



Научная статья

DOI: 10.15593/RZhBiomeh/2023.1.09

УДК 531/534: [57+61]

ВЫЯВЛЕНИЕ ПАТОБИОМЕХАНИЧЕСКИХ МАРКЕРОВ СТАТОКИНЕЗИОГРАММ НА ПРИМЕРЕ НЕЙРОСЕТЕВОЙ ИДЕНТИФИКАЦИИ ПОСТИНСУЛЬТНОГО СОСТОЯНИЯ

И.В. Степанян¹, С.С. Гроховский², М.А. Савкин³

¹ Институт машиноведения имени А.А. Благонравова Российской академии наук (ИМАШ РАН), Москва, Россия

² Исследовательский центр «МЕРА», Москва, Россия

³ Российский университет дружбы народов (РУДН), Москва, Россия

О СТАТЬЕ

Получена: 29 июня 2022

Одобрена: 09 марта 2023

Принята к публикации: 27 марта 2023

Ключевые слова:

опорная реакция, силовая платформа, постурография, стабилметрия, кластерный анализ, спектральные характеристики, визуализация.

АННОТАЦИЯ

Цель настоящего исследования – нейросетевое моделирование и определение параметров статокинезиограмм, которые являются носителями полезной информации об особенностях пострального регулирования, обусловившего полученную траекторию движений центра масс человека. Разработана методика получения информативных маркеров путём выявления центроидов кластеризации на основе самоорганизующихся нейронных сетей Кохонена с Евклидовой метрикой. Сети Кохонена, обучаемые без учителя (то есть без применения априорной диагностической информации о состоянии испытуемых), являются мощным и информативным методом, который позволяет получить не только графические, но и математические маркеры нарушений здоровья у испытуемых, исследовать биомеханику микродвижений центра давления на основе гибкого математического аппарата — нейросетевого кластерного анализа. На примере идентификации постинсультного состояния, проведён нейросетевой анализ стабилметрических данных и показан метод выявления патобиомеханических маркеров статокинезиограмм, который позволил стандартизировать типовую принадлежность групп испытуемых. С помощью нейронных сетей удалось выявить кластеры, которые поддаются медико-биологической интерпретации с достоверностью до 95,9 %, что обуславливает теоретическую значимость полученных результатов. Также были рассмотрены деревья решений и многослойная нейронная сеть, обучаемая с учителем. Многослойная нейронная сеть позволила выявлять маркеры нарушений здоровья с вероятностью 71,9 %.

© ПНИПУ

Введение

Постурология (лат. *postura* – поза) изучает механизмы удержания равновесия человеческого тела в пространстве. Эффективность пострального регулирования является важным интегральным показателем

функционального состояния человека и его здоровья. Для исследования пострального регулирования применяются биомеханические измерительные системы: методики захвата координат датчиков, которые крепятся к суставам пациента, оптические сенсоры для построения объемной модели осанки и другие методы.

© Степанян Иван Викторович – д.б.н, к.т.н, e-mail: neurocomp.pro@gmail.com ID: 0000-0003-3176-5279

© Гроховский Сергей Семенович – e-mail: director@mera-device.ru ID: 0000-0003-2314-4157

© Савкин Михаил Олегович – e-mail: zonerorqb@gmail.com ID: 0000-0003-2430-1118



Эта статья доступна в соответствии с условиями лицензии Creative Commons Attribution-NonCommercial License (CC BY-NC 4.0)

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

Одним из эффективных и наиболее распространенным приборным способом диагностики двигательных нарушений является стабилметрия (стабилография, постурография) [3], эффективность применения которой может быть существенно повышена путём внедрения нейросетевых технологий для анализа данных от стабилметрической платформы, получаемых в практической медицине в ходе проведения простых двигательных тестов.

Следует отметить, что стабилметрические системы — это относительно новый вид медицинской диагностико-реабилитационной аппаратуры, предназначенной для анализа функции равновесия тела человека. Технически реализация метода стабилметрии заключается в измерении с помощью специализированных устройств значений, составляющих реакции опоры с последующим определением по данным этих измерений мгновенных значений координат центра давления тела на опору. Стабилметрию не следует путать с другими методами применения силовых платформ, например, в оценке функции верхних конечностей [1]. Анализ траектории движения центра давления (ЦД) исследуемого тела на опору представляет ценность для решения практических задач, требующих оценки особенностей процессов, обусловивших полученную траекторию.

Научная проблема, рассматриваемая в данной работе, касается математического анализа двигательных нарушений, прежде всего контроля вертикальной позы и баланса тела у пациентов в постинсультный период. Статья является постановочной и носит методологический характер.

