,12%	12,24%	30,59%
PREDs_TAH	9	1242	438	11	73,59%	2,01%	45,00%
JELUD_TAH	10	1249	409	32	74,06%	2,39%	23,81%
FIBR_JELUD	13	1176	453	58	69,94%	2,79%	18,31%
A_V_BLOK	14	1243	400	43	73,94%	3,38%	24,56%
OTEK_LANC	55	1167	374	104	71,88%	12,82%	34,59%
RAZRIV	17	1233	413	37	73,53%	3,95%	31,48%
DRESSLER	20	1186	439	55	70,94%	4,36%	26,67%
ZSN	126	975	331	268	64,76%	27,57%	31,98%
REC_IM	41	1127	414	118	68,71%	9,01%	25,79%
P_IM_STEN	40	1169	383	108	71,12%	9,46%	27,03%
LET_IS_1	38	1196	394	72	72,59%	8,80%	34,55%
LET_IS_2	6	1271	411	12	75,12%	1,44%	33,33%
LET_IS_3	15	1246	400	39	74,18%	3,61%	27,78%
LET_IS_4	7	1238	439	16	73,24%	1,57%	30,43%
LET_IS_5	3	1249	439	9	73,65%	0,68%	25,00%
LET_IS_6	7	1249	424	20	73,88%	1,62%	25,93%
LET_IS_7	6	1223	450	21	72,29%	1,32%	22,22%
Итого:	479	21596	7384	1141	72,14%	6,09%	29,57%

Обсуждение и выводы

Полученные результаты прогнозирования позволяют утверждать, что искусственная нейронная сеть, обученная на предыдущем клиническом опыте, обладает достаточно высокой прогностической способностью по предсказанию исходов инфаркта миокарда, достигающей 84% общей точности. Таким образом, даже база скромного объема (1700 записей) позволяет обучать нейронные сети, позволяющие достаточно точно прогнозировать исходы заболевания.

Применение процедуры дополнения данных на разреженной выборке обеспечило значимое (почти в полтора раза) увеличение показателя общей точности (precision).

Применение вспомогательных слоев DropOut и BatchNormalization обеспечило рост как точности (accuracy) почти на 6-7%, так и общей точности (precision).

Вместе с тем, следует отметить, что показатели точности (precision) выглядят недостаточно высокими. Причиной этого, как можно предположить, является разреженность данных, недостаточное количество пациентов с наличием данного осложнения. Можно видеть, что чуть менее разреженные столбцы (например, столбец ZSN) предсказываются со значительно более высокой точностью. Следует также отметить, что процедура балансировки выборки репликами существующих записей позволяет решить эту проблему лишь отчасти.

Проверка гипотезы об эффективности исключения разреженных столбцов данных для повышения точности прогноза исхода заболевания в целом подтвердилась. Таблица 1 показывает, что исключение разреженных столбцов (содержащих не более 40 ненулевых значений) позволило поднять общую точность (accuracy) на величину 0,5% и точность (precision) на 1%.

Также эффективным оказалось применение консилиума нейросетей. Таблица 1 показывает, что переход на постановку диагнозом из 3 нейросетей вместо одной нейросети такой же архитектуры позволило поднять общую точность на величину около 1,5%, а консилиум из 5 сетей повысил общую точность еще на 7%.

Исследование архитектуры нейронной сети подтверждает результаты, полученные авторами в работах [15], [16] – достаточным размером сети является – 2 скрытых слоя по 30-60 сигмоидных нейронов, с увеличением размерности улучшения качества прогноза на основе базы данных [17] не происходит ни с ростом числа слоев, ни с ростом числа нейронов в каждом слое.

В целом можно видеть, что все примененные подходы к повышению точности прогнозов дали прирост точности диагноза (accuracy) в общей совокупности более, чем на 19%.

Таким образом, примененный подход к прогнозированию последствий инфаркта миокарда показал в большинстве случаев достаточно высокую общую точность (accuracy) и точность (precision). Следовательно, поставленная задача прогнозирования осложнений инфаркта миокарда искусственными нейронными сетями решена в данной работе успешно. Показано, что точность предсказания повышается за

счет очистки исходной базы данных от сильно разреженных столбцов, а также за счет применения консалиума нейронных сетей, действующих по методу голосования.

Перспективы дальнейшей работы заключаются в следующем:

- В применении для обучения нейросети базы данных более современных, чем использованная в исследовании [17], включающей большее число входных параметров, а также большее число случаев.
- В проверке предположения, что обучающая выборка большего размера позволит обучить и более сложную по архитектуре нейронную сеть, которая, соответственно, будет обладать лучшей прогностической способностью.

Список литературы

1. Global, regional, and national age-sex specific all-cause and cause-specific mortality for 240 causes of death, 1990-2013: a systematic analysis for the Global Burden of Disease Study 2013. // Lancet (London, England). 2015. Vol. 385, № 9963. P. 117–171.
2. Cardiovascular prevention 2017. national guidelines // Russ. J. Cardiol. 2018. Vol. 6. P. 7–122.
3. M. G. Bubnova, O. L. Barbarash, A. A. Doletsky, V. B. Krasnitsky, E. V. Lebedev, N. P. Lyamina, A. N. Repin, A. V. Light, G. A. Chumakov, D. M. Aronov, A. A. Abdullaev, T. P. Arutyunov, O. L. Barbarash, S. A. Boytsov, S. A. Boldueva, Yu. I. Buziashvili, A. S. Galyavich, A. A. Garganeeva, M. Yu. Gerasimenko, S. F. Gulyaeva, P. Ya. Dovgalevsky, A. I. Zhuravlev, V. S. Zadionchenko, V. P. Zaitsev, A. N. Zakirova, G. E. Ivanov, D. G. Iosseliani, A. M. Kalinina, R. S. Karpov, N. A. Kosilov, G. A. Kulikov, V. V. Kuharchuk, K. V. Lyadov, V. P. Mazaev, A. I. Martynov, O. F. Misyura, E. J. Parnes, N. B. Perepech, A. N. Repin, M. Ya. Ruda, I. I. Old Believers, A. B. Smulevich, A. L. Syrkin, S. N. Tereshchenko, I. V. Fomin, E. I. Chazov, I. E. Chazova, S. V. Shlyk, E. V. Shlyakhto, V. A. Shulman Acute st elevation myocardial infarction: aftercare and secondary prevention. national russian guidelines // Russ. J. Cardiol. 2015. Vol. 1. P. 6–52.
4. The Demographic Yearbook of Russia. 2015: Statistical Handbook. Moscow: Rosstat, 2015.
5. Peel A.A.F. et al. A coronary prognostic index for grading the severity of infarction // Heart. 1962. Vol. 24, № 6. P. 745–760.
6. Norris R.M. et al. A new coronary prognostic index // Am. Heart J. 1970. Vol. 79, № 3. P. 428–431.
7. Wlllems J.L., Pardaens J., De Geest H. Early risk stratification using clinical findings in patients with acute myocardial infarction // Eur. Heart J. 1984. Vol. 5, № 2. P. 130–139.
8. Zelicoff A.P. Myocardial infarction prediction by artificial neural networks. // Annals of internal medicine. United States, 1992. Vol. 116, № 8. P. 701; author reply 702.

9. Rossiev D.A. et al. Neural networks for forecasting of myocardial infarction complications // The Second International Symposium on Neuroinformatics and Neurocomputers. IEEE. P. 292–298.
10. Gorban A.N. et al. Medical, psychological and physiological applications of MultiNeuron neural simulator // International RNNS/IEEE Symposium on Neuroinformatics and Neurocomputers. 1995.
11. Gorban A.N. et al. "Multineuron" Neural Simulator and Its Medical Applications TT -. 대한전자공학회, 1994. Vol. 3, № 1. P. 1261–1264.
12. Eggers K.M. et al. Artificial neural network algorithms for early diagnosis of acute myocardial infarction and prediction of infarct size in chest pain patients // Int. J. Cardiol. 2007. Vol. 114, № 3. P. 366–374.
13. Nag P., Mondal S., More A. A Holistic User Centric Acute Myocardial Infarction Prediction System With Model Evaluation Using Data Mining Techniques // Adv. Sci. Technol. Eng. Syst. J. 2018. Vol. 3, № 6. P. 56–66.
14. Strodthoff N., Strodthoff C. Detecting and interpreting myocardial infarction using fully convolutional neural networks // Physiol. Meas. 2019. Vol. 40, № 1. P. 015001.
15. Dorrer M.G. et al. Using artificial intelligence to predict the human body's response to cardiovascular disease // J. Phys. Conf. Ser. {IOP} Publishing, 2020. Vol. 1679. P. 42012.
16. Golovenkin S.E. et al. Evaluation of the effectiveness of using artificial intelligence to predict the response of the human body to cardiovascular diseases // J. Phys. Conf. Ser. {IOP} Publishing, 2020. Vol. 1679. P. 42017.
17. Golovenkin S.E. et al. Myocardial infarction complications Database. University of Leicester, 2020.
18. Keras [Electronic resource]. URL: <https://keras.io/>.
19. TensorFlow [Electronic resource]. URL: <https://www.tensorflow.org/>.
20. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. 2015.
21. Hinton G.E. et al. Improving neural networks by preventing co-adaptation of feature detectors. 2012.
22. Ohsaki M. et al. Confusion-Matrix-Based Kernel Logistic Regression for Imbalanced Data Classification // IEEE Trans. Knowl. Data Eng. 2017. Vol. 29, № 9. P. 1806–1819.

РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТА ПО ВЫЯВЛЕНИЮ АНОМАЛИЙ В АМПЛИТУДНЫХ СПЕКТРАХ ВИБРАЦИИ С ПОМОЩЬЮ СВЁРТОЧНОЙ НЕЙРОННОЙ СЕТИ

Н.Н. Журухин¹, В.А. Углев²

¹ АО «Информационные спутниковые системы»

им. акад. М.Ф. Решетнёва», siriusov1990@yandex.ru

² Сибирский федеральный университет, uglev-v@yandex.ru

После проведения вибропрочностных испытаний [1] на воздействие синусоидальной вибрацией методом качающейся частоты с получением откликов конструкции объекта испытаний в виде амплитудных спектров вибрации производится выявление аномалий, вызванных средствами измерений. Выявление аномалий осуществляется персоналом визуально, что периодически приводит к их пропускам, соответственно, это может сказываться на адекватности режимов испытаний, а это в свою очередь может привести к превышению предельно допускаемых уровней вибрации на объекте испытаний [2]. Более того, на выявление аномалий персоналом затрачивается много рабочего времени.

Среди существующих методов выявления аномалий [3, 4] был произведён отбор применимых для выявления аномалий в амплитудных спектрах вибрации: метод, использующий правило трёх сигм; статические тесты; модельные тесты; методы обнаружения разладки [3, 5, 6] – все они требуют априорных данных о вибрационном отклике конструкции. В качестве априорных данных о вибрационном отклике конструкции могут выступать только амплитудные спектры вибрации, которых нет до испытаний, и ради получения которых проводятся вибрационные испытания на воздействие синусоидальной вибрации. Поэтому метод, использующий правило трёх сигм, статические тесты, модельные тесты, методы обнаружения разладки не подходят для выявления аномалий в амплитудных спектрах вибрации. По той же причине неприменимы итерационные методы и ансамбли алгоритмов [3]. Метрические методы и методы машинного обучения [3, 7, 8, 9] не требуют априорных данных о вибрационном отклике конструкции. Поэтому мы остановились на методе машинного обучения, в частности, свёрточные нейронные сети.

Нами был сформирован задачник, состоящий из графических изображений поведения спектра в процессе виброиспытаний. Обучение свёрточной нейронной сети произведено на задачнике, в который вошло в качестве обучающей выборки 4000 изображений и в качестве эталонной выборки 500 изображений. Размер изображений формата PNG, использованных для обучения составляет 432x288 пикселей. В задачнике представлено 4 класса амплитудных спектров вибрации, закодированных следующим образом:

- аномалия отсутствует – класс «0»;
- отсутствия полезного сигнала – класс «1»;
- деградация щита коммутации – класс «2»;
- ошибка в соответствии «ось объекта испытаний – ось вибропреобразователя» – класс «3».

Пример из задачника амплитудного спектра вибрации без аномалии представлен на рис. 1, с отсутствием полезного сигнала на рис. 2, с деградацией щита коммутации на рис. 3, с ошибкой в соответствии «ось объекта испытаний – ось вибропреобразователя» на рис. 4.




Рис. 1. Пример класса «0»




Рис. 2. Пример класса «1»




Рис. 3. Пример класса «2»




Рис. 4. Пример класса «3»

Для проведения эксперимента использовалась свёрточная нейронная сеть, состоящая из 10 слоёв, чередующиеся следующим образом:

- двумерный свёрточный слой, состоящий из 16 карт признаков с ядром свёртки размером 3x3. Размер выходных карт признаков слоя составляет 430x286 пикселя.
- двумерный слой подвыборки с размером ядра 2x2. Размер выходных карт признаков слоя составляет 215x143 пикселя.
- двумерный свёрточный слой, состоящий из 32 карт признаков с ядром свёртки

размером 3x3. Размер выходных карт признаков слоя составляет 213x141 пикселя.

- двумерный слой подвыборки с размером ядра 2x2. Размер выходных карт признаков слоя составляет 106x70 пикселя.

- двумерный свёрточный слой, состоящий из 48 карт признаков с ядром свёртки размером 3x3. Размер выходных карт признаков слоя составляет 104x68 пикселя.

- двумерный слой подвыборки с размером ядра 2x2. Размер выходных карт признаков слоя составляет 52x34 пикселя.

- слой выравнивания;

- полносвязный слой, состоящий из 64 нейронов;

- слой регуляризации для отключения нейронов с вероятностью 50%;

- полносвязный слой, состоящий из 4 нейронов, что соответствует количеству классов в задачнике.

Структура свёрточной нейронной сети представлена на рис. 5 с применением IBM Watson Studio Neural Network Modeler [10], включая:

- три двумерных свёрточных слоя, обозначенных как Conv 2D;

- три двумерных слоя подвыборки, обозначенных как Pool 2D;

- слой выравнивания, обозначенный как Flatten;

- два полносвязных слоя, обозначенных как Dense;

- слой регуляризации, обозначенный как Dropout.




Рис. 5. Структура свёрточной нейронной сети

Сама свёрточная нейронная сеть создана с помощью открытой нейросетевой библиотеке Keras [11, 12].

Эксперимент на объектах испытаний был проведён при вибрационных испытаниях на воздействие синусоидальной вибрацией с регистрацией откликов конструкции. Был произведён отбор 500 новых примеров амплитудных спектров вибрации, сформировав тем самым экспериментальную выборку (контрольные данные). К эксперименту для просмотра экспериментальной выборки было привлечено три оператора. Операторы самостоятельно провели просмотр экспериментальной выборки на предмет наличия аномалий в амплитудных спектрах вибрации и произвели отнесение

каждого из них к одному из классов. Также для выявления аномалий в амплитудных спектрах вибрации из экспериментальной выборки была использована свёрточная нейронная сеть. Экспертом предварительно выявлено, что в экспериментальной выборке присутствовало 14 аномалий класса «1», 30 аномалий класса «2», 18 аномалий класса «3». В качестве критериев оценки результатов выбрана точность, полнота, F1 мера. Критерии оценки были рассчитаны по полученным результатам для каждого из операторов и свёрточной нейронной сети после составления матрицы неточностей, включающих число истинно положительных (true positive), истинно отрицательных (true negative), ложноположительных (false positive) и ложноотрицательных (false negative) решений [13, 14].

После обработки результатов эксперимента были получены ложноположительные и ложноотрицательные решения от трёх операторов и от свёрточной нейронной сети (СНС) для классов «1», «2» и «3» (рис. 6.). СНС продемонстрировала наименьшее количество ложноположительных и ложноотрицательных решений.




Рис. 6. Ложноположительные и ложноотрицательные решения операторов и свёрточной нейронной сети

После обработки результатов эксперимента были рассчитаны показатели точности, полноты и F1 меры для трёх операторов и свёрточной нейронной сети по трём классам. Результаты расчёта представлены на рис. 7, 8 и 9 и в таблице 1.




Рис. 7. Критерии оценки результатов для класса «1»




Рис. 8. Критерии оценки результатов для класса «2»




Рис. 9. Критерии оценки результатов для класса «3»

Таблица 1.
Критерии оценки результатов для трёх классов

	Точность	Полнота	F1 мера
Для класса «1»			
Оператор 1	0,900	0,643	0,750
Оператор 2	1,000	0,643	0,783
Оператор 3	1,000	0,786	0,880
СНС	1,000	0,857	0,923
Для класса «2»			
Оператор 1	1,000	0,333	0,500
Оператор 2	0,882	0,500	0,638
Оператор 3	0,947	0,600	0,735
СНС	1,000	0,833	0,909
Для класса «3»			
Оператор 1	1,000	0,778	0,875
Оператор 2	1,000	0,222	0,364
Оператор 3	1,000	0,833	0,909
СНС	1,000	0,944	0,971

Далее были рассчитаны средние значения коэффициентов точности, полноты, F1 меры по трём классам с усреднением для трёх операторов и отдельно для свёрточной нейронной сети, которые приведены в таблице 2.

Таблица 2.
Средние значения коэффициентов

	Среднее значение коэффициента для трёх классов		
	Точность	Полнота	F1 мера
Среднее по операторам	0,970	0,593	0,715
СНС	1,000	0,878	0,935

Анализ затрат времени на выявление аномалий при эксперименте показал, что среднее время, затраченное операторами составило 53 минуты 20 секунд, время работы свёрточной нейронной сети – 20 секунд.

Для сравнения выводов операторов и результатов, полученных от свёрточной нейронной сети, данные были сведены в таблицу с целью построения по ней упругой карты [15] с помощью программы ViDaExpert [16]. В качестве примеров в задачник вошли оператор 1, оператор 2, оператор 3, эксперт (эталонные значения), СНС. В качестве признаков в задачник включены результаты опроса операторов, эталонные ответы и результаты, полученные от свёрточной нейронной сети. Сформированный задачник содержит 15, 31 и 19 признаков для класса «1», «2», «3», соответственно.

Упругая карта в плоском представлении для сравнения мнений по наличию аномалий класса «1», «2» и «3» представлена на рис. 10, 11 и 12 соответственно. Видно, что свёрточная нейронная сеть, показала лучшие результаты по точности, полноте, F1 мере при выявлении аномалий в амплитудных спектрах вибрации. Точность свёрточной нейронной сети оказалась в 1,03 раза выше, чем у людей-операторов. Значение показателя полноты свёрточной нейронной сети в 1,48 раза выше, чем у операторов. Значение показателя F1 меры свёрточной нейронной сети в 1,31 раза выше, чем у операторов. Скорость выявления аномалий увеличивается в 160 раз. На полученных упругих картах видна близость мнений эксперта и СНС (особенно, по классам «1» и «3»).




Рис. 10. Упругая карта для сравнения мнений по наличию аномалий класса «1».




Рис. 11. Упругая карта для сравнения мнений по наличию аномалий класса «2».