Инсульт, по-прежнему занимающий второе место в структуре заболеваемости и первое – в структуре инвалидности среди болезней системы кровообращения (по данным НАБИ), проявляется разнообразными двигательными нарушениями. Нарушение функции равновесия – одна из наиболее значимых проблем, возникающих у пациентов с церебральным инсультом. Это существенно ограничивает возможности к самообслуживанию и социализации, снижает качество жизни этих больных. У каждого пятого больного после инсульта выявляются падения, существенно ограничивающие возможности к самообслуживанию и социализации, приводящие к инвалидизации и снижающие качество жизни этих больных.

Современное состояние исследований

Современные исследования в области стабилметрии характеризуются широким разнообразием подходов и методов оценки функционального состояния человека. В [17] по данным серии стабилметрических тестов было установлено, что снижение устойчивости позы приводит к увеличению частоты и амплитуды колебаний ЦД. В [13] было проанализировано влияние здоровья и возраста на стабильность позы человека, на

основе стабилограмм была вычислена энтропия. Публикация [24] описывает применение метода стабилметрии для раскрытия принципов адаптации тела к условиям скользкой поверхности.

При рассмотрении детальных вейвлет-коэффициентов стабилограмм в работе [18] были идентифицированы параметры области сосредоточения отметок о положениях ЦД, накопленных за время исследования. В [10] представлен подход к описанию стабилограмм одномерной функцией углового сегмента, что использовалось в целях уменьшения размерности данных. В [19] предлагают контроль позы в качестве поведенческой характеристики для биометрии с применением различных статистических методов, включающих кластеризацию и методы машинного обучения. Определенный интерес представляет исследование [23], в котором было показано влияние традиционной китайской гимнастики на замедление эффектов сенсомоторного старения. Результаты публикации [22], основанные на динамических показателях контроля позы, подтверждают теорию о том, что улучшение стабильности позы в условиях когнитивных задач связано с автоматизмом у молодых и пожилых людей.

В то же время интенсивно развиваются методы машинного обучения. Применению нейронных сетей в стабилметрии посвящено множество работ, в том числе статьи [9; 12; 21; 11; 26; 27]. В то же время современные исследования по применению нейронных сетей Кохонена для анализа данных стабилметрии, согласно доступным источникам, сегодня носят ограниченный характер. Так, в [7] показана возможность применения нейронных сетей Кохонена для анализа допустимой области миграций ОЦД в зоне устойчивого равновесия по данным стабилметрии для старших возрастных групп пациентов. Таким образом, применению самоорганизующихся сетей Кохонена в стабилметрии посвящено сравнительно мало работ.

Описание методов исследования и исходных данных

В данном исследовании изучались спектральные характеристики стабилограмм с использованием нейронных сетей и методологии нейрокластеризации. Спектральные характеристики были получены путем быстрого преобразования Фурье стабилограмм. Реализация расчетов производилась на языке программирования Python 3.7.3 с применением пакетов *Rumvra*, *Minisom*, *Pandas*, *CatBoost*. Стабилограммы, отражающие индивидуальные паттерны постурального регулирования, могут содержать в себе маркеры отклонений от нормы. Предполагается, что данные маркеры присутствуют и в стабилограммах испытуемых, которые были обследованы в постинсультный период.

Для эксперимента были обработаны стабилметрические данные двух групп людей – перенесших инсульт и условно здоровых. Исследование проводилось в режиме тридцатисекундной пробы на платформе ST-

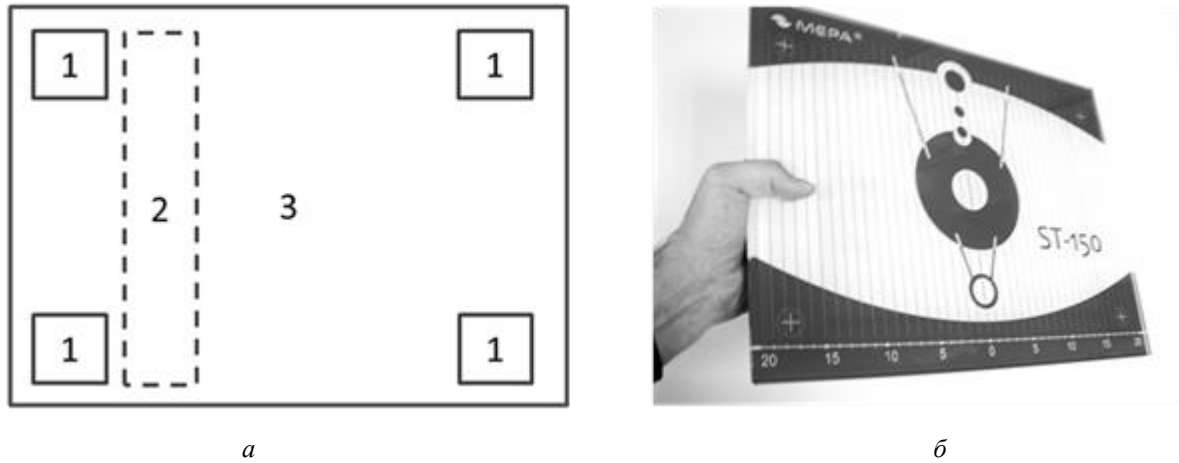


Рис. 1. Стабилоплатформа ST-150: *а* – компоновка: 1 — датчики силы; 2 — электронный преобразователь сигнала; 3 — опорная поверхность; *б* – общий вид прибора.