Рис. 12. Упругая карта для сравнения мнений по наличию аномалий класса «3»

Список литературы

1. Колесников А.В. Испытания конструкций и систем космических аппаратов: Курс лекций / А.В. Колесников. – Москва: МАИ, 2007. – 155 с.
2. Орлов С.А. Нормирование и отработка бортовой аппаратуры космических аппаратов на механические воздействия / С.А. Орлов, В.И. Копытов // Вестник СибГАУ. – №1. – 2013. – С. 125-129.
3. Дьяконов А.Г. Выявление аномалий в работе механизмов методами машинного обучения / А.Г. Дьяконов, А.М. Головина // Аналитика и управление данными в областях с интенсивным использованием данных: Сборник научных трудов XIX Международной конференции DAMDID / RCDL'2017. – Москва: ФИЦ ИУ РАН, 2017. – С. 389-396.
4. Журухин Н.Н. Выявление аномалий в амплитудных спектрах вибрации с помощью свёрточной нейронной сети / Н.Н. Журухин // Робототехника и искусственный интеллект: Материалы XII Всероссийской научно-технической конференции с

- международным участием. – Красноярск: Литера-принт, 2020. – С. 157-163.
5. Kreyszig E. Advanced Engineering Mathematics (4th ed.). – John Wiley & Sons Inc, 1979. – 880 p.
 6. Официальный сайт Сибирский государственный автомобильно-дорожный университет (СИБАДИ) [Электронный ресурс]: режим доступа - <http://bek.sibadi.org/fulltext/epd617.pdf>.
 7. Breunig M.M., Kriegel H.-P., Ng R.T., Sander J. LOF: Identifying Density-based Local Outliers // Proc. of the 2000 ACM SIGMOD Int. Conference on Management of Data, Dallas, TX, 2000. – pp. 93-104.
 8. Borne K.D. Effective Outlier Detection using K-Nearest Neighbor Data Distributions: Unsupervised Exploratory Mining of Non-Stationarity in Data Streams // Submitted to the Machine Learning Journal, Fairfax, VA, 2010. – pp. 1-26.
 9. Liu Y, Ding W. A KNNS based anomaly detection method applied for UAV flight data stream // Prognostics and System Health Management Conference (PHM), Beijing. 2015. – pp. 1-8.
 10. Официальный сайт IBM [Электронный ресурс]: режим доступа <https://developer.ibm.com/technologies/data-science/tutorials/create-and-experiment-with-dl-models-using-nn-modeler/>.
 11. Официальный сайт Keras [Электронный ресурс]: режим доступа - <https://keras.io/api/>.
 12. Официальный сайт Keras [Электронный ресурс]: режим доступа - <https://keras.io/guides/>.
 13. Рашка С. Python и машинное обучение: машинное и глубокое обучение с использованием Python, scikit-learn и TensorFlow / С. Рашка, В. Мирджалили. – СПб: Диалектика, 2019. – 656 с.
 14. Гудфеллоу Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль. – М: ДМК Пресс, 2018. – 652 с.
 15. Горбань А.Н. ViDaExpert: программа для нелинейной визуализации и анализа многомерных данных / А.Н. Горбань, А.Ю. Зиновьев, А.А. Питенко // Робототехника и искусственный интеллект: Материалы VI Всероссийской научно-технической конференции с международным участием. – Красноярск: Центр информации, 2014. – С. 120-126.
 16. Официальный сайт institutCurie [Электронный ресурс]: режим доступа - <http://bioinfo.curie.fr/projects/vidaexpert/>.

СОГЛАСОВАНИЕ ОНТОЛОГИЙ АГЕНТОВ СПЛОЧЕННЫХ ГИБРИДНЫХ ИНТЕЛЛЕКТУАЛЬНЫХ МНОГОАГЕНТНЫХ СИСТЕМ²

И.А.Кириков¹, С.В.Листопад², А.С.Лучко³

¹Калининградский филиал Федерального исследовательского центра «Информатика и управление» Российской академии наук, baltbipiran@mail.ru,

²Калининградский филиал Федерального исследовательского центра «Информатика и управление» Российской академии наук, ser-list-post@yandex.ru,

³ООО «АВТОТОР Холдинг Менеджмент», luchko@inbox.ru

При моделировании коллектива специалистов, решающих проблемы «за круглым столом», распределенными интеллектуальными системами, составленными из агентов, построенных различными разработчиками, существенную сложность составляет процесс их интеграции. Они могут быть несовместимы по языкам передачи сообщений, целям, моделям предметной области или протоколам решения проблем. В этом смысле, проблема аналогична той, с которой сталкиваются специалисты вновь созданного коллектива. Полярность точек зрения, неоднородность знаний, отсутствие принятых норм взаимодействия снижают эффективность совместной работы и качество предлагаемых решений. Отличие этих двух видов коллективного интеллекта в том, что реальные специалисты способны в результате взаимодействия разрешать конфликты относительно целей, ценностей, норм поведения и процесса решения проблемы. В этом случае малая группа развивается, проходя сложный путь от конгломерата незнакомых специалистов без общей цели до сплоченного коллектива единомышленников, осуществляющих эффективную совместную деятельность [1]. Для моделирования этих механизмов и снижения сложности интеграции агентов в единую систему в [2] предложен подход на основе сплоченных гибридных интеллектуальных многоагентных систем (СГИМАС). Они моделируют сплоченность коллектива специалистов на двух из трех уровней стратометрической концепции (СК) А.В. Петровского [3] (уровень эмоциональных межличностных отношений не рассматривается):

1) ценностно-ориентационное единство (ЦОЕ), т.е. близость основных ценностей и убеждений, возникающая в результате совместной деятельности;

2) ядро – единство обусловлено сходством целей членов коллектива.

Цель настоящей работы – разработка модели согласования онтологий агентов СГИМАС. Укрупненно могут быть выделены следующие направления исследований по разработке интеллектуальных систем с неоднородными онтологиями [4 – 6]:

1) разработка стандартных онтологий [7, 8] для определенных областей и согласование их применения множеством заинтересованных сторон. Процесс достаточно трудоемкий и релевантен лишь четко ограниченным предметным областям [4];

2) разработка методов и алгоритмов выравнивания онтологий (англ. ontology alignment), обеспечивающих установление соответствий между их элементами [6], например, [9 – 14]. Данные методы успешно работают, если соответствия могут быть

² Исследование выполнено при финансовой поддержке РФФИ (проект 20-07-00104а).

определены до того, как агенты начнут взаимодействовать, и выравниваемые онтологии статичны [5];

3) разработка методов слияния онтологий (англ. *ontology merging*) [6], обеспечивающих создание единой объединенной онтологии из двух или более исходных. Большинство разработанных методов предполагают интеграцию онтологий в автоматизированном режиме, например, [15 – 18], либо автоматическое интегрирование онтологий при условии допустимости ошибок, например, [19]. Общий недостаток этих методов – сложность получения интегрированной онтологии в динамических многоагентных системах, поскольку из-за накопления знаний онтологии агентов постоянно изменяются;

4) разработка методов и инструментов согласования онтологий путем переговоров (англ. *ontology negotiation*), предполагающих децентрализованный подход к совместному использованию разнородных онтологий [4 – 6]. Эти методы предполагают разрешение конфликтов онтологий при их возникновении в процессе взаимодействия агентов. При этом возрастают временные затраты непосредственно на решение поставленной проблемы.

Для применения в СГИМАС предлагается двухэтапная модель согласования онтологий путем переговоров. Первый этап выполняется при создании СГИМАС или изменении состава ее агентов и предполагает согласование онтологий до необходимого для совместной работы значения меры сходства. Второй этап согласования выполняется в процессе решения проблемы, когда агенты фиксируют ситуацию невозможности интерпретации семантики сообщений.

Формально СГИМАС [2] описывается выражением

$$chimas = \langle AG, env, INT, ORG, \{glng, ontng, protng\} \rangle, \quad (1)$$

где AG – множество агентов (2) системы, включающее подмножество $AG^{sp} \subseteq AG$ агентов-специалистов (АС), моделирующих рассуждения специалистов-членов коллектива, агента $ag^{dm} \in AG$, принимающего решения (АПР), агента-фасилитатора (АФ) $ag^{fc} \in AG$, отвечающего за организацию эффективного взаимодействия агентов и формирование сплоченности; env – концептуальная модель внешней среды; INT – множество элементов для структурирования взаимодействий агентов (3); ORG – множество архитектур СГИМАС; $\{glng, ontng, protng\}$ – множество моделей макроуровневых процессов, содержащее модель $glng$ согласования целей агентов, обеспечивающую сплоченность на уровне ядра СК [3], модель $ontng$ (6) согласования онтологий агентов, соответствующую обмену знаниями, опытом и убеждениями между членами коллектива и формированию сплоченности на уровне ЦОЕ [3], и модель $protng$ построения агентами протокола сплоченного решения проблем, имитирующую выработку специалистами норм взаимодействия на страте ЦОЕ [3].

Агент $ag \in AG$ из формулы (1) описывается выражением

$$ag = \langle id^{ag}, gl^{ag}, LANG^{ag}, ont^{ag}, OCM^{ag}, ACT^{ag}, prt^{ag} \rangle, \quad (2)$$

где id^{ag} – идентификатор (имя) агента; gl^{ag} – нечеткая цель агента; $LANG^{ag} \subseteq LANG$ – множество языков передачи сообщений, которыми «владеет» агент; ont^{ag} – модель предметной области (онтология) агента, описываемая выражением (4); OCM^{ag} – множество отображений концептов онтологий, элементы которого описываются выражением (5); ACT^{ag} – множество действий, реализуемых агентом; prt^{ag} – модель протокола решения проблемы, разрабатываемая агентом в процессе взаимодействия с другими агентами.

Множество INT элементов для структурирования взаимодействий агентов из формулы (1) описывается выражением

$$INT = \{prot^{bsc}, PRC, LANG, ont^{bsc}, chn\}, \quad (3)$$

где $prot^{bsc}$ – базовый протокол, обеспечивающий взаимодействие агентов по формированию протокола решения проблемы; PRC – множество элементов для конструирования протокола решения проблемы агентами-специалистами и АПР; $LANG$ – множество языков передачи сообщений агентов; ont^{bsc} – базовая онтология, обеспечивающая интерпретацию агентами семантики сообщений по согласованию собственных целей и моделей предметной области, формированию протокола решения проблемы, описываемая выражением (4); chn – степень сплоченности агентов [2], описывающая степень сходства целей и онтологий, а также согласованности протокола решения проблемы.

Модели онтологий агентов ont^{ag} и базовой онтологии ont^{bsc} из выражений (2) и (3) соответственно описываются следующим образом:

$$ont = \langle L, C, R, AT, FC, FR, FA, H^c, H^r, INST \rangle, \quad (4)$$

где $L = L^c \cup L^r \cup L^{at} \cup L^{va}$ – лексикон, множество лексем, состоящее из подмножеств лексем, обозначающих понятия L^c , отношения L^r , атрибуты L^{at} и их значения L^{va} ; C – множество концептов; $R: C \times C$ – множество отношений между концептами; $AT: C \times L^{va}$ – множество атрибутов концептов; $FC: 2^{L^c} \rightarrow 2^C$ – функция связи лексикона с концептами; $FR: 2^{L^r} \rightarrow 2^R$ – функция связи лексикона с отношениями; $FA: L^{at} \rightarrow AT$ – функция связи лексикона с атрибутами; $H^c = C \times C$ – таксономическая иерархия концептов; $H^r = R \times R$ – иерархия отношений; $INST$ – множество экземпляров, концептов единичного объема [20].

Отображение $osm_{ij}^{ag} \in OCM^{ag}$ (2) описывается выражением

$$osm_{ij}^{ag} = \langle id_i^{ag}, id_j^{ag}, el_i, el_j \rangle, \quad (5)$$

где id_i^{ag} – идентификатор АС ag_i , хранящего отображение osm_{ij}^{ag} ; id_j^{ag} – идентификатор АС ag_j , онтология которого отображается на онтологию АС ag_i ; el_i, el_j – элементы онтологий ont_i^{ag}, ont_j^{ag} АС ag_i, ag_j соответственно, $el \in L \cup C \cup R \cup AT$.

Модель согласования онтологий агентов описывается выражением

$$ontng = \langle ontsid^{fc}, ontsid^{sp}, OCM, ONTNM \rangle, OCM = \bigcup_{AG} OCM^{ag}, \quad (6)$$

где $ontsid^{fc}$ – модель идентификации АФ ситуации необходимости согласования онтологий АС; $ontsid^{sp}$ – модель идентификации АС ситуации неэффективной коммуникации; $ONTNM$ – методы согласования элементов онтологий.

Модель $ontsid^{fc}$ из выражения (6) описывает процесс идентификации АФ ситуации необходимости согласования онтологий АС при изменении состава агентов СГИМАС или модификации их онтологий. Данная модель представляется выражением

$$\begin{aligned} ontsid^{fc} = & r_1 (ACT_{ops}^{agfc}, act_{osc}^{agfc}) \circ r_1 (act_{osc}^{agfc}, act_{onn}^{agfc}) \circ r_1 (act_{onn}^{agfc}, act_{oeng}^{agfc}) \circ r_1 (act_{oeng}^{agfc}, act_{ocdn}^{agfc}) \circ \\ & \circ r_2 (ACT_{ops}^{agfc}, ONT^{ag}) \circ r_3 (ACT_{ops}^{agfc}, ONTS^{ag}) \circ r_2 (act_{osc}^{agfc}, ONTS^{ag}) \circ r_3 (act_{osc}^{agfc}, onts^{chimas}) \circ \\ & \circ r_2 (act_{onn}^{agfc}, onts^{chimas}) \circ r_2 (act_{onn}^{agfc}, onntr) \circ r_3 (act_{onn}^{agfc}, onntr) \circ r_2 (act_{oeng}^{agfc}, onntr) \circ \\ & \circ r_2 (act_{oeng}^{agfc}, ONT^{ag}) \circ r_2 (act_{oeng}^{agfc}, OCM) \circ r_3 (act_{oeng}^{agfc}, OEFN) \circ r_2 (act_{ocdn}^{agfc}, OEFN), \end{aligned}$$

где r_1, r_2, r_3 – отношения «следование», «иметь аргументом», «иметь результатом» соответственно; ACT_{ops}^{agfc} – множество действий АФ, рассмотренных в [2], по вычислению множества попарных оценок $ONTS^{ag}$ сходства онтологий АС ONT^{ag} ; act_{osc}^{agfc} – действие АФ по вычислению интегрированной оценки $onts^{chimas}$ сходства онтологий АС как среднего арифметического оценок $ONTS^{ag}$; act_{onn}^{agfc} – вычисление АФ оценки $onntr$ необходимости согласования онтологий АС на основе интегрированной оценки $onts^{chimas}$ сходства онтологий АС и порогового значения сходства онтологий АС $onntr$, определяемого в результате вычислительных экспериментов со СГИМАС; act_{oeng}^{agfc} – идентификация АФ множества $OEFN$ элементов онтологий, требующих согласования (7); act_{ocdn}^{agfc} – распределение АФ заданий АС на согласование концептов из множества $OEFN$.

Множество $OEFN$ определяется следующим выражением:

$$OEFN = \{ \langle id_i^{ag}, id_j^{ag}, el_j \rangle \mid (el_j \notin EL_i) \wedge (\langle id_i^{ag}, id_j^{ag}, el_j \rangle \notin Pr_{1,2,4} OCM) \}. \quad (7)$$

Модель $ontsid^{sp}$ из выражения (6) описывает процесс идентификации АС ситуации неэффективной коммуникации с другим АС и оценки необходимости согласования их онтологий. Данный процесс запускается при получении одним АС от другого очередного сообщения в процессе решения проблемы. Данная модель представляется выражением

$$\begin{aligned} ontsid^{sp} = & r_1 (act_{mint}^{sp}, act_{rqci}^{sp}) \circ r_1 (act_{rqci}^{sp}, act_{rcci}^{sp}) \circ r_2 (act_{mint}^{sp}, msg^{prb}) \circ r_3 (act_{mint}^{sp}, OEFN) \circ \\ & \circ r_2 (act_{rqci}^{sp}, OEFN) \circ r_3 (act_{rqci}^{sp}, msg^{crq}) \circ r_2 (act_{rcci}^{sp}, msg^{crp}) \circ r_3 (act_{rcci}^{sp}, OEFN), \end{aligned}$$

где act_{mint}^{sp} – интерпретация АС сообщения msg^{prb} и формирование множества $OEFN$ элементов сообщения msg^{prb} , требующих согласования (7), если сообщение не удалось интерпретировать; act_{rqci}^{sp} – формирование АС сообщения-запроса msg^{crq} на подтверждение правильности интерпретации сообщения msg^{prb} , если $OEFN = \emptyset$; act_{rcci}^{sp} – разбор АС сообщения-ответа msg^{crp} , содержащего подтверждение или опровержение

правильности интерпретации сообщения msg^{prb} , и, если есть, извлечение множества $OEFN$ элементов, требующих согласования.

Обобщенная концептуальная схема sch^{ontnm} метода $ontnm \in ONTNM$ согласования элементов онтологий описывается выражением

$$\begin{aligned} sch^{ontnm} = & r_1(act_{meq}^{sp}, act_{aer}^{sp}) \circ r_1(act_{aer}^{sp}, act_{cont}^{sp}) \circ r_1(act_{cont}^{sp}, act_{meq}^{sp}) \circ r_1(act_{aeq}^{sp}, act_{mer}^{sp}) \circ \\ & \circ r_1(act_{mer}^{sp}, act_{aeq}^{sp}) \circ r_2(act_{meq}^{sp}, oefn) \circ r_3(act_{meq}^{sp}, msg^{eq}) \circ r_2(act_{aer}^{sp}, msg^{er}) \circ r_2(act_{aer}^{sp}, ont^{ag}) \circ \\ & \circ r_3(act_{aer}^{sp}, OEFN^*) \circ r_2(act_{cont}^{sp}, OEFN^*) \circ r_2(act_{cont}^{sp}, OEFN) \circ r_2(act_{cont}^{sp}, msg^{er}) \circ \\ & \circ r_3(act_{cont}^{sp}, ont^{ag}) \circ r_2(act_{cont}^{sp}, OEFN) \circ r_2(act_{aeq}^{sp}, msg^{eq}) \circ r_2(act_{aeq}^{sp}, ont^{ag}) \circ \\ & \circ r_3(act_{aeq}^{sp}, ARG) \circ r_2(act_{mer}^{sp}, ARG) \circ r_3(act_{mer}^{sp}, msg^{er}), \end{aligned}$$

где act_{meq}^{sp} – формирование и отправка запроса msg^{eq} на согласование элемента $oefn \in OEFN$, если $OEFN = \emptyset$ метод завершает свою работу; act_{aer}^{sp} – анализ полученного сообщения-ответа msg^{er} на основе онтологии ont^{ag} и при наличии формирование множества $OEFN^*$ элементов онтологии, которые требуется согласовать, прежде чем будет возможно согласовать элемент $oefn$; act_{cont}^{sp} – корректировка онтологии агента ont^{ag} в соответствии с полученным сообщением-ответом msg^{er} и удаление элемента $oefn$ из множества $OEFN$ элементов, требующих согласования, если $OEFN^* = \emptyset$, в противном случае $OEFN = OEFN \cup OEFN^*$, а изменения онтологии не выполняются; act_{aeq}^{sp} – анализ полученного сообщения-запроса msg^{eq} на основе онтологии ont^{ag} и при наличии формирование множества ARG аргументов, подкрепляющих элемент $oefn$; act_{mer}^{sp} – формирование и отправка сообщения-ответа msg^{er} , содержащего множество ARG аргументов.

Методы согласования элементов онтологий из множества $ONTNM$, построенные в соответствии со схемой sch^{ontnm} , различаются между собой типами согласуемых элементов $oefn$ онтологий, допустимых аргументов ARG , используемых для подкрепления согласуемого элемента, а также соответствующими им реализациями действий по анализу запросов act_{aeq}^{sp} , ответов act_{aer}^{sp} и корректировке онтологии act_{cont}^{sp} . Так в качестве аргументов ARG могут использоваться, например, определение элемента с помощью элементов более высокого уровня в соответствии с иерархиями H^c и H^r или объяснение с использованием наборов примеров и контрпримеров [5].

Таким образом, предложенная модель согласования онтологий агентов СГИМАС позволит снизить интенсивность конфликтов, которые обусловлены различиями в моделях предметной области агентов, созданных различными группами разработчиков и соответствующих различным специалистам по решаемой проблеме. Наличие механизма предварительного согласования онтологий позволяет сократить время решения проблемы за счет сближения онтологий на этапе формирования коллектива агентов и снижения числа конфликтов. Механизм согласования путем переговоров в

процессе решения проблемы позволяет откладывать согласование отдельных элементов онтологий, избегая однообразности онтологий агентов.

Рассмотрены особенности проектирования неоднородных интеллектуальных систем распределенными командами разработчиков и сложности, возникающие при интеграции элементов таких систем. С целью снижения трудозатрат этого этапа разработки предложена концепция сплоченных гибридных интеллектуальных многоагентных систем, реализующих механизмы согласования целей, онтологий, а также выработку протокола коллективного решения проблемы. Рассмотрены существующие подходы к проблеме согласования неоднородных онтологий интеллектуальных систем. Рассмотрена модель сплоченных гибридных интеллектуальных многоагентных систем и предложена модель согласования онтологий их агентов. Сочетание механизмов предварительного согласования онтологий и согласования путем переговоров в процессе решения проблемы позволяет снижать число конфликтов и не допускать чрезмерной однообразности онтологий.

Список литературы

1. Почебут Л.Г. Организационная социальная психология. Учебное пособие / Л.Г. Почебут, В.А. Чикер. — СПб.: Изд-во «Речь», 2002. — 298 с.
2. Listopad S.V. Similarity measure of agents' ontologies in cohesive hybrid intelligent multi-agent system / S.V. Listopad, I.A. Kirikov // *Journal of Physics: Conference Series*. — 2020. — Vol. 1679. — № 3. — 032061.
3. Петровский А.В. Опыт построения социально-психологической концепции групповой активности / А.В. Петровский // *Вопросы психологии*. — 1973. — № 5. — С. 3 – 17.
4. Bailin S. Ontology negotiation between intelligent information agents / S. Bailin, W. Truszkowski // *The Knowledge Engineering Review*. — 2002. — Vol. 17. — № 1. — pp. 7 – 19.
5. van Diggelen J. Ontology negotiation in heterogeneous multi-agent systems: The ANEMONE system / J. van Diggelen, R.-J. Beun, F. Dignum, R.M. van Eijk, J.-J. Meyer // *Applied Ontology*. — 2007. — № 2. — pp. 267 – 303.
6. Zhu J. Ontology negotiation: Knowledge interchange between distributed ontologies through agent negotiation / J. Zhu, L. Teng, H. Lu, J. Shi, B. Li // *Concurrency and Computation: Practice and Experience*. 2019. E-print: <https://onlinelibrary.wiley.com/doi/abs/10.1002/cpe.5406>
7. Humphreys B.L. The UMLS project: making the conceptual connection between users and the information they need / B.L. Humphreys, D.A.B. Lindberg // *Bulletin of the Medical Library Association*. — 1993. — Vol. 81. — № 2. — pp. 170 – 177.
8. Price C. SNOMED clinical terms / C. Price, K. Spackman // *BJHC&IM-British Journal of Healthcare Computing & Information Management*. — 2000. — Vol. 17. — № 3. — pp. 27 – 31.
9. Бова В.В. Эволюционный подход к решению задачи интеграции онтологий / В.В. Бова, Д.В. Заруба, В.В. Курейчик // *Известия ЮФУ. Технические науки*. — 2015. — №. 6 (167). — С. 41 – 56.

10. Ehrig M. An Ontology Mapping - An Integrated Approach / M. Ehrig, Y. Sure // In: The Semantic Web: Research and Applications. Bussler C.J., Davies J., Fensel D., Studer R. (eds). ESWS 2004. Lecture Notes in Computer Science. — Vol 3053. — Berlin, Heidelberg: Springer. — 2004. — pp. 3-13.
11. Fernandez S. A Fuzzy Rule-Based System for Ontology Mapping / S. Fernandez, J.R. Velasco, M.A. Lopez-Carmona // Principles of Practice in Multi-Agent Systems. PRIMA 2009. Lecture Notes in Computer Science. — 2009. — Vol. 5925. — pp. 500 – 507.
12. Gavrilova T. Knowledge Mapping for Teaching and Learning / T. Gavrilova // The 21st Century: a scientific quarterly. — 2007. — № 2(24). — pp. 21-32.
13. Idoudi R. Ontology knowledge mining for ontology alignment / R. Idoudi, K.S. Ettabaa, B. Solaiman, K. Hamrouni // International Journal of Computational Intelligent Systems. — 2016. — Vol. 9. — № 5. — pp. 876 – 887.
14. Xue X. Optimizing ontology alignment by using compact genetic algorithm / X. Xue, J. Liu, P.W. Tsai, X. Zhan, A. Ren // In: 2015 11th International Conference on Computational Intelligence and Security (CIS). — Shenzhen, China: IEEE. — 2016. — pp. 231 – 234.
15. Кудрявцев Д.В. Практические методы отображения и объединения онтологий / Д.В. Кудрявцев // В: Труды 11-й Национальной конференции по искусственному интеллекту с международным участием (КИИ-08). — Том 3. — М.: ЛЕНАНД. — 2008. — С. 164 – 173.
16. Noy N.F. The PROMPT suite: interactive tools for ontology merging and mapping / N.F. Noy, M.A. Musen // International Journal of Human-Computer Studies. — 2003. — Vol. 59. — № 6. — pp. 983 – 1024.
17. McGuinness D.L. The Chimaera ontology environment / D.L. McGuinness, R. Fikes, J. Rice, S. Wilder // Proceedings of the Seventeenth National Conference on Artificial Intelligence (AAAI 2000). — Austin, Texas: AAAI. — 2000. — pp. 1123 – 1124.
18. Stumme G. FCA-merge: bottom-up merging of ontologies / G. Stumme, A. Maedche // Proceedings of the Seventeenth International Joint Conference on Artificial Intelligence (I). San Francisco: Morgan Kaufmann. — 2001. — pp. 225 – 230.
19. Maiz N. Automatic Ontology Merging by Hierarchical Clustering and Inference Mechanisms / N. Maiz, M. Fahad, O. Boussaid, F. Bentayeb // Proceedings of I-KNOW '10: 10th international conference on knowledge management and knowledge technologies. — Graz, Austria: Verlag der Technischen Universität Graz. — 2010. — pp. 81 – 93.
20. Крюков К.В. Меры семантической близости в онтологии / К.В. Крюков, Л.А. Панкова, В.А. Пронина, В.С. Суховеров, Л.Б. Шипилина // Проблемы управления. — 2010. — № 5. — С. 2 – 14.

ОБНАРУЖЕНИЕ РЕЧЕВОЙ АКТИВНОСТИ С ИСПОЛЬЗОВАНИЕМ МЕТОДА ЭНТРОПИИ ЗАПОЛНЕНИЯ ФАЗОВОГО ПРОСТРАНСТВА

Н.П.Кузенков¹, В.М.Логинов¹

¹Сибирский федеральный университет,
Институт космических и информационных технологий, каф. прикладной математики и
компьютерной безопасности, *knp@vivaldi.net*

Обнаружение голосовой активности, или VAD (англ. Voice Activity Detection) — это технология анализа речи, которая позволяет обнаруживать речевые паузы с целью их дальнейшего удаления или какого-либо преобразования. В телекоммуникационных системах самыми дорогими и наиболее загруженными элементами, как правило, являются линии связи, соединяющие сетевые элементы. Таким образом, эффективность системы связи определяется в первую очередь эффективностью использования линий связи. Для увеличения объема передаваемой информации используется множество различных методов, например, частотное и временное мультиплексирование сигналов. В системах голосовой связи, включая системы сотовой связи, используются различные системы сжатия. По той причине, что человеческая речь является естественным источником информации, она включает в себя множество данных, не несущих смысловой нагрузки, которые могут быть удалены из речевого сигнала. Поэтому было разработано множество различных алгоритмов, которые устраняют избыточность речи, пытаясь различать только значимые параметры речи. Наиболее распространенным и эффективным способом сжатия речевых данных является удаление пауз между фразами, словами и отдельными звуками, которые составляют значительную часть речи. Например, в образце речи, который используется в этой статье, общая продолжительность пауз достигает 43%. В случае диалога общая продолжительность пауз значительно увеличится. Обработка речи без пауз позволяет в несколько раз снизить объем трафика, сохраняя качество речевого сигнала. Более того, решения подавляющего большинства задач по анализу и преобразованию речи человека начинаются именно с поиска речевых сегментов, которые затем подвергаются дальнейшему анализу, как, например, в системах распознавания речи или верификации (идентификации) диктора либо же кодируются и сжимаются, как в системах передачи голосовой информации.

Помимо различных систем связи, методы VAD используются во множестве технологий обработки речи, включая распознавание речи, анализ речи, кодирование речи и другие. Точный алгоритм обнаружения голосовой активности улучшает качество систем распознавания речи, особенно в присутствии шума [1].

Кроме того, некоторыми авторами были предприняты попытки применить методы VAD нетрадиционным способом, как, например, для более точной верификации говорящего [2], распознавания эмоций [3, 4] или исследований разборчивости предложений [5].

На сегодняшний день разработано множество методов обнаружения голосовой активности. Все они основаны на разных принципах. Как правило, разработка алгоритмов VAD включает в себя следующие этапы [6]:

- Определение функций, позволяющих оценить какие-либо информативные показатели речевого сигнала.
- Разработка правил принятия решений, позволяющих различать озвученные сегменты речи.

Обычно меры для выделения признаков выбираются из следующих: мощность и близкие к мощности характеристики, мера оценки периодичности сигнала (спектр, кепстр, вейвлет-коэффициенты и т.д.) или статистическая характеристика речевого сигнала, вычисляемые внутри скользящего окна. Превышение сигналом пороговой мощности может быть использовано в качестве решающего правила лишь в простейшем случае при отсутствии или низком уровне шума и постоянной громкости речи. Для более сложных случаев широкое распространение получили методы классификации и кластеризации, машинного обучения, искусственных нейронных сетей и так далее [7-13].

В данной работе в качестве одной из характеристик речевого сигнала используется энтропия заполнения фазового пространства, метод вычисления которой можно кратко описать следующим образом. Если исследуемый сигнал представлен в виде множества $\{x_i\}$, его траектория в фазовом пространстве может быть описана в двумерном случае следующим образом: $\{x_n, x_{n+k}\}$, где $k=1,2,\dots,n$ — это временная задержка, на которую смещается исследуемый сигнал. Энтропия выбирается для количественной оценки динамики, характеризующей меру заполнения фазовой плоскости образцами сигналов. Для её вычисления фазовая плоскость делится на квадраты $N \times N$. Общее количество квадратов соответственно равно N^2 . Далее определяются вероятности p_i^k для каждого квадрата i и временного сдвига k : $p_i^k = \frac{m_{i,k}}{M_k}$, где $m_{i,k}$ — количество отсчетов в квадрате i и $M_k = M - 2k$ — количество отсчетов на фазовой плоскости, соответствующее временной задержке k , M — суммарное количество отсчетов сигнала. Представленный в виде набора значений параметр k представляет собой характерное время, выраженное в отсчётах сигнала, позволяющее оценить динамику фазовых портретов в зависимости от значений k . Временная задержка k связана с характерными физическими временами τ следующим образом: $k=f \cdot \tau$, где f — частота дискретизации. Энтропия S_k , соответствующая моменту k , определяется следующим образом:

$$S_k = - \sum_{i=1}^{N^2} p_i^k \log_2 p_i^k \quad (1)$$

Следует отметить, что поведение функции отражает временные особенности сигнала и позволяет определять характерные времена периодических и случайных сигналов по положению экстремумов функции. В целом для энтропии характерны следующие особенности: быстрый рост при малых значениях k и выход на стационарный уровень (для случайных сигналов), случайные колебания с малой амплитудой вблизи стационарного уровня, формирование локальных минимумов на

временах, кратных половине либо целому значению периода колебаний каких-либо компонент сигнала либо модулирующей его функции.

В качестве иллюстрации были исследованы два вида шума. В первом случае была рассчитана энтропия нормального распределенного шума. Во втором случае тот же шум был модулирован синусоидальным сигналом с частотой модуляции $\nu = \frac{2}{3}$ Гц.

Энтропия была рассчитана для обоих сигналов. Энтропия первого сигнала имеет большее среднее значение и совершает случайные колебания вблизи стационарного уровня, а энтропия второго сигнала совершает как периодические, так и случайные колебания, формируя локальные минимумы вблизи половины периода колебаний модулирующего сигнала (рис. 1).




Рис. 1. Энтропия нормально распределенного шума (вверху) и нормально распределенного шума с амплитудной модуляцией (внизу).

Как было показано ранее, можно использовать предложенный способ энтропии заполнения фазового пространства для анализа временных рядов и установления факта наличия периодических компонент (в том числе в виде модулирующих функций) в составе анализируемых сигналов [14].

Помимо энтропии заполнения фазового пространства, для определения речевой активности также использовалась огибающая речевого сигнала. Существует множество способов определения огибающей сигнала. В настоящей работе используется следующий подход: выполнялось умножение абсолютных значений отсчетов сигнала в скользящем окне длительностью 10 мс на значения параболической функции, равной 0 на границах окна и 1 в центре окна. После чего, выбиралось максимальное значение из предыдущего этапа в качестве величины огибающей сигнала. Данный подход по сравнению с вычислением среднего от абсолютных значений либо же мощности сигнала в скользящем окне, обладает большим быстродействием при изменениях формы сигнала и формирует огибающую сигнала, приближенную к локальным максимальным значениям (рис. 2).




Рис.2. Огибающая речевого сигнала.

Распределение мгновенных значений огибающей речевого сигнала, построенное в полулогарифмической шкале, носит полимодальный характер и имеет два ярко выраженных максимума (рис. 3).




Рис.3. Распределение значений огибающей речевого сигнала.

Очевидно, что окрестность первого (левого) максимума соответствует паузам речевого сигнала и отражает распределение амплитуды аддитивных шумов. Наличие минимума на графике распределения может стать значимым фактором для процедур кластеризации, которые используют значения огибающей речевого сигнала. Характеристики энтропии также могут быть использованы наравне со значениями огибающей речевого сигнала благодаря следующим свойствам: изменению стационарного уровня и возрастанию размаха при формировании локальных минимумов в случае наличия какой-либо периодичности в исследуемом сигнале.

С целью выделения сегментов речевой активности каждое значение речевого сигнала сопоставлялось с трёхмерным вектором, включающим в себя следующие параметры: натуральный логарифм огибающей речевого сигнала ($\ln E$), среднее значение энтропии ($\langle S \rangle$) и стандартное отклонение энтропии ($\sigma(S)$).

Набор векторов затем был разделен на кластеры с использованием методов восходящей иерархической кластеризации. Было испробовано несколько вариантов кластеризации, с различными способами измерения расстояния между точками и кластерами. В конце концов, была выбрана следующая комбинация: оценка дистанций

для попарных расстояний по методу Канберры, которые могут быть определены для точек p_i и p_j следующим образом:

$$d = \frac{|\vec{p}_i - \vec{p}_j|}{|\vec{p}_i + \vec{p}_j|} \quad (2)$$

и метод невзвешенной парной группы со средним арифметическим для измерения расстояний между кластерами (UPGMA). В этом случае было получено наиболее естественное разделение на кластеры. Оптимальное количество кластеров равно 4, данное количество которых было оценено с использованием 30 различных индексов оценки результатов кластеризации из пакета NbClust, входящего в состав R.

В соответствии с результатами кластеризации были выведены следующие правила обнаружения речевых пауз для речевых сигналов с соотношением энергии сигнал/шум не менее 35 дБ:

- $\ln E < -5.0$,
- $(3.43 - \langle S \rangle)^2 + (0.0653 - \sigma(S))^2 < 0.0288$.

Предложенный способ обнаружения речевой активности продемонстрировал эффективное различения пауз и высокую способность сохранять тихие речевые звуки. В качестве ошибок первого рода для предложенного метода можно принять незначительное количество случаев распознавания в качестве речевых звуков шумов при выполнении диктором быстрого вдоха, в качестве ошибок второго рода — принятие в качестве паузы участков тихих шумных согласных в начале или в конце речевых звуков. По субъективной оценке, качество звучания речи после преобразования с использованием предложенного метода сопоставимо с качеством речи, подвернутой обработке алгоритмами VAD в сетях GSM.

С целью повышения эффективности алгоритма можно предложить следующие модификации: во-первых, использовать несимметричную функцию в скользящем окне при вычислении огибающей сигнала, поскольку в речевых звуках скорости возрастания и убывания мощности обычно различаются между собой; во-вторых, использовать более сложную, чем размах, функцию от энтропии, что вероятно позволит эффективно использовать метод при наличии аддитивных периодических шумов, наподобие наводок от электрических сетей.

Список литературы

1. Ramírez, J. Voice Activity Detection. Fundamentals and Speech Recognition System Robustness / Ramírez, J., Gorriz, J., Segura, J. // Robust Speech Recognition and Understanding. — 2007 — V. 6(9). 24p.
2. Igras-Cybulska, M. Structure of pauses in speech in the context of speaker verification and classification of speech type / Igras-Cybulska, M., Ziolkowski, B., Zelasko, P., & Witkowski, M. // EURASIP Journal on Audio, Speech and Music Processing. — 2016 — V. 18. p. 1–16.
3. Alghifari, M. On the use of voice activity detection in speech emotion recognition / Alghifari, M., Gunawan, T., Nordin, M., Qadri, S., Kartiwi, M., Janin, Z. // Bulletin of Electrical Engineering and Informatics. — 2019. — V. 4(8). p. 1324-1332.
4. Sztahó, D. Speech activity detection and automatic prosodic processing unit segmentation for emotion recognition / Sztahó, D., Vicsi, K. // Intelligent Decision

Technologies. — 2014 — V. 4(8). p. 315-324.

5. Sakamoto, S. Effects of inter-word pauses on speech intelligibility under long-path echo conditions / Sakamoto, S., Cui, Z., Miyashita, T., Morimoto, M., Suzuki, Y., Sato, H. // *Applied Acoustics*. — 2018. — № 140. p. 263-274.

6. Shabeeba T. K. A Survey on Voice Activity Detection Methods / Shabeeba T. K., Anand P. // *International Journal of Current Trends in Engineering & Research (IJCTER)*. — 2016. — V. 2(4). p. 668-675.

7. Suraj M. A survey of voice detection and recognition algorithms / Suraj M., Aaditya S., Nirmal S., Ankit S., Bhushan T. // *International Journal of Advance Engineering and Research Development*. — 2017. — V. 2(4). p. 550-552.

8. Graf, S. Features for voice activity detection: a comparative analysis / Graf, S., Herbig, T., Buck, M., Schmidt, G. // *EURASIP Journal on Advances in Signal Processing*. — 2015. — V. 11. 91p.

9. Ong, W. Real-Time Robust Voice Activity Detection Using the Upper Envelope Weighted Entropy Measure and the Dual-Rate Adaptive Nonlinear Filter / Ong, W., Tan, A., Vengadasalam, V., Tan, C., Ooi, T. // *Entropy*. — 2017 — V. 19, 487— 21p.

10. Ali, Z. Innovative Method for Unsupervised Voice Activity Detection and Classification of Audio Segments / Ali, Z., Talha, M. // *IEEE Access*. 2018. — V. 6. — p.15494-15504.

11. Hughes, T. Recurrent Neural Networks for Voice Activity Detection / Hughes, T., Mierle, K. // *ICASSP IEEE*. — 2013. — p.7378-7382.

12. Ghosh, P. K. Robust Voice Activity Detection Using Long-Term Signal Variability / Ghosh, P. K., Tsiartas, A., Narayanan, S. // *IEEE Transactions on Audio, Speech, and Language Processing*. — 2011. — V. 3(19). — p.600-613.

13. Drugman, T. Voice Activity Detection: Merging Source and Filter-based Information / Drugman, T., Stylianou, Y., Kida, Y., Akamine, M. // *IEEE Signal Processing Letters*. — 2015. — V. 2(23). — p.252-256.

14. Кузенков, Н.П. Исследование временных рядов с использованием энтропии заполнения многомерных фазовых пространств / Кузенков, Н.П., Логинов В.М. // *Моделирование неравновесных систем. Материалы XV Всероссийского семинара, 5-7 октября 2012г., ИВМ СО РАН, Красноярск*. — 2012. — с.100-103.

ОБРАБОТКА И АНАЛИЗ СНИМКОВ ДЛЯ ВЫЯСНЕНИЯ БИОЛОГИЧЕСКОЙ СТРУКТУРЫ МОЗГА С ПОЗИЦИИ ФОРМИРОВАНИЯ МОДЕЛИ НС

А.В.Медиевский¹, А.Г.Зотин², К.В.Симонов³, А.С. Кругляков³

¹Красноярский государственный медицинский университет
имени профессора В.Ф. Войно-Ясенецкого. amedievsky@yandex.ru,

²Сибирский государственный университет науки и технологий
имени академика М.Ф. Решетнева. zotinkrs@gmail.com

³Институт вычислительного моделирования СО РАН. simonovkv50@gmail.com

Введение

В основе формирования модели биологической нейронной сети необходимо заложить данные её структуры, полученные с микроскопических снимков. Анализ серии снимков позволит выявить и описать структурные особенности и состояния нейронов. В работе предлагается выполнять обработку и анализ изображений микроскопии при помощи шпатель-преобразований, а также контрастирования при помощи цветового кодирования. В результате выполнения обработки снимков по предлагаемой методике, возможно, получить информацию о нервных клетках, их координатах и взаимосвязях при помощи отростков. Это в свою очередь позволит оценить структурные особенности и состояния нейронов.

Мозг, по своей природе, очень сложная структура, состоящая из нескольких видов клеток, которые организованы в трёхмерном пространстве и имеют достаточно плотное взаиморасположение. Центральная нервная система включает в себя сами нейроны и вспомогательные клетки – глию.

В нашем исследовании основной акцент сделан на нейронах и способах их выявления на микроскопических снимках. Размер тела нейрона находится в диапазоне от 5 до 150 мкм, а диаметр отростка, выходящего из тела нейрона, обычно не превышает 5 мкм. Для анализа данных структур, из-за их размера, необходимо использовать микроскоп, способный увеличивать изображение до 2500х раз.

Основой для результативного исследования в нейрофизиологии и нейробиологии является структурное изучение живой ткани, в связи с этим можно использовать не все виды микроскопии. Для исследования живых клеток агрессивные красители необходимо заменить на витальные, либо прибегнуть к нативной микроскопии – без окрашивания [1].

Для исследования развития и функционирования нейронной сети наилучшим вариантом является нативная микроскопия, так как нейроны, совершенно, не подвергаются воздействию извне, и их физиология остаётся прежней. Однако основным недостатком такого метода является слабая контрастность. Поэтому нейробиологу важно как точнее оценить структуру нейронной сети.

Основной задачей данной работы является разработка вычислительной методики для выделения объектов на нативных микроскопических изображениях, полученных со светового микроскопа. А также визуализация интересующих клеток с усиленным контрастированием и цветовым кодированием.

Полученные в результате расчетов изображения необходимы для изучения развития нейронной сети; выявления и подсчёта количества контактов между клетками; отслеживания патологических состояний и исследования методов лечения; качественного анализа передачи сигнала от одной клетки к другой в комбинации с работой микроэлектродов [2]; создания, в итоге, цифровой модели культуры нервных клеток.

Для микроскопии используется культура нервных клеток, выращенных на питательной среде в чашке Петри из плюрипотентных стволовых клеток, которые выделили из головного мозга мыши [3]. Данная методика подготовки биологической ткани позволяет получить монослойный органоид, существующий на протяжении длительного периода времени. Благодаря этому появляется возможность сделать неограниченное количество снимков растущих нейронов.

1. Технологии анализа активности нейронов

Анализ активности нейронов может осуществляться при помощи различных методик. Наиболее популярным, на данный момент, является кальциевый имиджинг [4-5]. Суть метода заключается в флуоресцентной микроскопии только тех нейронов, которые возбуждены. Если нейрон восстанавливает свой мембранный потенциал / концентрацию кальция в цитоплазме, то флуоресценция прекращается. Данный эффект возможен благодаря флуоресцентному белку, который начинает испускать фотоны в момент поступления кальция внутрь клетки. Этот белок используется в красителях, вводимых внутрь культуры клеток, либо внутрь живой особи.

Кальциевый имиджинг позволяет зафиксировать распространение нервного импульса по нейронной сети, что демонстрирует возможные синаптические связи и также очертания нейронов. Но полученные данные характеризуют только ту часть нейронной сети, в которой клетки меняли мембранный потенциал, а, следовательно, невозбуждённые клетки не будут зафиксированы. Также из недостатков данного метода можно подчеркнуть следующую проблему – нет возможности получить данные о качественной характеристике синапса, через которые не передался стимул. Таким образом, используя этот метод, мы имеем на выходе бинарные данные (есть возбуждение / нет возбуждения), а аналоговая часть упускается.

Другая развивающаяся методика для анализа активности нейронов использует мультиэлектродные массивы (МЕА) [6]. Они состоят из микроэлектродов размером 50 мкм, в среднем используется 64 единицы, которые улавливают малейшие изменения мембранного потенциала и передают сигнал на компьютер. Универсальность этой методики заключается в том, что электроды могут работать в двух режимах: режим регистрации сигнала и режим стимуляции нейронов. В тоже время, МЕА имея большой размер микроэлектродов, улавливает изменения потенциала не только от интересующего нейрона, но и от соседних клеток. Это в свою очередь приводит к неточному анализу активности нейронов. Аналогичная ситуация возникает и при стимуляции – импульс подаётся на группу нейронов.

В этом случае, основываясь на массиве данных о локальных всплесках активности нервных клеток невозможно создать модель нейронной сети. Так как

упускается визуальная оценка культуры клеток. Таким образом, эта методика предоставляет лишь дополнительную информацию для моделирования. В свою очередь для решения ключевой задачи исследования необходим набор данных о структуре нервных клеток, который может быть получен при помощи обработки микроскопических снимков.

2. Обработка снимков микроскопии

Рассмотрим методы обработки снимков для подсчета/определения структуры биологических нейронных связей на основе шиарлет-преобразования с контрастированием цветовым кодированием. Шиарлет-преобразование является современным методом многомерного анализа пространственных данных и изображений. Этот метод отличается возможностью определения анизотропной составляющей в анализируемых экспериментальных данных, что может быть применимым для решения задач обработки сложных изображений.

Направленное многомасштабное представление изображений для выделения и интерпретации криволинейных сингулярностей получило большое внимание в гармоническом анализе за последние 25 лет. Понятия, связанные с шиарлет-преобразованием (сдвиговое), изучаются в работах [7-9]. Формулы преобразования имеют однородную конструкцию как для непрерывного, так и для дискретного вариантов.

В [7] представлен алгоритм, называемый «Быстрое дискретное шиарлет-преобразование» (FFST). Он основан на дискретном быстром прямом и обратном преобразовании Фурье. Вейвлет Мейера используется в качестве материнского вейвлета. Альтернативный подход к вычислению преобразования сдвига, называемый «ShearLab», описан в [8-9]. Данная реализация основана на дискретном быстром преобразовании Фурье; однако этот алгоритм интерпретирует частотный диапазон несколько иначе.

Алгоритм FFST позволяет решать задачи построения контуров объекта интереса на изображении. В нем представление контуров формируется как сумма коэффициентов преобразования фиксированных значений параметров для последнего сдвига шкалы и различных значений параметров:

$$f_{cont} = \sum_{k=0}^{k_{\max}} \sum_{m=0}^{m_{\max}} sh_{\psi}(f(j^*, k, m))$$

где sh_{ψ} коэффициент сдвига для шкалы j^* поворота (ориентации) k и смещения m , $k_{\max}$ – максимальное число поворотов, $m_{\max}$ – максимальная величина смещения.

В качестве вычислительного инструментария для анализа и выделения внутренних геометрических черт исследуемой ткани предлагается вычислительная методика решения задачи количественного морфологического (геометрического) представления визуальных данных на основе шиарлет-преобразований [10]. При этом также используется алгоритм коррекции параметров освещения для серии снимков на основе технологии Retinex [11].

При проведении микроскопии выявляются не только клетки центральной нервной системы, но и клетки крови. Поэтому выделенные объекты на

микроскопическом снимке, для определения своего типа, анализируются и дифференцируются по морфоструктуре. Это позволяет отдельно визуализировать интересующие клетки. Нейроны легко отличить от других типов клеток благодаря наличию характерных отростков, присущих только им.

Методика решения задачи выделения нейронов и их связей на основе шиарлет-преобразования и контрастирования цветовым кодированием состоит из следующих этапов.

- Постановка задачи количественного геометрического (морфологического и текстурного) анализа изображений на выделение и сегментацию объектов интереса, а также его цветовую визуализацию, подбор вариантов исходных снимков.
- Компьютерная предобработка исходных снимков для устранения возможной шумовой составляющей, а также для повышения контраста и коррекции яркостных характеристик изображений. Форматирование выделенного набора исходных снимков для получения расчетных изображений и их численного анализа на основе алгоритмов шиарлет-преобразования (спектральная декомпозиция с учетом геометрических особенностей и анизотропии).
- Настройка параметров расчетного алгоритма шиарлет-преобразования и шкалы цветового кодирования изображений для решения поставленной задачи. Сравнительный анализ первых вариантов расчета исходных изображений для выделения эталонов различных объектов интереса на снимках.
- Сравнительная классификация эталонов объектов интереса по геометрическим, текстурным и морфологическим признакам. Коррекция исходной шкалы цветового кодирования с учетом выделенных локальных геометрических, текстурных и морфологических особенностей эталонов объектов интереса.
- Численное моделирование расчетных изображений на основе шиарлет-преобразования и установленной шкалы цветового кодирования для получения оптимальной сегментации и цветовой визуализации конкретных объектов интереса. Составление соответствующих таблиц и построение графиков полученных расчетных характеристик для выполнения следующих этапов исследования.

Конечный результат, после многоэтапной обработки снимков, будет содержать в себе карту нейронной сети с информацией о расположении каждого нейрона и его связях с другими клетками. Вся карта может быть разделена по секторам с назначенными координатами. Это позволит определить для каждого нейрона свои индивидуальные координаты. Следовательно, модельное описание нейронной сети не будет ограничена одним микроскопическим снимком. При этом будут учитываться связи с нейронами, которые зафиксированы на множестве других снимков.

3. Моделирование нейронной сети с применением обработанных снимков и модифицированного МЕА

Процесс моделирования нейронной сети осуществляется на основании структуры культуры клеток, полученных с обработанных изображений. Но для полноценной модели требуется и функциональная характеристика нейронов, к которой

относится способность нервных клеток передавать возбуждение на последующую часть нейронного ансамбля [12].

Для оценки функциональной характеристики каждой клетки мы предлагаем модифицированный вариант метода МЭА. Новая версия будет обладать подвижными микроэлектродами, способными самонаводиться на нужные координаты в соответствии с данными от проанализированных микроскопических снимков и взаимодействовать с конкретным нейроном. Контакт микроэлектрода с единственной клеткой позволит изучать её индивидуальные спайки с минимальным шумом от возбуждения соседних клеток [13]. Также новый вариант МЭА позволит регистрировать небольшое отклонение мембранного потенциала от нормы. Это наблюдается при секреции недостаточного количества нейромедиатора для передачи возбуждения от предыдущего нейрона к следующему.

По изменившемуся мембранному потенциалу можно предположительно определить коэффициент эффективности передачи импульса. Имея координаты расположения каждого нейрона и регистрируемые потенциалы с них, появляется возможность объединения этих данных в режиме реального времени. Новый подход позволяет по-новому исследовать физиологию нейронной сети.

На снимке культуры нервных клеток (рис. 1) можно отображать красным цветом максимальное изменение мембранного потенциала, процесс его восстановления – желтым, а восстановленный мембранный потенциал оставить без цветовых изменений. В рамках предлагаемой вычислительной методики на рисунках 2-3 представлены примеры обработки исходных снимков на основе ширлет-преобразования с контрастированием цветовым кодированием (варианты А, Б).




Рис. 1. Культура нервных клеток: а – микроскопическое изображение невозбуждённых нейронов; б – микроскопическое изображение трёх возбужденных нейронов.




Рис. 2. Шиарлет-преобразование исходных снимков и цветовое кодирование (вариант А).




Рис. 3. Шиарлет-преобразование исходных снимков и цветовое кодирование (вариант Б).

Отметим, что вариант цветового кодирования А сильнее контрастирует нервные отростки и нагляднее демонстрирует взаимосвязи между клетками. В свою очередь вариант цветового кодирования Б окрашивает границы нейронов тонкой каймой малинового цвета. Предложенная вычислительная методика позволяет решать различные задачи при интерпретации исходных данных наблюдений.

Заключение

Создание модели биологической нейронной сети очень важная, но сложная задача, так как от нейронов отходит большое количество, хаотично растущих отростков, имеющих синапсы в непредсказуемых местах. Отказавшись от химических методов окраски, мы сохраняем подлинную биологическую структуру и не влияем на дальнейшее развитие. Мы предложили методику, помогающую определить границы клеточной стенки нейронов и позволяющую выявить новые паттерны для дифференциации видов клеток. Для оценки качественной характеристики

микроскопическое исследование может быть скомбинировано с данными от мультиэлектродных массивов на основе модифицированного МЭА, что позволит создать модель, максимально приближенной к реальной.

Список литературы

1. Lichtman J.W. The neuronal naturalist: watching neurons in their native habitat / J.W.Lichtman, S.E.Fraser // *Nat Neurosci.* — 2001. — №4. — С.1215 – 1220.
2. Pimashkin A. Adaptive enhancement of learning protocol in hippocampal cultured networks grown on multielectrode arrays / A.Pimashkin, A.Gladkov, I.Mukhina, V.Kazantsev // *Front Neural Circuits.* — 2013. — V.24. — №7:87.
3. Kaech S. Culturing hippocampal neurons/ S.Kaech, G.Banker // *Nat. Protoc.* — 2006. — №1(5). — P.2406 – 2415.
4. Stosiek C. In vivo two-photon calcium imaging of neuronal networks / C.Stosiek, O.Garaschuk, K.Holthoff, A.Konnerth // *Proc. Natl. Acad. Sci. USA*, 2003. — T.100(12). — P.7319-7324.
5. Grienberger C. Imaging Calcium in Neurons / C.Grienberger, A.Konnerth // *Neuron.* — 2012. — V.73. — Is.5. — P.862 – 885.
6. Мухина И.В. Мультиэлектродные матрицы новые возможности в исследовании пластичности нейрональной сети / И.В.Мухина, В.Б.Казанцев, Л.Г.Хаспеков, Ю.Н.Захаров, М.В.Ведунова, Е.В.Митрошина, С.А.Коротченко, Е.А.Корягина // *Современные технологии в медицине.* — 2009. — №1. — С.8 – 15.
7. Hauser, S. Fast finite shearlet transform: a tutorial. — University of Kaiserslautern, 2010.
8. Lim W-Q (2010) The discrete shearlet transform: a new directional transform and compactly supported shearlet frames // *IEEE Trans. Imag. Proc.*, 2010. — V.19. — P.1166 – 1180.
9. Labate D. Sparse multidimensional representation using shearlets / D.Labate, W-Q.Lim, G.Kutyniok, G.Weiss // *Proc. SPIE 5914, Wavelets XI*, 59140U
10. Zotin A. Tissue Germination Evaluation on Implants Based on Shearlet Transform and Color Coding / A.Zotin, K.Simonov, F.Kapsargin, T.Cherepanova, A.Kruglyakov. — In: Favorskaya M., Jain L. (eds) *Computer Vision in Advanced Control Systems-5. Intelligent Systems Reference Library*, 2020. — V.175. — P.265 – 294.
11. Zotin A.G. Fast algorithm of image enhancement based on multi-scale retinex / A.G.Zotin // *Int. J. Reasoning-based Intelligent Systems.* — 2020. — V.12. — №2. — P.106 – 116.
12. К. В. Анохин, М. С. Бурцев, В. А. Ильин, И. И. Киселев, К. А. Кукин, К. В. Лахман, А. В. Параскевов, Р. Б. Рыбка, А. Г. Сбоев, Н. В. Твердохлебов, “Современные подходы к моделированию активности культур нейронов in vitro / К.В.Анохин, М.С.Бурцев, В.А.Ильин, И.И.Киселев, К.А.Кукин, К.В.Лахман, А.В. Параскевов, Р.Б.Рыбка, А.Г.Сбоев, Н.В.Твердохлебов // *Матем. биология и биоинформ.* — 2012. — Т.7. — №2. — С.372 – 397.
13. Robinson D.A. The electrical properties of metal microelectrodes / D.A.Robinson // *Proceedings of the IEEE.* — 1968. — V.56. — №6. — P.1065 – 1071.

ВНУТРЕННЯЯ СТРУКТУРИРОВАННОСТЬ АНСАМБЛЯ ГЕНОВ тРНК ЧЕЛОВЕКА ПО ЧАСТОТАМ ТРИПЛЕТОВ

Я.В. Недорез¹, М.Г. Садовский^{2,3,4}

¹Сибирский федеральный университет, nedorez.ya@gmail.com

²Институт вычислительного моделирования СО РАН, msad@icm.krasn.ru

³Красноярский государственный медицинский университет имени профессора

В. Ф. Войно-Ясенецкого МЗ РФ

⁴СНКЦ ФМБА России, г. Красноярск

Бурное развитие средств и техник секвенирования генетических данных привело к взрывообразному росту объёма этих данных. Следует сразу подчеркнуть, что такое стремительное развитие техник секвенирования привело на практике к тому, что собранные данные оказываются весьма сильно неоднородными по своему качеству. В этой ситуации встаёт задача анализа больших объёмов многомерных данных, а также выявления ошибок в них с дальнейшей фильтрацией (исключением неполных либо повреждённых данных). Среди всех генетических данных, полученных в последнее время выделяются определённые группы, качество секвенирования которых весьма высоко. К таковым относятся генетические последовательности транспортных тРНК. Для таких «хороших» данных естественным является вопрос о соотношении функции, кодируемой этими последовательностями, структуры и таксономии. Если с понятием таксономии проблем не возникает: в рамках существующей «макроскопической» классификации организмов их таксономия однозначна, то гораздо сложнее всё обстоит со структурой.

В настоящее время исследователи [1] выделяют большое разнообразие структур; не пытаясь в рамках настоящей работы их даже перечислить, сразу укажем ту структуру, которую мы будем исследовать в настоящей работе. Такой структурой будет тринуклеотидный состав исследуемых генов [2 – 4]. Часто [5, 6] его называют частотным словарём триплетов. Следует также подчеркнуть, что понятие функции тоже неоднозначно: одна и та же молекула (нуклеотидная последовательность) может выполнять разные функции. Так, запятая, например, молекула ДНК, кроме кодирования наследственной информации может выступать катализатором некоторых биологических процессов [7]. В рамках настоящей работы мы будем исследовать связь между структурой (триплетный состав), функцией и таксономией, используя весьма специфический генетический материал: гены тРНК человека. Эти гены кодируют специфические РНК, осуществляющие транспорт аминокислотных остатков к месту их сборки в пептиды — рибосомы. По-видимому, гены тРНК являются одними из самых коротких во всём геноме человека. Кроме того, гены тРНК всех организмов отличаются высоким консерватизмом.

Отличительной особенностью генов тРНК является их высокая специализация. Их продукт — транспортная РНК — осуществляет единственную функцию: транспортирует вполне специфический аминокислотный остаток к рибосоме и передаёт его в синтезируемый пептид, если у этой молекулы антикодон соответствует кодону матричной последовательности. Все перечисленные особенности транспортной РНК делают их очень удобным объектом для изучения связи между структурой (триплетным составом), функцией (транспортировкой аминокислотного остатка) и таксономией их

носителей. Целью данной работы является выявление связи между структурой и функцией на примере транспортных РНК человека; связь с таксономией в данном случае не изучается, поскольку все исследуемые объекты принадлежат одному виду (и, возможно, одному организму).

Теперь введём строгие определения и точные понятия: будем рассматривать символьную последовательность и четырёхбуквенного алфавита, соответствующую тому или иному гену; обозначим её длину через N . Будем также считать, что исследуемые последовательности генов являются связанными: они не содержат пробелов. Кроме того, будем считать, что последовательности генов не содержат иных символов, кроме указанных в алфавите.

Частотным словарём триплетов W_3 будем называть список всех триплетов, встречающихся в данном гене. Триплетом $\omega_1, \omega_2, \omega_3 \dots \omega_{64}$ будем называть любые три подряд стоящие нуклеотида. Подчеркнём, что триплеты в частотном словаре W_3 подсчитываются с шагом 1. Переход от символьных последовательностей, соответствующих гену, к частотному словарю преобразует каждый ген тРНК в точку в 63-мерном евклидовом пространстве, координатами в котором являются частоты соответствующих триплетов. Поскольку сумма всех 64 триплетов равна единице, постольку все точки, соответствующие генам тРНК будут лежать на 63-мерной гиперплоскости размерности 1. Формально в данной ситуации можно исключить любой из триплетов из рассмотрения. Мы исключили триплет, имеющий наименьшее стандартное отклонение, определяемое по всему множеству изучаемых последовательностей. Обоснование такому выбору просто: предположим, что значение частоты данного триплета у всех последовательностей одинаково. Это значит, что с точки зрения этого триплета никакого различия между последовательностями нет. Соответственно, триплет, имеющий наименьшее стандартное отклонение, даёт наименьший вклад в различимость последовательностей, и поэтому его исключение является наиболее целесообразным.

Анализируемые данные были получены из Genomic tRNA Database (GtRNAdb) [8], базы данных, содержащей исключительно гены транспортной РНК, обнаруженных и предсказанных в геномных последовательностях разных организмов. База данных содержит исчерпывающий список всех используемых в данном исследовании 416 генов тРНК из ядерного генома человека. Данные были предоставлены Genome Reference Consortium в феврале 2009 г.

Переход от анализа нуклеотидных последовательностей к анализу их частотных словарей позволяет привлечь богатый арсенал средств анализа многомерных метрических данных. Основной задачей нашей работы является выявление внутренней структурированности массива данных: проверка того, что, во-первых, точки, соответствующие генам различных тРНК, формируют в пространстве частот сравнительно плотные кластеры, а во-вторых, каждый из выявленных кластеров содержит по преимуществу гены, обеспечивающие транспорт одной и той же аминокислоты.

Изучение внутренней структурированности данных проводилось при помощи свободно распространяемого ПО ViDaExpert [9, 10]. Выявление кластеров во множестве генов осуществлялось методом упругих карт; этот метод позволяет визуализовать и кластеризовать многомерные данные. Кратко опишем суть метода упругих карт. На

первом шаге на множестве данных определяются первая и вторая главные компоненты. На них, как на осях, строится плоскость, на которую проектируются все точки. На втором шаге на этой плоскости выбирается минимальный квадрат, содержащий все проекции данных, и каждая точка соединяется со своей проекцией математической пружиной. Эта пружина имеет бесконечную растяжимость, и её упругие свойства не меняются по мере растяжения. Коэффициент жесткости одинаков для всех пружин. На третьем шаге выделенный минимальный квадрат заменяется на упругую однородную мембрану, и вся система отпускается так, чтобы она достигла минимума суммарной энергии деформации. Следует подчеркнуть, что на практике используется немного отличающаяся схема построения упругой карты. Минимальный квадрат покрывается решеткой размера $k \times k$, и прообразу каждой из точек соединяются не с прообразом этой проекции, а с ближайшим к этому образу узлом решетки. Тем самым, упругая мембрана заменяется на кусочно-линейную упругую мембрану, в которой каждая ячейка решетки может претерпевать деформации, описанные аффинным преобразованием, оставаясь при этом плоской. После того, как минимум суммарной энергии деформации упруго кусочно-линейной мембраны и математических пружин достигнут, положение образа каждой точки данных переопределяется: находится её ортогональная проекция на деформированной мембране.




Рис. 1. — Распределение генов, кодирующих изоакцепторы разных аминокислот. Обозначения разных аминокислот предоставлены на легенде слева.

На четвёртом шаге математические пружины удаляются, и мембрана принимает прежнее расправленное состояние; при этом «распрямлении» упругой карты (переходе к новым внутренним координатам) некоторые из образов сближаются, а некоторые,

наоборот, удаляются. И именно картина распределения образов во внутренних координатах и отображает внутреннюю структуру множества данных.

Приведенные ниже результаты показывают, что функция генов тРНК преобладает над структурой: анализируемые последовательности имеют тенденцию группироваться в чётко обособленные кластеры, которые однозначно выделяются на упругой карте по локальной плотности. Проверка состава этих кластеров показала, что они обладают чрезвычайно высокой однородностью. Кластеры можно условно разделить на две группы: в первую входят кластеры, целиком состоящие из генов, кодирующих изоакцепторы (тРНК, несущие одну и ту же аминокислоту). Доля изоакцепторных кластеров составляет 83%. Вторую группу составляют кластеры, включающие в себя генов разных изоакцепторов; однако, несмотря на это, доля генов одного изоакцептора в таких кластерах преобладает над остальными (примерное соотношение — 2:5).

Рисунок 1 иллюстрирует данное наблюдение. На рисунке показана тенденция распределения генов тРНК на мягкой эластичной карте размером 16×16 (карта снабжена «шахматной» системой координат, где горизонтальные ячейки соответствуют буквенным обозначениям, а вертикальные — числовым).




Рисунок 2. — Гены, кодирующие изодекодеры

а) тРНК-Phe

AUA
AUC
AUU

б) тРНК-Leu

UUA
UUG
CUC, CUU
CUA
CUG

в) тРНК-Lys

AAG
AAA

Следующее наблюдение состоит в том, что в некоторых случаях гены изодекодеров (тРНК, несущих одну и ту же аминокислоту, но имеющих разные антикодоны) группируются обособленно друг от друга. Такой характер распределения проиллюстрирован на Рисунке 2, где на примере генов, кодирующих изоакцепторы изолейцина, лейцина и лизина, видно расщепление генов разных изодекодеров на разные кластеры.

Картина распределения генов по кластерам, представленная в настоящей работе, по всей видимости, является универсальной: на уровне генов функция является ведущей характеристикой, определяющей структуру распределения частотных словарей триплетов в частотном пространстве. Действительно, в работах [3, 4] показано, что гены различных АТФ-синтаз митохондрий грибов распределяются в пространстве частот триплетов на три кластера, и состав этих кластеров целиком определяется функцией

соответствующей единицы АТФ-синтазы. Аналогично, гены фотосистемы 1, локализованный в хлоропластах различных растений, также образуют весьма плотные кластеры, определяемые функцией. Противоположная картина наблюдается на уровне генома: так, в работе [11] показано, что распределение геномов митохондрий различных животных в пространстве частот триплетов, определённых по всему геному в целом, практически полностью определяется таксономией носителя соответствующего генома.

Список литературы

1. Marchet C, Boucher C, Puglisi SJ, Medvedev P, Salson M, Chikhi R. Data structures based on k-mers for querying large collections of sequencing data sets. *Genome Research*. 2021 Jan 1;31(1):1-2.
2. Sadovsky, M.G., Senashova, M.Y. and Malyshev, A.V., 2020. Amazing symmetrical clustering in chloroplast genomes. *BMC bioinformatics*, 21(2), pp.1-14.
3. Sadovsky MG, Fedotovskaia V. Comparative analysis of triplet composition of common mitochondrial and chloroplast genes of the same species. *bioRxiv*. 2020 Jan 1.
4. Fedotovskaya V, Sadovsky M, Kolesnikova A, Shpagina T, Putintseva Y. Function vs. Taxonomy: Further Reading from Fungal Mitochondrial ATP Synthases. In *IWBBIO 2020* May 6 (pp. 438-444).
5. Bugaenko, N.N., Gorban, A.N. & Sadovsky, M.G. Maximum Entropy Method in Analysis of Genetic Text and Measurement of its Information Content. *Open Systems & Information Dynamics* 5, 265–278 (1998).
6. Бугаенко НН, Горбань АН, Садовский МГ. Информационная емкость нуклеотидных последовательностей и их фрагментов. *Биофизика*. 1997;42(5):1047-53.
7. Silverman SK. Catalytic DNA: Scope, Applications, and Biochemistry of Deoxyribozymes. *Trends Biochem Sci*. 2016 41(7):595-609.
8. de Crécy-Lagard V, Ross RL, Jaroch M, Marchand V, Eisenhart C, Brégeon D, Motorin Y, Limbach PA. Survey and validation of tRNA modifications and their corresponding genes in *Bacillus subtilis* sp *subtilis* strain 168. *Biomolecules*. 2020, 10(7):977.
9. Montagud A, Traynard P, Martignetti L, Bonnet E, Barillot E, Zinovyev A, Calzone L. Conceptual and computational framework for logical modelling of biological networks deregulated in diseases. *Briefings in bioinformatics*. 2019 Jul;20(4):1238-49.
10. Bondarev AE. The procedures of visual analysis for multidimensional data volumes. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Inform. Sciences*. 2019 May 13;42:2.
11. Yu. Putintseva, A. Chernyshova, V. Fedotova, M.Sadovsky Genome structure of organelles strongly relates to taxonomy of bearers // *LNBI*, vol.9043, Part II, 2015, pp.481 – 490.

ВЫЯВЛЕНИЕ НЕКОТОРЫХ ТЕНДЕНЦИЙ ИЗМЕНЕНИЯ СОДЕРЖАНИЯ УЧЕБНЫХ ПЛАНОВ МАГИСТРАТУРЫ НАПРАВЛЕНИЯ «СИСТЕМНЫЙ АНАЛИЗ И УПРАВЛЕНИЕ» С ПОМОЩЬЮ МЕТОДА UGVA В УСЛОВИЯХ РЕАЛИЗАЦИИ ФГОС ВО 3++

Д.А. Проценко

Сибирский федеральный университет, *daryapro@mail.ru*

Введение

В 2019-2020 гг. в России вступили в силу новые федеральные образовательные стандарты ФГОС ВО 3++, основной акцент в которых сделан на интеграцию трудовых функций из профессионального стандарта и профессиональных компетенций выпускника. ФГОС ВО 3++ приводят перечень применимых профессиональных стандартов, которыми отныне обязано руководствоваться высшее учебное заведение при составлении образовательных программ. Профессиональные компетенции теперь должны определяться вузом самостоятельно с учётом профиля программы подготовки и требований рынка труда. Кроме этого ФГОС ВО 3++ не содержат перечня обязательных учебных дисциплин, и вузы получили право самим определять состав учебных дисциплин базовой части учебной программы. Гибкому формированию учебной программы также способствует наличие большой вариативной части.

Данные нововведения не могли не сказаться на содержательном наполнении учебных программ. В настоящее время вузы обновляют свои образовательные программы в соответствии с новыми требованиями. Возникает вопрос: как оценить влияние новых возможностей, появившихся у вузов, на предлагаемые ими учебные программы? Привело ли внедрение последней версии стандарта только к формальной смене учебных планов или вузы используют полученную свободу действий для реальных положительных изменений в содержании образования?

Конкретизируем наш анализ, взяв для сравнения программы подготовки магистров по направлению 27.04.03 «Системный анализ и управление» Сибирского федерального университета [1] и Национального исследовательского ядерного университета «МИФИ» [2], разработанные ими в соответствии с требованиями ФГОС ВО 3+ и ФГОС ВО 3++.

Сравнение учебных планов методом UGVA

Сравнение учебных планов представляет собой сложную задачу многопараметрического сравнения объектов. Чтобы существенно облегчить анализ на основе множества параметров, целесообразно использовать их визуальное представление. Графический образ в максимально информативной форме может отразить значимые параметры исследуемого объекта. Не все методы визуального представления данных могут быть применимы для нашего объекта исследования. Наиболее подходящим для нас является метод унифицированного графического воплощения активности UGVA [3], основанный на идеях американского математика Г. Чернова [4], предложившего соотносить параметры исследуемого объекта с элементами лица человека, и В. А. Филимонова [5], использовавшего вместо лица фигуру человека. Метод унифицированного графического воплощения активности опирается на ещё более содержательный по структуре образ человека и подходит для оценки и

визуализации баланса содержания учебных программ и их сравнения между собой.

Частная параметрическая модель для направления подготовки 27.04.03 «Системный анализ и управление» и вариант её визуализации описаны в [6]. Вид данной модели в нотации UGVA представлен на рисунке 1.




Рис. 1. Частная модель визуализации содержания учебных планов для направления подготовки 27.04.03 «Системный анализ и управление» по методу UGVA

Предложенная модель основана на следующих критериях – профессиональных умениях (ПУ), которые используются при сравнении учебных планов между собой:

- владение методами анализа сложных систем (ПУ1);
- владение методами синтеза сложных систем (ПУ2);
- владение методами эффективного управления сложными системами (ПУ3);
- использование информационных технологий для решения прикладных задач (ПУ4);
- моделирование сложных систем и процессов (ПУ5);
- способность решать инженерные задачи в области специализации (ПУ6);
- прочее (ПУ7).

Элементы визуального образа отдельно кодируют выделенные группы ПУ, формируемые учебными дисциплинами базовой и вариативной части учебного плана. Размеры элементов варьируются в зависимости от задаваемых параметров. Параметры для отрисовки образа получаются в результате расчёта по методике [3], использующей в качестве исходных данных экспертные оценки, выставленные для каждой представленной в учебном плане учебной дисциплины и характеризующие её вклад в формирование выделенных ПУ. Отрисовку образов в нотации UGVA осуществим с помощью сервиса, расположенного на Интернет-ресурсе <https://aesu.ru>.

Представленный образ отражает как соотношение ключевых групп ПУ, так и интегральную характеристику сбалансированности содержания учебного плана (определяет выражение «лица»). Под сбалансированностью δ понимается степень отклонения соотношения предлагаемых в учебном плане дисциплин, формирующих выделенные ПУ, от равно пропорционального вклада [3].

Воспользуемся предложенной частной моделью для направления подготовки 27.04.03 «Системный анализ и управление» и построим визуальные образы содержания

выбранных нами учебных программ, чтобы провести их анализ и наглядное сравнение. Визуальные образы содержания учебных планов для профиля подготовки 27.04.03.06 «Основы проектирования космических аппаратов» Сибирского федерального университета (СФУ) представлены на рисунке 2. Слева показан образ учебного плана, разработанного в соответствии с ФГОС ВО 3+, а справа приведён визуальный образ содержания учебного плана, обновлённого в связи с внедрением ФГОС ВО 3++.




Рис. 2. Визуальные образы содержания учебных планов программы магистратуры 27.04.03.06 «Основы проектирования космических аппаратов» СФУ, разработанные в соответствии с требованиями ФГОС ВО 3+ (слева) и ФГОС ВО 3++ (справа)

Красным цветом обозначены те элементы образа, показатели которых отсутствуют. Явно видно, как сместились акценты содержательного наполнения данного учебного плана при переработке. Наложим два образа друг на друга, что позволит более наглядно обозначить отличия содержания двух рассматриваемых учебных планов (рисунок 3).




Рис. 3. Наложение визуальных образов содержания учебных планов программы магистратуры 27.04.03.06 «Основы проектирования космических аппаратов» СФУ

Зелёным цветом на рисунке отмечено увеличение значений параметров образа учебного плана, разработанного в соответствии с требованиями ФГОС ВО 3++, относительно параметров образа предыдущего учебного плана, разработанного в соответствии с требованиями ФГОС ВО 3+. Синим цветом обозначено уменьшение соответствующих значений этих параметров.

В новом учебном плане, предлагаемом СФУ с 2021 г., увеличена доля вклада профилирующих дисциплин (ПУ6), выраженная в размере «шляпы». «Шляпа» приобрела свои максимальные допустимые размеры.

Плечо «левой руки» во втором образе уменьшилось, что указывает на сокращение в базовой части учебного плана вклада учебных дисциплин, формирующих ПУ4 (использование информационных технологий). В вариативной части учебного плана («предплечье») дисциплины, направленные на использование информационных технологий для решения прикладных задач, отсутствуют совсем.

Верхняя часть «корпуса» второго образа уменьшилась в размере. Это означает, что часть дисциплин, формирующих ПУ5 (математическое моделирование сложных систем), была убрана из базовой части учебного плана. Надо отметить, что в предыдущем образе размеры этой части (верхняя часть «корпуса») были близки к оптимальному показателю. Нижняя часть «корпуса» во втором образе отсутствует, то есть в вариативной части нового учебного плана дисциплины, формирующие ПУ5, не представлены.

Часть дисциплин, направленных на общую подготовку, была перенесена из вариативной в базовую часть, благодаря чему их показатель для вариативной части учебного плана достиг оптимального значения (высота верхней части «таза») и несколько улучшился для базовой части (длина верхней части «таза»). Что касается ПУ, относящихся к специфике направления подготовки (методы анализа, синтеза и управления), то показатели их вклада остались приблизительно на том же уровне, то есть количество учебных дисциплин, формирующих эти ПУ, в вариативной части близко к минимальному значению, а показатель для базовой части близок к оптимальному.

В целом, значение сбалансированности содержания данной учебной программы, кодируемое с помощью выражения «лица», снизилось, что безусловно скажется на качестве получаемого образования в рамках данной программы подготовки.

Теперь рассмотрим и проанализируем содержательные изменения, вызванные внедрением ФГОС ВО 3++, в ещё одной программе рассматриваемого нами направления подготовки. Используя ту же частную модель, построим визуальные образы содержания учебных планов программы магистратуры 27.04.03 «Системная инженерия искусственных систем», предлагаемой Национальным исследовательским ядерным университетом «МИФИ» (НИЯУ МИФИ). Визуальные образы показаны на рисунке 4.




Рис. 4. Визуальные образы содержания учебных планов программы магистратуры «Системная инженерия искусственных систем» НИЯУ МИФИ, разработанные в соответствии с требованиями ФГОС ВО 3+ (слева) и ФГОС ВО 3++ (справа)

Видно, что по большому счёту учебный план не претерпел каких-либо значительных изменений. Как и в предыдущем случае, наложим полученные образы друг на друга для более чёткого выявления отличий (рисунок 5).

Мы видим, что доля вклада отраслевых дисциплин при смене учебного плана была незначительно изменена, но осталась на уровне, близком к оптимальному. При этом часть учебных дисциплин, отражающих отраслевую специализацию подготовки, была перенесена из вариативной части учебного плана в базовую часть.

Доля вклада учебных дисциплин, формирующих профессиональные умения, связанные с использованием методов анализа, синтеза и управления, была несколько увеличена в базовой части учебного плана, благодаря чему этот показатель принял оптимальное значение. При этом вклад этого ПУ, формируемый учебными дисциплинами вариативной части, уменьшен не был и остался на прежнем уровне.




Рис. 5. Наложение визуальных образов содержания учебных планов программы магистратуры 27.04.03 «Системная инженерия искусственных систем» НИЯУ МИФИ

Левая «рука» образа претерпела незначительные изменения в районе «предплечья», демонстрируя незначительное сокращение вклада ПУ4 (использование информационных технологий), формируемого дисциплинами вариативной части. Однако, этот показатель лишь незначительно сместился от оптимального уровня. Что касается базовой части, то значение этого показателя не изменилось и осталось на прежнем уровне.

Вклад ПУ5 (математическое моделирование сложных систем) остался примерно на том же уровне. Вариативная часть была несколько уменьшена (нижняя часть «корпуса»), за счёт чего показатель несколько ухудшился. Базовая часть (верхняя часть «корпуса») немного увеличилась, но всё ещё остаётся недостаточной для формирования оптимального показателя.

В целом следует отметить, что, несмотря на значительное увеличение количества дисциплин в базовой части учебного плана, это было сделано не в ущерб вариативной части, которая была дополнена дисциплинами, непосредственно формирующими ключевые ПУ рассматриваемого направления подготовки (анализ, синтез, управление, IT-технологии, мат. моделирование), благодаря чему показатель сбалансированности содержания нового учебного плана не ухудшился, а общее количество ключевых дисциплин, формирующих необходимые компетенции, возросло.

Сравнение содержания учебных программ, актуализируемых вузами в связи с обновлением требований федеральных стандартов, при помощи метода унифицированного графического воплощения активности позволяет отслеживать, выявлять и корректировать отрицательные тенденции, которые могут негативно сказаться на качестве услуг, предоставляемых образовательной организацией.

Заключение

Обновлённые стандарты ФГОС ВО 3++ предоставили высшим учебным заведениям широкие возможности для усовершенствования учебных программ в рамках различных направлений подготовки, что позволяет вузам максимально полно учесть отраслевую специализацию и требования региональных рынков труда.

В этих условиях крайне актуальной становится задача разработки оптимальных учебных программ, повышающих качество подготовки выпускников за счёт надлежащего уровня сформированности ключевых профессиональных умений. Реализация требований обновлённых ФГОС предполагает большую ответственность самого высшего учебного заведения при актуализации содержания предлагаемых учебных программ.

В статье представлены результаты анализа изменений содержательного наполнения учебных планов магистратуры направления 27.04.03 «Системный анализ и управление», предлагаемых Сибирским федеральным университетом и Национальным исследовательским ядерным университетом «МИФИ» в условиях реализации ФГОС ВО 3++. Оценка баланса содержания, визуальное представление и сравнение учебных планов методом UGVA показали, что только от самого вуза и составителей учебных

программ зависит, насколько сильно и в каком направлении будут смещены акценты при смене учебных планов, и каким образом это повлияет на качество подготовки специалистов. Грамотное использование самостоятельности, предоставляемой федеральными стандартами нового поколения при составлении новых учебных планов, позволяет высшему учебному заведению оперативно реагировать на запросы рынка труда, повысить востребованность программы подготовки и достойно конкурировать на рынке образовательных услуг.

Список литературы

1. Учебный план магистратуры «Системный анализ и управление» [Электронный ресурс] // Сибирский федеральный университет [сайт]. – Красноярск, 2021. – Режим доступа: <http://edu.sfu-kras.ru/programs#show>.
2. Учебный план магистратуры «Системный анализ и управление» [Электронный ресурс] // Национальный исследовательский ядерный университет «МИФИ» [сайт]. – Москва, 2021. – Режим доступа: http://eis.mephi.ru/AccGateway/index.aspx?report_param_gosn=3&report_param_ismagister=true.
3. Углев В.А. Метод унифицированного графического воплощения активности (UGVA) / В. А. Углев // Робототехника и искусственный интеллект: Материалы XI Всероссийской конференции с международным участием. – Красноярск: ЛИТЕРА-принт, 2019. – С. 161-172. doi: 10.13140/RG.2.2.15680.46088.
4. Chernoff, H. The Use of Faces to Represent Points in K-Dimensional Space Graphically / H. Chernoff // Journal of the American Statistical Association. – 1973. – Vol. 68, № 342. – P. 361–368. – Режим доступа: <http://www.jstor.org/pss/2284077>.
5. Филимонов, В. А. Применение простого конструктора «4 уровня» для обеспечения научной новизны публикаций [Электронный ресурс] // DOI: 10.13140/RG.2.2.24636.90240 (<https://www.researchgate.net/publication/332250190>).
6. Углев В. А. Оценка баланса нагрузки по учебной программе магистратуры направления «Системный анализ и управление» методом UGVA / В.А. Углев, Д.А. Проценко // Робототехника и искусственный интеллект: Материалы XII Всероссийской конференции с международным участием. – Красноярск: ЛИТЕРА-принт, 2020. – С. 227-235.

ТЕХНОЛОГИЯ СОЗДАНИЯ ГИБРИДНЫХ ЭКСПЕРТНЫХ СИСТЕМ С НЕЙРОСЕТЕВЫМИ КОМПОНЕНТАМИ В АНАЛИТИЧЕСКИХ ИНФОРМАЦИОННЫХ СИСТЕМАХ ОРГАНИЗАЦИЙ.

О.И. Пятковский

Алтайский государственный технический университет им. И.И. Ползунова

Современные комплексные информационные системы, применяющиеся для эффективного управления социально-экономическими объектами, являются очень сложными с многочисленными функциональными и обеспечивающими компонентами. Они поддерживают полный жизненный цикл основного объекта изделия, товара услуги и все фазы эффективного управления предприятием. Для реализации этих требований необходимо построение адекватных моделей проблемной области, обеспечивающих достижение целей и эффективных траекторий развития предприятий.

Для решения задач эффективного управления предприятием необходимо построение гибридных мультиагентных экспертных систем [3,6] с нейросетевыми компонентами, обеспечивающих эффективную поддержку принятия решений на всех уровнях и фазах управления, стадиях жизненного цикла продукта, услуги.

Основным достоинством нейросетевых компонентов в мультиагентных гибридных экспертных системах является их возможность самоорганизации в непрерывно изменяющихся в реальном масштабе времени динамических бизнес-процессах в организации [1,2].

В статье представлены вопросы создания аналитических систем с применением нейросетевых компонентов. Основным объектом исследований является не решение отдельных задач в информационной системе, а вопросы проектирования и эксплуатации комплексных систем нейросетевыми компонентами. Эффективная работа таких систем на реальном объекте возможна только при реализации определенных требований при их создании.

В процессе развития аналитических информационных систем осуществляется непрерывный прямой и обратный реинжиниринг бизнес - процессов предприятия [8].

В процессе обратного реинжиниринга разрабатывается модель функционирования предприятия «Как-есть». Она отображает адекватное представление о действующих процессах в организации. Моделирование системы управления предприятием выполняется на основе непрерывного глубокого изучения проблемной области.

Изучение проблемной области определяется следующей последовательностью операций. При разработке поля знаний [6], работающей информационной системы, используются различные методы решения задач [7]. В том числе в задачах поддержки принятия решений выполняются неформализованные алгоритмы, основанные на накопленной информации в базах знаний. Для изучения и построения алгоритмов решения задач используются методы извлечения знаний, основанные на как на текстологических, так и на коммуникативных методах (активных и пассивных) [6]. Наиболее эффективными являются методы количественного и качественного

экспертного оценивания [9]. Целью сбора данных и извлечения знаний является создание моделей, адекватных предметной области.

На основе изученных материалов составляется (уточняется) подробное описание предметной области. Созданная комплексная модель проблемной области определяет следующие составляющие в различных стратах ее описания: 1) теоретико-множественное описание предметной области (внутренние, внешние ее элементы и связи в системе); 2) графическое, структурное и теоретико-множественное описание иерархической структуры целей деятельности предприятия; 3) модели структур предприятия, реализующих цели (производственная, технологическая, организационная); 4) совокупность технологий (методов, инструментальных средств и алгоритмов), реализующих систему; 5) внутренние и внешние факторы, влияющие на ее создание и функционирование; 6) модели функциональной части системы - методов и технологий управления предприятием (структурную функциональную матрицу и ее описание, диаграмму прецедентов, диаграммы бизнес-процессов: структурный, объектный, процессно-ориентированный, операционно-ориентированный подходы); 7) модели баз данных и знаний; 8) условия и факторы, влияющие на создание и функционирования системы; 9) описание компонентов обеспечивающих подсистем; 10) программную реализацию всех компонентов системы и ее подробное описание.

Модели должны быть адекватными, отображать все функции и, в том числе, базовые. Для описания моделей используются методологии ARIS, UML, а также стандартные системы программирования.

На втором этапе – «прямого» реинжиниринга проводятся исследование и анализ разработанных моделей «Как есть» - с выявлением недостатков системы во всех ее компонентах. На основе маркетинговых исследований, глубокого анализа разработанной модели деятельности предприятия, методов и алгоритмов решения задач, изучения передовых технологий управления и инновационных разработок в стране и за ее пределами, научных достижений в области создания и эксплуатации информационных систем определяются недостатки и направления развития системы. В процессе «прямого» реинжиниринга создается новая модель действующего предприятия «Как должно быть». Структура и описание данной модели аналогична выше - изложенной «Как есть».

Рассмотрим особенности построения гибридной экспертной системы с нейросетевыми компонентами в составе доработанной (созданной новой) модели управления предприятием. За основу разработки поля знаний берется структурное описание процессов деятельности организации. В нем отражена иерархическая структура всех взаимосвязанных показателей, рассчитываемых в аналитической информационной системе. Данное структурное описание отражает также целевые вершины всех решаемых задач и однозначно переводится в дерево целей аналитической системы, определяющее поле знаний системы.

На первом этапе – формирования функциональной структуры системы используются методы извлечения знаний, том числе методы экспертного оценивания наиболее эффективными из которых являются методы анкетирования «Дельфи», и обработки степени согласованности экспертов по методике Кендэла [9].

Следующим этапом структурно-функционального описания системы является определение методов решения задач для определения значений показателей в узлах графа поля знаний. Как правило, неформализованные задачи реализуются в фазах планирования, оценки и прогнозирования. Формализованные задачи решаются в основном в управленческих фазах учета и планирования. Для решения формализованных задач используются известные методы расчета показателей в экономике, в том числе экономико-математические аналитические модели [7]. Для решения неформализованных задач оценки, прогнозирования, планирования, необходимы экспертные знания, базы знаний, анализ данных с помощью математического аппарата нейросетевых технологий и экспертных систем с различными моделями представления знаний.

Основной проблемой для внедрения нейросетевых компонентов в поле знаний аналитической системы является сложность и динамичность информационных систем. Решение, принимаемое на основе экспертных систем, эффективно только в реальном масштабе времени. Например, число компонентов нейросетевого прогнозирования продаж товаров соответствует числу товаров во всех магазинах торгующей организации. Для многих сетей магазинов это очень большое значение. Также следует иметь в виду, что тестирование системы и в том числе проверка адекватности нейросетевых моделей возможна только в составе реально-работающей комплексной информационной системы. Это подтверждает невозможность настройки нейросетевых компонентов автономно вне действующей информационной системы. Из этого следует необходимость комплексного проектирования систем со всеми этапами их жизненного цикла и компонентами. Технология этого процесса была представлена выше.




Рис. 1. Структура нейросетевого компонента.

Разработанная структура нейросетевого компонента (рисунок 1)[3,4] обеспечивает реализацию его самообучающихся возможностей. Основными

компонентами, реализующими автоматическое самообучение нейроимитатора, являются конструктор, контрастер, учитель, оценка и управляющий модуль.

На рисунке 2 представлен процесс функционирования нейросетевого решателя в режиме автоматического самообучения. В данной схеме показано подключение экспертной системы при формировании управляющего сигнала для переключения нейросетевого решателя в режим самообучения и автоматизированного формирования значений целевого параметра $\bar{Y}$ перед дообучением нейронной сети. Перевод нейроимитатора в режим самообучения определяется управляющими коэффициентами $\bar{K}$. Они формируются на основе определения расстояния вектора текущих значений показателей до значений вектора при последнем обучении сети. Если расстояние достигает величины отклонения $\bar{\varepsilon}$, управляющая экспертная система подключает блок формирования значений целевого параметра $\bar{Y}$ для обучающей выборки нейронной сети. После его формирования вырабатывается сигнал на включение режима самообучения. Величина отклонения $\bar{\varepsilon}$ подбирается экспериментальным путем при проектировании информационной системы [4].




Рис. 2. Функционирование нейросетевого решателя в режиме самообучения

Блок автоматизированного формирования значений целевого параметра $\bar{Y}$ задачника нейросети работает перед ее обучением по сигналу управляющей экспертной системы. Наиболее качественные данные задачника получаются на основе фактической выборочной,

экспериментальной информации, в том числе по данным происшедших событий, выполненных опытов и экспериментов. Такие способы приемлемы для решения задач прогнозирования. При решении неформализованных задач оценки состояния объекта управления, получение значения целевого параметра экспериментальным путем бывает невозможно. В этом случае используется экспертная информация, формируемая опытными специалистами в соответствующей области знаний. Для обработки этой информации используются методы экспертной оценки [9]. Эти данные при проектировании системы анализируются инженерами – когнитологами и накапливаются в базе знаний управляющей экспертной системы.

Программная реализация системы выполнена на основе разработанных программно - инструментальных комплексов с WEB-сервисами: «Бизнес-аналитик», «Нейроаналитик», обладающими адаптивными свойствами, для реализации представленных в статье технологий самоорганизации. [4,5].

Разработанная технология создания гибридных экспертных систем с нейросетевыми компонентами была опробована при проектировании систем управления торгово-сервисными и производственными предприятиями и показала эффективность ее использования.

Список литературы

1. Горбань А.Н. Обучение нейронных сетей / А.Н. Горбань. - М.: изд. СССР-США СП "ParaGraph", 1990. - 159с.
2. Миркес Е.М. Нейрокомпьютер. Проект стандарта / Е.М. Миркес. - Новосибирск: Наука. Сибирское предприятие РАН, 1999. - 337с.
3. Пятковский О.И. Интеллектуальные компоненты автоматизированных информационных систем управления предприятием: Монография / О.И. Пятковский. - Барнаул: изд-во АлтГТУ, 1999. - 351с.
4. Авдеев А.С., Пятковский О.И. Адаптивная модель прогнозирования временных рядов на примере продаж автомобилей в регионе // Нейроинформатика, её приложения и анализ данных: материалы XVII Всеросс. Семинара / ИВМ СО РАН. – Красноярск, 2009. – С. 9–12.
5. Авдеев А.С., Гунер М.В., О.И. Пятковский О.И. Разработка WEB – сервисов интеллектуальной информационной системы «Бизнес-аналитик» и их применение при решении задачи оценки инвестиционных проектов» // Нейроинформатика, её приложения и анализ данных: материалы XVII Всеросс. Семинара / ИВМ СО РАН. – Красноярск, 2013. – С. 111–117.
6. Гаврилова, Т.А. Базы знаний интеллектуальных систем / Т. А. Гаврилова, В.Ф. Хорошевский – СПб.: Питер, 2000. – 384с.
7. Волкова В.Н. Теория систем: Учеб. Пособие/ В.Н. Волкова, А.А. Денисов. - М.: Высш.шк., 2006.-511 с.: ил.
8. Ойхман Е.Г., Попов Э.В. Реинжиниринг бизнеса: Реинжиниринг организаций и информационные технологии. -М.Финансы и статистика, 1997.-336 с.: ил.
9. Воронов А. А. Теоретические основы построения автоматизированных систем управления: Разраб. техн. задания / А.А. Воронов, Г.А. Кондратьев, Ю.В. Чистяков ; АН СССР, Дальневост. науч. центр, Ин-т автоматизации и процессов управления. - Москва : Наука, 1977. - 232 с.: ил.

ОБОСНОВАНИЕ ПРОЦЕССА ОБУЧЕНИЯ ЭКСПЕРТНОЙ НЕЙРОННОЙ СЕТИ ПРИ ИСПОЛЬЗОВАНИИ ПАРАЛЛЕЛЬНЫХ ВЫЧИСЛЕНИЙ В ОБЛАЧНОМ СЕРВИСЕ

Тимофеев М.Н.¹, Ковалева О.А.^{1,2}

¹ФГБОУ ВО «Тамбовский государственный университет имени Г.Р. Державина»,

²ФГБОУ ВО «Тамбовский государственный технический университет»

Аннотация. В данной статье разработаны теоретические положения алгоритма построения нейросетевых средств оценивания параметров параллельных вычислений экспертных данных в облачном сервисе при решении класса задач - выявлении сбоев и точности параллельных вычислений экспертных данных. Экспериментальная проверка модели создания эффективных нейросетевых средств оценки точности параллельных вычислений экспертных данных в облачном сервисе на примере распознавания данных социологической статистики и оценки вероятности возникновения ошибок обучений.

Ключевые слова: нейросетевые модели, нейросеть, облачное хранилище, социологические данные, экспертная система, обучение нейронной сети.

Введение. В качестве отправного пункта обоснования алгоритма нейросетевого оценивания параметров параллельных вычислений экспертных данных в облачном сервисе использованы результаты [1; 2; 6; 9; 10], в которых показана возможность использования нейронной сети для аппроксимации с заданной точностью произвольной функций. Так, в [2] показано доказательство теоремы Хехт-Нильсена, в которой доказана принципиальная возможность представления непрерывной произвольной функции многих переменных с помощью нейронной сети с прямым распространением сигнала, когда сеть содержит как минимум один слой нейронов. Используемый тип нейросетевой модели с одним слоем скрытых нейронов получил название двухслойного персептрона, а с несколькими слоями скрытых нейронов - название многослойного персептрона [3]. Похожий результат, но уже для скрытой Марковской модели типа РБФ (радиальная базисная функция), получен в работах Д. Парка и И. Сандберга, приведенных в [5; 10]. Доказано, что при выполнении определенных структурных правил (достаточное количество скрытых нейронов), с помощью нейронной сети с радиальными базисными функциями, возможно аппроксимировать произвольную гладкую функцию. Можно отметить, что подобная модель выявления ошибок обработки экспертных данных для информационной системы использована в [8]. В итоге, применение к функционалу теоремы Хехт-Нильсена и результатов Д. Парка и И. Сандберга позволяет утверждать, что с помощью многослойного персептрона и нейронной сети с радиальными базисными функциями можно с заданной точностью обрабатывать большие социологические данные. Далее будет рассмотрено использование полученного результата на конкретном примере. Таким образом, **цель данной статьи** – является разработка и обоснование теоретических положений, лежащих в основе алгоритмов обучения нейронной сети для обработки больших социологических данных.

Материалы и методы.

За основу выбраны записи из базы данных облачного сервиса KDD-99, которая содержит примеры выборки информационной системы и сигнатуры параллельных вычислений экспертных данных. Требуется показать: гарантированность распознавания представленных параллельных вычислений экспертных данных с помощью нейросетевых моделей вида многослойного персептрона и нейронной сети с радиальными базисными функциями.

База данных облачного сервиса KDD-99 содержит около 5000000 записей – образов сетевых соединений данных SPSS, зарегистрированных через определенные промежутки времени [10]. Каждая запись состоит из 42 полей. В полях от 1 до 41 записаны такие параметры сетевого соединения как продолжительность, тип протокола, сетевой сервис, количество полученных байтов, количество переданных байтов, статус соединения и т.д. В 42 поле записана информация, характеризующая отсутствие погрешности вычислений (normal), или ее тип. В базе представлены 22 вида ошибки вычислений экспертных данных, которые разделяются на 4 основных класса – отказ в обслуживании (DoS), несанкционированное получение прав доступа незарегистрированным пользователем (R2L), несанкционированное повышение привилегий (U2R) и ошибки оценки экспертных данных (Probe) с учетом множества нормальных состояний на основе теоремы Хехт-Нильсена и результатов Д. Парка и И. Сандберга (1):

$$\begin{cases} U = F(p_1, p_2, \dots, p_{41}) \\ U \in (A_1, A_2, \dots, A_{22}, N_1) \end{cases} \quad (1)$$

где $p_1, p_2, \dots, p_{41}$ - параметры эффективности работы системы; $A_1, A_2, \dots, A_{22}$ - виды параллельных вычислений экспертных данных; N_1 - нормальное состояние ИС.

Для исследования свойств экспертной модели создания эффективных нейросетевых средств оценки при использовании параллельных вычислений в облачном сервисе разработан подход к определению оптимального вида нейросетевой модели и результаты исследования возможностей применения методов теории нейронной сети для оценки параметров обработки экспертных данных.

Таблица 1.

Величины оценки свойств модели параллельных вычислений экспертных данных в облачном сервисе с прямым распространением сигнала и адаптивных систем

№	Описание свойств	Вид нейронной сети				
		Многослойный персептрон	Сверточные нейронные сети	НС с радиальными базисными функциями	НС адаптивной резонансной теории	Вероятностные
$E_{1,1}$	Ограниченность количества входных параметров	-1	-1	-1	-1	-1

$E_{1,2}$	Ограниченность обучающей выборки	-1	-1	-1	0	-1
$E_{1,3}$	Допустимость шума	1	1	0	-1	0
$E_{1,4}$	Допустимость корреляции	1	1	1	1	1
$E_{1,5}$	Необходимость отражения всех аспектов процесса	-1	-1	1	-1	1
$E_{1,6}$	Необходимость пропорционального представления примеров	-1	1	-1	-1	-1
$E_{1,7}$	Возможность использования дискретных входных параметров	1	1	1	1	1
$E_{1,8}$	Возможность использования непрерывных входных параметров	1	1	1	1	1
$E_{1,9}$	Возможность использования обучающей выборки, объем которой меньше количества входных параметров	-1	-1	1	1	1
$E_{2,1}$	Короткий срок обучения	-1	-1	0	1	1
$E_{2,2}$	Необходимость представления в обучающих примерах ожидаемого выхода	1	1	1	-1	1
$E_{2,3}$	Автоматизация обучения	1	1	-1	1	1
$E_{2,4}$	Возможность обучению	0	0	1	1	1
$E_{2,5}$	Качество обучения	1	1	0	1	1
$E_{2,6}$	Возможность обучения на экспертных данных	-1	-1	-1	-1	1
$E_{2,7}$	Неизменность Результатов	1	1	1	1	1
$E_{3,1}$	Объем памяти	1	1	-1	-1	-1
$E_{3,2}$	Экстраполяции результатов обучения	1	0	-1	-1	-1
$E_{4,1}$	Интерпретируемость выхода в виде вероятности	0	-1	0	-1	1
$E_{4,2}$	Интерпретируемость выхода в графическом виде	-1	0	-1	-1	-1
$E_{4,3}$	Возможность вербализации	1	-1	0	-1	0
$E_{5,1}$	Скорость принятия решения	1	1	1	1	1
$E_{5,2}$	Объем программной реализации	-1	-1	1	0	-1
$E_{6,1}$	Распознавание образов	1	0	1	1	1
$E_{6,2}$	Анализ текста	-1	-1	-1	0	0
$E_{6,3}$	Управление параметрами защиты	-1	-1	-1	-1	-1
$E_{6,4}$	Приспособленность к автономному функционированию	0	-1	1	1	-1
$E_{6,5}$	Моделирование временных рядов	1	-1	0	0	0
$E_{6,6}$	Анализ изображений	1	1	-1	-1	-1
$E_{6,7}$	Анализ звука	1	0	-1	-1	-1
$E_{6,8}$	Разведывательный анализ данных	-1	-1	-1	-1	-1

С учетом трехбалльной числовой оценки, формула (1) модифицируется так:

$$E_{\Sigma} = \sum_{k=1}^K E_k(a_i) \rightarrow \max, a_i \in A, i = 1, 2, \dots, 7 \quad (2)$$

где E_{Σ} - интегральный критерий оптимизации вида нейронной модели; A - множество допустимых видов нейронной модели.

Согласно полученным результатам, компоненты A определяются так:

$$A = \{БСП, РБФ, PNN, ТК, АРТ, АНС, СНС\} \quad (3)$$

Для конкретной задачи оценки параметров ИС значимость критериев оптимизации, возможно учесть, введя в (1) соответствующие весовые коэффициенты:

$$E_{\Sigma} = \sum_{k=1}^K (r_k \times E_k(a_i) \rightarrow \max, a_i \in A, i = 1, 2, \dots, 7, \quad (4)$$

где r_k - весовой коэффициент k -го критерия оптимизации.

Для проверки модели создания эффективных нейросетевых средств оценки точности параллельных вычислений экспертных данных в облачном сервисе на примере распознавания данных социологической статистики, следует провести оценку вероятности возникновения ошибок обучений.

Возможной причиной относительной ошибки обучения в области минимальных значений выходных параметров экспериментальной модели может являться запись критерия оценки качества обучения в виде квадратичного функционала вида:

$$\varepsilon(W) \rightarrow \min, \varepsilon^2(W) = (y_1 - y_i^r)^2 \quad (5)$$

где y_1, y_i^r - ожидаемый и реальный выходной сигнал i -го нейрона модели; W - матрица весовых коэффициентов синаптических связей.

Возможным путем уменьшения относительной ошибки является использование функционала относительной квадратичной ошибки вида:

$$\bar{\varepsilon}_i^2(W) = (\varepsilon_i(W) / y_i)^2 = (y_i - y_i^r / y_i)^2, y_i \neq 0 \quad (6)$$

где $\bar{\varepsilon}_i$ - ошибка обучения i -го выходного нейрона; y_1 - ожидаемый сигнал i -го выходного нейрона; y_i^r - реальный сигнал i -го выходного нейрона.

С целью верификации полученных результатов проведены эксперименты, в которых минимальные и максимальные значения аргументов отличались между собой в 100 раз. Для использования предложенного проекта применительно к работе социологов необходимо использование двухъядерной системы обработки данных.




Рис. 1. Ядерный компонент системы.

Экспериментальная проверка модели создания эффективных нейросетевых средств оценки точности параллельных вычислений экспертных данных в облачном сервисе на примере отказа системы включала проверку величины абсолютной, относительной и ошибки экстраполяции по использованию математического аппарата обучения НС.

В качестве иллюстрации на рисунке 2 показаны графики абсолютной и относительной ошибок обучения и экстраполяции функции $y=x^3+x^2+x$, аппроксимированной экспериментальной модели (модель многослойного персептрона) с классическим и модифицированным алгоритмом обучения.




Рис. 2. Результаты оценки ошибок обучения НС.

Определено, что оптимальное количество скрытых нейронов в экспериментальной модели равен 12. На рисунке 2а, 2в, 2е ось ординат соответствует абсолютной ошибке обучение (Δ), а на графиках 2б, 2г, 2д - относительная ошибка обучения (δ). На всех графиках ось абсцисс соответствует значению подопытной функции (x).

Рассчитанные критерии эффективности известных нейросетевых методов и разработанного алгоритма приведены в таблице 4.1.

Таблица 2.

Оценка эффективности нейросетевых моделей и методов

№	Модель, метод	критерий					
		$d_{ткк}$	$d_{одв}$	$d_{анв}$	$d_{гуз}$	$d_{ооп}$	D^{Σ}

1	Метод определения фрагментов программного кода ОФПК	0,176777	0,5	1,414214	0,25	0,125	2,46599
2	Модель ТК (МТК)	0,088388	0,5	0,353553	0,353553	0,088388	1,383883
3	Нейросетевая искусственная система (НИС)	0,125	0,5	0,353553	0,353553	0,125	1,457107
4	Нейросетевой подход обработки SQL-данных (НПВИ)	0,176777	0,5	0,353553	0,353553	0,088388	1,472272
5	Метод построения совокупного классификатора трафика (ПСКТ)	0,088388	0,5	0,353553	0,25	0,088388	1,28033
6	Алгоритм оценки параметров параллельных вычислений (разработка автора)	2,828427	2	2,828427	5,656854	8	24,62742

Анализ данных таблицы 2 указывает на то, что использование предложенной алгоритм оценки параметров параллельных вычислений позволяет повысить генеральный показатель эффективности разработки в 3,85 раза по отношению к иным нейросетевым методам. Снижение параметров погрешности доказывает, что использование предложенной модификации алгоритма уменьшает относительную ошибку обучения в среднем в 2 раза. При этом в области небольших значений моделируемой функции относительная ошибка обучения уменьшилась примерно в 10 раз. Таким образом, результаты многочисленных экспериментов подтверждают целесообразность предложенной модификации алгоритма обучения модели создания эффективных нейросетевых средств оценки точности параллельных вычислений экспертных данных в облачном сервисе на примере распознавания кибератак и возможности применения методологии нейросетевого оценивания параметров безопасности информационных систем.

Выводы. В рамках данной статьи разработаны теоретические положения алгоритма построения нейросетевых средств оценивания параметров параллельных вычислений экспертных данных в облачном сервисе при решении класса задач - выявления сбоев и точности параллельных вычислений данных социологических опросов, а также обоснована методика контроля сбоев автоматизированных информационных систем на основе нейросетевых технологий, которая основана на:

- методике многослойного персептрона и нейронной сети с радиальными базисными функциями для выявления сбоев параллельных вычислений экспертных данных;

- формализации анализа устойчивости расчётных схем алгоритмов за счет оценки погрешности моделирования;

- математическом описании процессов детерминирования параметров статистически подобных сбоев параллельных вычислений экспертных данных, продукционных правил представления обучающих примеров и структуры и весовых коэффициентов синаптических связей нейросетевой модели типа MPNN, обеспечивается оперативность распознавания и расширение множества видов сбоев параллельных вычислений экспертных данных, характеристики которых не представлены в статистических данных.

Решения базируются на возможности моделирования параллельных вычислений экспертных данных непрерывной многопараметрической функцией и использовании теорем Колмогорова-Арнольда и Хехт-Нильсена, в которых доказана возможность применения нейронной сети с прямым распространением сигнала для представления произвольной непрерывной многомерной функции заданной точности. Экспериментальная проверка модели создания эффективных нейросетевых средств оценки точности параллельных вычислений экспертных данных в облачном сервисе может быть реализована на примере распознавания данных социологической статистики в облачном сервисе и оценки вероятности возникновения ошибок обучений.

Список литературы

1. Егоров Н. В., Карпов А. Г.. Диагностические информационно-экспертные системы - СПб.: Изд-во СПбГУ, 2002. - с.442-467.
2. Горбань А. Н. Нейронные сети на персональном компьютере / А. Н. Горбань, Д. А. Россиев. - Новосибирск: Наука, 1996. - 276 с.
3. Игнатов В. А. Элементы теории оптимального обслуживания технических изделий / В. А. Игнатов, Г. Г. Маньшин, В. В. Костановский. -Минск: Наука и техника, 1974. - 192 с.
4. Кендалл М. Многомерный статистический анализ и временные ряды / Кендалл М., Стюарт А.; пер. с англ. - М.: Наука, 1976. - 722 с.
5. Корченко А.А. Система выявления аномального состояния в компьютерных сетях / А.А. Корченко // Безопасность. - 2012. - № 2 (18). - С. 80-84.
6. Лебедев В.В. Алгоритмы ускорения сверточных нейронных сетей : автореферат дис. кандидата физико-математических наук : 05.13.01; [Место защиты: Моск. физ.-техн. ин-т (гос. ун-т)]. - Долгопрудный, 2018. - 24 с.
7. Орлов А. И. Высокие статистические технологии / А. И. Орлов // Заводская лаборатория. - 2003. - Т. 69, №11. - С. 55-60.
8. Орлов А. И. Прикладная статистика. - М.: КноРус, 2015.. - 656 с.
9. Петросян Л. А., Захаров В. В. Математические модели в экологии: научное издание - СПб. : Изд-во С.-Петербург. ун-та, 1997 - с. 202-223.
10. Хайкин С. Нейронные сети: полный курс: [перевод с английского]. - Изд. 2-е, испр. - Москва: Вильямс; Санкт-Петербург: Вильямс, 2018. - 1103 с
11. Шапоров С.Д. Математические методы прикладной статистики: учебное пособие; М-во образования и науки Российской Федерации, Федеральное гос. авт. образовательное учреждение высш. образования Санкт-Петербургский гос. ун-т аэрокосмического приборостроения. - Санкт-Петербург : ГУАП, 2016. - 407 с.

КЛАССИФИКАТОР ФУНКЦИОНАЛЬНОГО СОСТОЯНИЯ СИСТЕМЫ ДЫХАНИЯ НА ОСНОВЕ ДЕСКРИПТОРОВ, ПОЛУЧЕННЫХ ПО СПЕКТРУ ФУРЬЕ ВЕЙВЛЕТ-КОЭФФИЦИЕНТОВ ЭЛЕКТРОКАРДИОСИГНАЛА³

С.А. Филист¹, М.Б.Мяснянкин¹, Р.И. Сафронов², А.А. Кузьмин¹

¹Юго-Западный государственный университет,
каф. биомедицинской инженерии, *SFelist@gmail.com*

²Курская государственная сельскохозяйственная академия имени И.И. Иванова,
каф. электротехники и электроэнергетики, *russafronov@yandex.ru*

Кардиореспираторная система, состоящая из сердечно-сосудистой системы (ССС) и системы дыхания (СД), является наиболее чутким индикатором физиологического состояния организма, поэтому актуальным направлением исследования является разработка методов классификации функционального состояния (ФС) этой системы на основе дескрипторов, полученных в процессе анализа динамики взаимодействия ССС и СД на определенном промежутке времени [1, 2]. К важным диагностическим показателям функционального состояния кардиореспираторной системы относятся показатели синхронности сердечного, сосудистого и дыхательного ритмов, которые обеспечивают адекватный уровень адаптации организма при экзогенных воздействиях [3, 4, 5].

При построении дескрипторов для классификаторов ФС СД полагаем, что основная релевантная информация сосредоточена в медленных волнах [6]. Поэтому задача формирования признакового пространства сводится к выделению медленных волн в исследуемом сигнале и их адекватному описанию в сформированном пространстве информативных признаков.

Ритм дыхания (РД) можно наблюдать на спектральной характеристике электрокардиосигнала (ЭКС) в виде волнового цуга в области частот в диапазоне от 0,15 до 0,4 Гц [3]. На рис. 1 показан амплитудный спектр Фурье ЭКС, на котором выделены цуги системных ритмов, соответствующие частотным диапазонам в области медленных волн [1, 6].




Рис. 1. Амплитудный спектр Фурье электрокардиосигнала, записанного в течение трех минут с частотой дискретизации 200 Гц.

³ Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20-38-90058.

Acknowledgments: The reported study was funded by RFBR, project number 20-38-90058..

Электрофизиологические сигналы, используемые для выделения системных ритмов, не являются стационарными на наблюдаемых интервалах, поэтому Фурье-анализ не позволяет формировать дескрипторы для надежной классификации ФС СД. В этом случае целесообразно использовать частотно-временной анализ, в частности, вейвлет-анализ. Учитывая, что вейвлет – плоскость электрокардиосигнала отражает, как ритмы ССС, так и ритмы СД, для получения дескрипторов функционального состояния СД используем строки вейвлет-плоскости электрокардиосигнала, принадлежащих частотному диапазону ритма дыхания (РД) [6]. Показатели вариабельности этих строк по времени и по частоте используем в качестве дескрипторов для обучаемого классификатора функционального состояния СД, выполненного на многослойной нейронной сети прямого распространения [7, 8].

На рис.2 показано одно из сечений вейвлет-плоскости ЭКС по оси частот (на вейвлет-плоскости это вертикальная ось). Параметры вейвлет-преобразования подобраны таким образом, чтобы полный частотный диапазон включал частоты от 40 Гц до 0,08 Гц. Каждому системному ритму соответствует свой частотный диапазон, так же, как и на рис.1.




Рис.2. Эпюра одного столбика вейвлет-плоскости электрокардиосигнала.

В каждом частотном цуге на рис. 2 отражена вариация частоты в строке вейвлет-плоскости, к которой принадлежит данный цуг. Другими словами, в цуге представлена вариация частотных составляющих РД, которые представлены данной строкой вейвлет-плоскости. Анализ этих частотных составляющих показал, что цугам вейвлет-плоскости, строки которых лежат в области РД, соответствуют длины волн с периодами 20...30 секунд, что позволяет отнести их к диапазону VLF. Цуги, которые принадлежат строкам вейвлет-плоскости, частоты которых лежат в диапазоне между частотами кардиоритма и частотами ритма дыхания, несут медленные волны первого порядка, которым, как правило, соответствует системный ритм 0,1 Гц. Вопрос построения дескрипторов для «слабых» классификаторов по этим цугам сводится к определению спектра Фурье соответствующего цуга.

В классификаторе ФС СД используем иерархическую структуру нейронной сети, которая включает две автономных нейронных сети NET1 и NET2, каждая из которых имеет два выхода, показывающих вероятность нахождения СД в заданном ФС и

вероятность нахождения СД в индифферентном классе, и третью нейронную сеть NET, агрегирующую решения первых двух по обоим выходам. На рисунке 3 представлена структурная схема нейросетевого классификатора функционального состояния СД. В классификаторе в качестве дескрипторов нейронной сети NET1 используются показатели вариабельности выделенных строк вейвлет-плоскости по времени (по сдвигу), а в качестве дескрипторов нейронной сети NET2 используются показатели вариабельности выделенных строк вейвлет-плоскости по частоте (по масштабу).

Для вычисления дескрипторов нейронной сети NET1 формируем матрицу размером $L \times N$ из строк вейвлет-плоскости, лежащих в области частот РД. Здесь L -число строк вейвлет-плоскости ЭКС, лежащих в диапазоне РД, а N - число столбцов вейвлет плоскости, которое определяется числом отсчетов ЭКС. Определяем спектры Фурье $\{f_{\ell k}\}$, $\ell = \overline{1, L}$, $k = \overline{1, N}$ строк полученной матрицы, выделяем из N спектральных коэффициентов Фурье в каждой из L строк матрицы M коэффициентов $f_{\ell m}^*$, соответствующих диапазону VLF спектра ЭКС [4], определяем первые разности этих коэффициентов по строкам и вычисляем множество дескрипторов для NET1 $\{d1_j\}$, $j = \overline{1, M}$ как

$$d1_j = \sum_{\ell=2}^L |f_{\ell,j}^* - f_{\ell-1,j}^*|. \quad (1)$$




Рис.2. Структурная схема иерархического классификатора.

Для вычисления дескрипторов второй нейронной сети используем ту же матрицу вейлет-коэффициентов $\{w_{\ell n}\}$, $\ell = \overline{1, L}$, $n = \overline{1, N}$ размером $L \times N$, сформированную из строк

вейвлет-плоскости, лежащих в области частот РД. Транспонируем полученную матрицу вейвлет-коэффициентов в матрицу $N \times L$, в каждой из N строк транспонированной матрицы находим максимальный по абсолютной величине вейвлет-коэффициент, определяем номер строки транспонированной матрицы, которой принадлежит этот вейвлет-коэффициент, формируем вариационный ряд из N номеров строк транспонированной матрицы, элементы которого определяют как

$$d2_n = \arg \left(\max_{\ell \in \overline{1, L}} (|w_{n\ell}|) \right), \quad (2)$$

определяем спектр полученного вариационного ряда

$$fd2_k = \sum_{n=1}^N d2_n \cdot \exp(-2\pi kn / N), \quad (3)$$

выбираем из множества $\{fd2_k\}$, $k = \overline{1, N}$ множество спектральных коэффициентов $\{fd2_k^*\}$, $k = \overline{1, \Theta}$, лежащих в диапазоне VLF спектра ЭКС [4], и используют значения элементов этого множества в качестве дескрипторов нейронной сети NET2.

Функциональное состояние СД классифицируется следующим образом. К пациенту подключаются датчики пневмографа и электрокардиографа. Их сигналы оцифровываются и поступают в ЭВМ. После получения синхронной записи файлов с заданным числом отсчетов определяется спектральный диапазон пневмограммы [3]. Программный модуль «селектор частот» выделяет диапазон частот, в котором лежит основная энергия спектра пневмограммы и передает границы этого диапазона в модуль формирования дескрипторов. В модуле «вейвлет-анализ» определяется вейвлет-преобразование ЭКС.

Для определения показателей variability РД использовался сегмент вейвлет-плоскости ЭКС, строки которого принадлежали частотному диапазону, занимаемому РД. Так как частотный диапазон РД является уникальным для каждого индивидуума, то для его определения вычислялся спектр Фурье ЭКС, и анализировался спектральный состав его цуга, принадлежащего РД. По определенному частотному диапазону цуга вычислялись параметры для построения вейвлет-плоскости ЭКС.

Вычисления дескрипторов нейронной сети NET 1 осуществляют путем формируется матрица вейвлет-коэффициентов размером $L \times N$, находящихся в области РД, и определения спектров Фурье в строках этой матрицы. В результате множество вейвлет-коэффициентов $\{w_{\ell n}\}$, $\ell = \overline{1, L}$, $n = \overline{1, N}$ трансформируется в множество коэффициентов Фурье $\{f_{\ell k}\}$, $\ell = \overline{1, L}$, $k = \overline{1, N}$, где

$$f_{\ell k} = \sum_{n=1}^N w_{\ell n} \cdot \exp(-2\pi kn / N). \quad (4)$$

Далее осуществлялась селекция столбцов спектральных коэффициентов Фурье строк вейвлет-плоскости, в результате которой в каждой строке из N спектральных коэффициентов выбирают M спектральных коэффициентов Фурье, принадлежащих

диапазону VLF. Матрица спектральных коэффициентов преобразуется из $L \times N$ в $L \times M$ с элементами $\{f_{\ell m}^*\}, \ell = \overline{1, L}, m = \overline{1, M}$.

В итоге можем определить вариацию спектра Фурье по частоте в виде первых разностей элементов по строкам матрицы $L \times M$

$$\Delta_{\ell m} = f_{\ell, m}^* - f_{\ell, m-1}^*, \quad m = \overline{2, M}. \quad (5)$$

Вычисление дескрипторов для NET 1 осуществляем по формуле

$$d1_m = \sum_{\ell=2}^L |\Delta_{\ell m}|. \quad (6)$$

Вычисления дескрипторов нейронной сети NET2 осуществляется путем анализа строк вейвлет-плоскости, находящихся в области РД, то есть на основе анализа матрицы вейвлет-коэффициентов $\{w_{\ell n}\}, \ell = \overline{1, L}, n = \overline{1, N}$ размером $L \times N$. Эта матрица трансформируется, в результате чего получают матрицу вейвлет-коэффициентов $\{w_{n\ell}\}, n = \overline{1, N}; \ell = \overline{1, L}$ размером $N \times L$.

В каждой из N строк транспонированной матрицы находят максимальный по абсолютной величине вейвлет-коэффициент и определяют номер строки транспонированной матрицы, которой принадлежит этот вейвлет-коэффициент. В результате этой процедуры формируют вариационный ряд из N номеров столбцов транспонированной матрицы, элементы которого определяем согласно (2). Значение элемента вариационного ряда определяется по максимальному по абсолютной величине вейвлет-коэффициенту. Элементу вариационного ряда присваивается значение номера столбца трансформированной матрицы, в котором находится максимальный элемент.

Спектр $\{fd2_k\}, k = \overline{1, N}$ полученного вариационного ряда определяется согласно (3). Из множества $\{fd2_k\}, k = \overline{1, N}$ выбираю множество спектральных коэффициентов $\{fd2_k^*\}, k = \overline{1, \Theta}$, лежащих в диапазоне VLF, и используют значения элементов этого множества в качестве дескрипторов нейронной сети NET2.

Обучающие выборки формируются на основе клинических исследований S пациентов, СД которых находится в одном из двух классов ФС, одно из которых индифферентное. После обучения всех нейронных сетей первого иерархического уровня формируется таблица «объект – признак» для нейронной сети NET. Обучающая выборка для обучения нейронной сети NET формируется из выходов нейронных сетей NET1 и NET2 согласно таблице 1.

Таблица 1

Формат данных для таблицы «объект-признак» для обучения нейронной сети NET

NN образцов	Выход NET1		Выход NET2		Цель	
	$P1$	$\overline{P1}$	$P2$	$\overline{P2}$	P	$\overline{P}$

1	$NET1_1$	$\overline{NET1_1}$	$NET2_1$	$\overline{NET2_1}$	1	0
2	$NET1_2$	$\overline{NET1_2}$	$NET2_2$	$\overline{NET2_2}$	0	1
.	.	.	.	.	.	.
.	.	.	.	.	.	.
.	.	.	.	.	.	.
S	$NET1_s$	$\overline{NET1_s}$	$NET2_s$	$\overline{NET2_s}$	1	0

В качестве примера была взята группа пациентов, больных пневмонией с четко поставленным диагнозом (рентгенография, рентгеновская томография, данные лабораторного анализа) и группа волонтеров без легочных патологий. Диагнозы кодируются символами "0" и "1". Из полученной обучающей выборки методом скользящего экзамена формируются контрольные выборки. Пространство информативных признаков определяется для каждой нейронной сети группы NET1 и NET2 посредством определения (6) и (3).

Показатели качества диагностики предлагаемого классификатора - диагностическая чувствительность (ДЧ), диагностическая специфичность (ДС) и диагностическая эффективность (ДЭ) сравнивались, как с прототипом, с показателями качества рентгеновских исследований на той же контрольной выборке. Показатели качества диагностики по классам «пневмония - нет пневмонии» для одной из контрольных выборок представлены в таблице 2.

Анализируя таблицу 2, приходим к выводу, что на данной контрольной выборке оба способа классификации ФС СД имеют практически одинаковые диагностические эффективности.

Таблица 2

Показатели качества прогнозирования функционального состояния системы дыхания на контрольной выборке

Обследуемые	Классификатор					
	На основе анализа вариабельности медленных волн VLF диапазона			Рентгенологические исследования		
	ДЧ	ДС	ДЭ	ДЧ	ДС	ДЭ
$n_{\omega_1}^1 = 60$	76%	82%	79%	87%	68%	79%
$n_{\omega_1}^2 = 60$	82%	76%		68%	87%	

Иерархическая модель нейросетевого классификатора ФС СД, основанная на дескрипторах, полученных по результатам анализа спектра Фурье вейвлет-коэффициентов ЭКС превосходит рентгенологическое исследование по специфичности и несколько уступают по чувствительности, что позволяет рекомендовать полученный классификатор ФС СД в клиническую практику.

Список литературы

1. Петрова, Т.В. Предикторы синхронности системных ритмов живых систем для классификаторов их функциональных состояний / Т.В. Петрова, С.А. Филист, С.В. Дегтярев, А.В. Киселев, О.В. Шаталова // Системный анализ и управление в биомедицинских системах. 2018. Т. 17. № 3. - С. 693-700.
2. Модели латентных предикторов в интеллектуальных системах прогнозирования состояния живых систем/ А.В. Киселев, О.В. Шаталова, З.У. Протасова, С.А. Филист, Н.С. Стадниченко //Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10. № 1. - С. 114-133.
3. Гришин, О.В. Вариабельность легочного газообмена и дыхательного ритма / О.В. Гришин, В.Г. Гришин, Ю.В. Коваленко// Физиология человека, 2012, том 38, № 2. - С. 87–93.
4. Мяснянкин, М.Б. Формирование дескрипторов для классификаторов функционального состояния системы дыхания на основе спектрального анализа электрокардиосигнала/Мяснянкин М.Б., Филист С.А., Киселев А.В., Кузьмин А.А.//Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10. № 3/4. - С. 8-28.
5. Изучение сердечно-сосудистого и дыхательного синхронизма при различных режимах дыхания/ Л.А. Носкин, А.В. Рубинский, А.П. Романчук, В.Н. Марченко, В.В. Пивоваров, А.Б. Черепов, Л.А. Заровкина //Патогенез. – 2018. – Т. 16, №4 – С.90–96.
6. Myasnyankin, M.B. Neural network classifiers with descriptors obtained on the basis of analysis of the system rhythms in intellectual prediction systems for non-hospital pneumonia/ M.B. Myasnyankin, A.A. Kuzmin and S A Filist// Journal of Physics: Conference Series 1801 (2021) 012046, doi:10.1088/1742-6596/1801/1/012046.
7. Филист, С.А. Гибридная нейронная сеть с макрослоями для медицинских приложений / С.А. Филист, О.В. Шаталова, М.А. Ефремов // Нейрокомпьютеры. Разработка и применение. - 2014. - №6. - С. 35-39.
8. Филист, С.А. Универсальные сетевые модели для задач классификации биомедицинских данных / С.А. Филист, Р.А. Томакова, З.Д. Яа // Известия Юго-Западного государственного университета. - Курск: Изд-во ЮЗГУ, 2012. – №4(43). – Ч. 2. – С. 44-50.

СПИСОК ДОКЛАДОВ

Алехина А.Е., Доррер М.Г., Садовский М.Г., Феллер А.А. ПРИМЕНЕНИЕ МОДЕЛЕЙ YOLOV4 В ЗАДАЧАХ КИНЕМАТИКИ ЧЕЛОВЕКА В ОБЛАСТИ СПОРТИВНОЙ МЕДИЦИНЫ	3
А.Г. Арутюнян, К.О. Туценко, А.А. Хорошавина, Д.В. Похабов, В.Г. Абрамов, М.Е. Туник, М.Г. Садовский О РОБАСТНОСТИ ДАННЫХ БОТУЛИНОТЕРАПИИ СПАСТИКИ У БОЛЬНЫХ С ПОСЛЕДСТВИЯМИ ОСТРОГО ОЧАГОВОГО ПОРАЖЕНИЯ ГОЛОВНОГО МОЗГА	15
Л.А.Астапова, А.М.Корсаков, А.В.Бахшиев, Е.А.Ерёменко, Е.Ю.Смирнова СЕГМЕНТНАЯ СПАЙКОВАЯ МОДЕЛЬ НЕЙРОНА В ЗАДАЧЕ КЛАССИФИКАЦИИ ПАТТЕРНОВ ИМПУЛЬСОВ	19
С.И.Барцев, Г.М.Маркова СОПОСТАВЛЕНИЕ МЕТОДОВ ИДЕНТИФИКАЦИИ СТИМУЛА, ПОЛУЧЕННОГО ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТЬЮ, ПО НЕЙРОННОЙ АКТИВНОСТИ	26
Р.В. Бикмурзин, Д.П. Федченко КЛАССИФИКАЦИЯ ЗВЕЗД ПО НАЛИЧИЮ ЭКЗОПЛАНЕТ ИЗ КАТАЛОГА GAIA DR2	31
Н.М. Богатов, А.Н. Богатова, С.А. Сухих, Л.Р. Григорьян, М.С. Коваленко, А.А. Носаль, Д.А. Щетинин ВЛИЯНИЕ ПСИХОТЕХНИК НА ИЗМЕНЕНИЕ РИТМОВ МОЗГА И ТЕМПЕРАТУРЫ ЛИЦА	36
М.А. Габова МОДЕЛИРОВАНИЕ РАСЧЕТА ПОЖАРНЫХ РИСКОВ ЭЛЕКТРОУСТАНОВОК АГРАРНО-ПРОМЫШЛЕННОГО КОМПЛЕКСА	42
С.Е. Головенкин, С.Ю. Никулина, Ю.В. Орлова, Е.Ю. Пелипецкая, Т.Д. Верещагина, М. Г. Доррер ОСЛОЖНЕНИЯ ИНФАРКТА МИОКАРДА: ОЦЕНКА ЗНАЧИМОСТИ ВХОДНЫХ ПАРАМЕТРОВ ПРИ ПРОГНОЗИРОВАНИИ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ	47
М. Г. Доррер, С.Е. Головенкин, С.Ю. Никулина, Ю.В. Орлова, Е.Ю. Пелипецкая	

ПОДБОР ПРОЦЕДУР ДОПОЛНЕНИЯ ДАННЫХ, АРХИТЕКТУРЫ И АЛГОРИТМА ОБУЧЕНИЯ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ ТЕЧЕНИЯ ИНФАРКТА МИОКАРДА	54
Н.Н. Журухин, В.А. Углев РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТА ПО ВЫЯВЛЕНИЮ АНОМАЛИЙ В АМПЛИТУДНЫХ СПЕКТРАХ ВИБРАЦИИ С ПОМОЩЬЮ СВЁРТОЧНОЙ НЕЙРОННОЙ СЕТИ	65
И.А.Кириков, С.В.Листопад, А.С.Лучко СОГЛАСОВАНИЕ ОНТОЛОГИЙ АГЕНТОВ СПЛОЧЕННЫХ ГИБРИДНЫХ ИНТЕЛЛЕКТУАЛЬНЫХ МНОГОАГЕНТНЫХ СИСТЕМ	73
Н.П.Кузенков, В.М.Логинов ОБНАРУЖЕНИЕ РЕЧЕВОЙ АКТИВНОСТИ С ИСПОЛЬЗОВАНИЕМ МЕТОДА ЭНТРОПИИ ЗАПОЛНЕНИЯ ФАЗОВОГО ПРОСТРАНСТВА	80
А.В.Медиевский, А.Г.Зотин, К.В.Симонов, А.С. Кругляков ОБРАБОТКА И АНАЛИЗ СНИМКОВ ДЛЯ ВЫЯСНЕНИЯ БИОЛОГИЧЕСКОЙ СТРУКТУРЫ МОЗГА С ПОЗИЦИИ ФОРМИРОВАНИЯ МОДЕЛИ НС	86
Я.В. Недорез, М.Г. Садовский ВНУТРЕННЯЯ СТРУКТУРИРОВАННОСТЬ АНСАМБЛЯ ГЕНОВ тРНК ЧЕЛОВЕКА ПО ЧАСТОТАМ ТРИПЛЕТОВ	93
Д.А. Проценко ВЫЯВЛЕНИЕ НЕКОТОРЫХ ТЕНДЕНЦИЙ ИЗМЕНЕНИЯ СОДЕРЖАНИЯ УЧЕБНЫХ ПЛАНОВ МАГИСТРАТУРЫ НАПРАВЛЕНИЯ «СИСТЕМНЫЙ АНАЛИЗ И УПРАВЛЕНИЕ» С ПОМОЩЬЮ МЕТОДА UGVA В УСЛОВИЯХ РЕАЛИЗАЦИИ ФГОС ВО 3++	98
О.И. Пятковский ТЕХНОЛОГИЯ СОЗДАНИЯ ГИБРИДНЫХ ЭКСПЕРТНЫХ СИСТЕМ С НЕЙРОСЕТЕВЫМИ КОМПОНЕНТАМИ В АНАЛИТИЧЕСКИХ ИНФОРМАЦИОННЫХ СИСТЕМАХ ОРГАНИЗАЦИЙ.	105
Тимофеев М.Н., Ковалева О.А. ОБОСНОВАНИЕ ПРОЦЕССА ОБУЧЕНИЯ ЭКСПЕРТНОЙ НЕЙРОННОЙ СЕТИ ПРИ ИСПОЛЬЗОВАНИИ ПАРАЛЛЕЛЬНЫХ ВЫЧИСЛЕНИЙ В ОБЛАЧНОМ СЕРВИСЕ	110
С.А. Филист, М.Б.Мяснянкин, Р.И. Сафронов, А.А. Кузьмин	

КЛАССИФИКАТОР ФУНКЦИОНАЛЬНОГО СОСТОЯНИЯ
СИСТЕМЫ ДЫХАНИЯ НА ОСНОВЕ ДЕСКРИПТОРОВ,
ПОЛУЧЕННЫХ ПО СПЕКТРУ ФУРЬЕ ВЕЙВЛЕТ-КОЭФФИЦИЕНТОВ
ЭЛЕКТРОКАРДИОСИГНАЛА

117

СПИСОК АВТОРОВ

Ф.И.О.	Место работы	Стр.
Абрамов Владислав Геннадьевич	660037, Красноярск, Коломенская ул., 26 к.2, ФГБУ «Федеральный Сибирский научно-клинический центр Федерального медико-биологического агентства Рос- сии» E-mail: excalibr@mail.ru	15
Алехина Анна Ев- геньевна	660000, Красноярск, просп. имени газеты Краснояр- ский Рабочий, 31, Сибирский государственный уни- верситет науки и технологий им. М.Ф. Решетнева E-mail: a.tolmacheva@solutionfactory.ru	3
Арутюнян Артём Гагикович	660062, Красноярск, ул. Курчатова, 17, Красноярская межрайонная клиническая больница скорой меди- цинской помощи имени Н.С. Карповича E-mail: artem.a.arm@mail.ru	15
Астапова Любовь Алексеевна	194064, Санкт-Петербург, Тихорецкий пр., д. 21, Цен- тральный научно-исследовательский и опытно- конструкторский институт робототехники и техниче- ской кибернетики (ЦНИИ РТК) E-mail: l.astapova@rtc.ru	19
Барцев Сергей Игоревич	660036, Красноярск, ул. Академгородок, строение 50, Институт биофизики СО РАН E-mail: bartsev@yandex.ru	26
Бахшиев Алек- сандр Валерьевич	195251, Санкт-Петербург, Политехническая ул., 29, Санкт-Петербургский политехнический университет Петра Великого E-mail: alexab@rtc.ru	19
Бикмурзин Рустам Василович	660074, Красноярск, ул. Киренского, 28, корпус № 12 (Б), Сибирский федеральный университет E-mail: Bikmurzin.sfe@gmail.com	31
Богатов Николай Маркович	350040, г. Краснодар, ул. Ставропольская, 149, ФГБОУ ВПО «Кубанский государственный универ- ситет», E-mail: bogatov@phys.kubsu.ru	36
Богатова Анна Ни- колаевна	350040, г. Краснодар, ул. Ставропольская, 149, ФГБОУ ВПО «Кубанский государственный универ- ситет», E-mail: anna_bogatova@mail.ru	36
Верещагина Тать- яна Дмитриевна	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский уни- верситет. имени профессора В.Ф.Войно-Ясенецкого E-mail: tdv2110@yandex.ru	47

Габова Мария Андреевна	656038, г. Барнаул, пр. Ленина, 46, Алтайский государственный технический университет им. И.И. Ползунова E-mail: Gabova_ma@mail.ru	42
Головенкин Сергей Евгеньевич	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский университет. имени профессора В.Ф.Войно-Ясенецкого E-mail: gse2008@mail.ru	47, 54
Григорьян Леонтий Рустемович	350040, Краснодар, ул. Ставропольская 149, Кубанский государственный университет E-mail: leonmezon@mail.ru	36
Доррер Михаил Георгиевич	660000, Красноярск, просп. имени газеты Красноярский Рабочий, 31, Сибирский государственный университет науки и технологий им. М.Ф. Решетнева E-mail: dorrer_mg@sibsau.ru	3, 47, 54
Ерёменко Е.А.	195251, Санкт-Петербург, Политехническая ул., 29, Санкт-Петербургский политехнический университет Петра Великого E-mail: elizaveta.yeremenko@gmail.com	19
Журухин Николай Николаевич	662972, Железногорск, ул. Ленина, 52, АО «Информационные спутниковые системы» E-mail: siriusov1990@yandex.ru	65
Зотин Александр Геннадьевич	660000, Красноярск, просп. имени газеты Красноярский Рабочий, 31, Сибирский государственный университет науки и технологий им. М.Ф. Решетнева E-mail: zotinkrs@gmail.com	86
Кириков Игорь Александрович	236022, Калининград, ул. Гостиная, 5, Калининградский филиал ФИЦ «Информатика и управление» РАН E-mail: baltbipiran@mail.ru	73
Ковалева Ольга Александровна	392000, г. Тамбов, ул. Интернациональная, 33, ФГБОУ ВО «Тамбовский государственный университет имени Г.Р.Державина» E-mail: solomina-oa@yandex.ru	110
Коваленко Максим Сергеевич	350040, г. Краснодар, ул. Ставропольская, 149, ФГБОУ ВПО «Кубанский государственный университет», E-mail: m.s.kovalenko@ya.ru	36
Корсаков Антон Михайлович	194064, Санкт-Петербург, Тихорецкий пр., д. 21, Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК) E-mail: alexab@rtc.ru	19
Кругляков Алексей Сергеевич	660036, г. Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: piggsyy@gmail.com	86

Кузенков Николай Петрович	660074, Красноярск, ул. Киренского, 26Б, Сибирский федеральный университет E-mail: knp@vivaldi.net	80
Кузьмин Александр Алексеевич	305040, г. Курск, ул. 50 лет Октября, 94, Юго-Западный государственный университет E-mail: Sfilist@gmail.com	117
Листопад Сергей Викторович	Калининград, ул. Гостиная, д.5, Калининградский филиал ФИЦ "Информатика и управление" РАН E-mail: ser-list-post@yandex.ru	73
Логинов Валерий Михайлович	660074, Красноярск, ул. Киренского, 26Б, Сибирский федеральный университет E-mail: valog_1949@mail	80
Лучко Александр Сергеевич	236013, Калининград, ул. Магнитогорская, дом 4, ООО "АВТОТОР Холдинг Менеджмент" E-mail: luchko@inbox.ru	73
Маркова Галия Муратовна	660041, Красноярск, Свободный пр., 82А, Сибирский федеральный университет E-mail: irvingstone@bk.ru	26
Медиевский Алексей Владимирович	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский университет. Имени профессора В.Ф.Войно-Ясенецкого E-mail: amedievsky@yandex.ru	86
Мяснянкин Максим Борисович	305040, г. Курск, ул. 50 лет Октября, 94, Юго-Западный государственный университет E-mail: 79606039503@mail.ru	117
Недорез Яна Владимировна	660041, Красноярск, Свободный пр., 82А, Сибирский федеральный университет, ИФБиБТ E-mail: oleynik48@mail.ru	93
Никулина Светлана Юрьевна	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский университет. Имени профессора В.Ф.Войно-Ясенецкого E-mail: gse2008@mail.ru	47, 54
Носаль Анастасия Анатольевна	350040, г. Краснодар, ул. Ставропольская, 149, ФГБОУ ВПО «Кубанский государственный университет», E-mail: nosal.nastya@mail.ru	36
Орлова Юлия Викторовна	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский университет. Имени профессора В.Ф.Войно-Ясенецкого E-mail: gse2008@mail.ru	47, 54
Пелипецкая Елена Юрьевна	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский университет. Имени профессора В.Ф.Войно-Ясенецкого E-mail: gse2008@mail.ru	47, 54
Похабов Дмитрий	660022, Красноярск, ул. Партизана Железняка, 1,	15

Владимирович	Красноярский государственный медицинский университет им. Проф. В.Ф. Войно-Ясенецкого Минздрава России, Федеральное государственное бюджетное учреждение «Федеральный Сибирский научно-клинический центр Федерального медико-биологического агентства» E-mail: neurodmit@mail.ru	
Проценко Дарья Алексеевна	662971, Железногорск, ул. Кирова, 12-а, Сибирский федеральный университет, филиал г. Железногорска E-mail: daryapro@mail.ru	98
Пятковский Олег Иванович	656038, г. Барнаул, пр. Ленина 46, Алтайский государственный технический университет им. И.И. Ползунова E-mail: poi1952@mail.ru	105
Садовский Михаил Георгиевич	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: msad@icm.krasn.ru	3, 15, 93
Сафронов Руслан Игоревич	305040, г. Курск, ул. 50 лет Октября, 94, Юго-Западный государственный университет E-mail: Sfilist@gmail.com	117
Симонов Констан- тин Васильевич	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: <u>siminovkv50@icm.krasn.ru</u>	86
Смирнова Екате- рина Юрьевна	194064, Санкт-Петербург, Тихорецкий пр., д. 21, Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК) E-mail: eus@rtc.ru	19
Сухих Станислав Алексеевич	350040, г. Краснодар, ул. Ставропольская, 149, ФГБОУ ВПО «Кубанский государственный университет», E-mail: suhih_52@mail.ru	36
Тимофеев Михаил Николаевич	392000, г. Тамбов, ул. Интернациональная, 33, ФГБОУ ВО «Тамбовский государственный универси- тет имени Г.Р.Державина» E-mail: timmn@mail.ru	110
Туник Мария Ев- геньевна	Красноярский государственный медицинский уни- верситет им. проф. В.Ф. Войно-Ясенецкого Минздра- ва России E-mail: tsuprikova.mary.maria@yandex.ru	15
Туценко Ксения Олеговна	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский уни- верситет им. проф. В.Ф. Войно-Ясенецкого Минздра- ва России E-mail: kseniamkib@gmail.com	15

Углев Виктор Александрович	662971, Железногорск, ул. Кирова, 12-а, Сибирский федеральный университет, филиал г. Железногорска E-mail: uglev-v@yandex.ru	65
Федченко Дмитрий Петрович	660041, Красноярск, Свободный пр., 82А, Сибирский федеральный университет E-mail: fdp@bk.ru	31
Феллер Алёна Александровна	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский уни- верситет им. В.Ф.Войно-Ясенецкого Минздрава РФ E-mail: felleraa96@mail.ru	3
Филист Сергей Алексеевич	305040, г. Курск, ул. 50 лет Октября, 94, Юго- Западный государственный университет E-mail: Sfilist@gmail.com	117
Хорошавина Алина Алексеевна	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский уни- верситет им. проф. В.Ф. Войно-Ясенецкого Минзdra- ва России E-mail: horoshavina-lina-yan@ya.ru	15
Щетинин Дмитрий Александрович	350040, г. Краснодар, ул. Ставропольская, 149, ФГБОУ ВПО «Кубанский государственный универ- ситет», E-mail: d_shhetinin@mail.ru	36

Научное издание

Нейроинформатика, её приложения и анализ данных

Материалы XXIX Всероссийского семинара 24 сентября – 26 сентября 2021 года

Редактор М.Ю. Сенашова
Компьютерная верстка: М.Ю. Сенашова

Подписано в печать «15» августа 2021 г. Формат 60 × 90/8. (А4)
Бумага офсетная. Печать плоская.
Усл. печ. л. 11,0. Уч.-изд. л. 11,3.
Тираж 500 экз. Заказ 12

Отпечатано в типографии ИВМ СО РАН
660036, Красноярск, Академгородок