Рис. 2. Пример стахокинезиграммы. По осям *X* и *Y* отложены координаты ЦД относительно центра стабилоплатформы во фронтальной и сагиттальной проекциях соответственно, мм

150 с открытыми глазами в спокойной вертикальной позе. В исследовании анализировались полученные ранее с соблюдением современных этических норм записи стабилметрических тестов при неоднократном тестировании 65 пациентов (средний возраст 58 ± 10 лет) с нарушением равновесия в восстановительном периоде ишемического инсульта головного мозга, а также 65 условно здоровых добровольцев (25 мужчин и 40 женщин, средний возраст 47 ± 10 лет). Анализировался спектральный состав 628 массивов данных стабилметрии условно здоровых добровольцев и 628 массивов данных пациентов, восстанавливающихся после перенесенного инсульта. Эти массивы данных были сформированы в результате многократных стабилметрических тестов всех испытуемых. Равное

число результатов исследований здоровых испытуемых и испытуемых с нарушением состояния здоровья было выбрано в целях объективизации нейросетевой оценки.

Для стабилметрии применялась силовая платформа модельного ряда ST-150 Россия (рис. 1); регистрационный номер медицинского изделия ФСР 2010/07900; свидетельство об утверждении типа средств измерений RU.C.39.004.A N 41201. Стандартная частота опроса платформы при проведении измерений (частота дискретизации) не менее 250 Гц. На рис. 2 показан пример реальной стахограммы.

Из анализа литературы следует, что для исследования характерных для определенных состояний человека особенностей миграций ЦД тела на опору эффек-

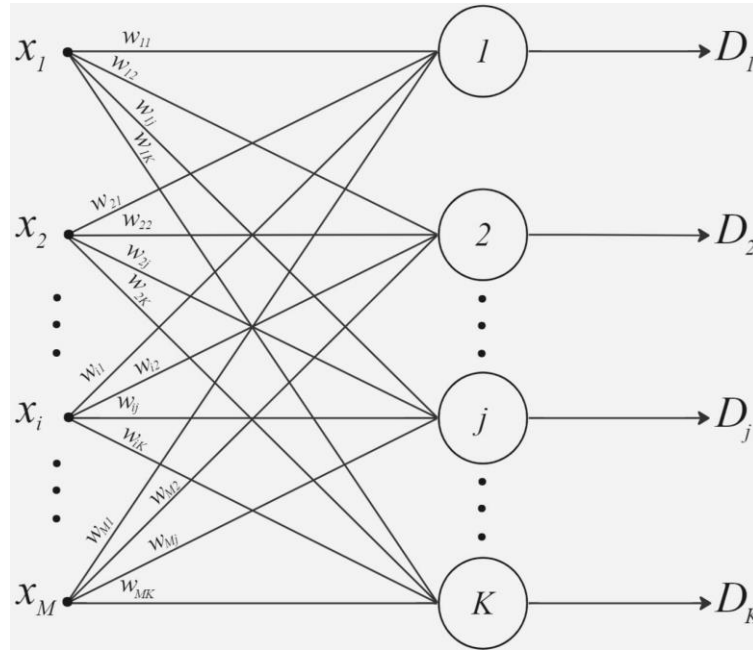


Рис. 3. Обобщённая структура сети Кохонена с выходным одномерным слоем. Сеть состоит из M входных и K выходных нейронов, каждый нейрон характеризуется весовыми коэффициентами w_{ij}

тивным инструментом являются искусственные нейронные карты Кохонена с самоорганизацией, поскольку они способны проецировать многомерные данные в пространство произвольной размерности [16].

Структура сети Кохонена состоит из двух полносвязных нейронных слоев – входной (рецепторный) слой признаков, принимающий входные данные, и выходной слой, состоящий из нейронов, каждый из которых формирует кластер, «притягивая» к себе за счет нейроподобных механизмов тот или иной входной вектор (рис. 3). Сеть Кохонена имеет два режима функционирования — режим обучения (самоорганизация на основе обучающей выборки) и режим эксплуатации, в котором сеть распознает входной вектор, относя его к тому или иному кластеру. Дальнейшая статистическая обработка результатов кластеризации позволяет отнести анализируемый вектор к тому или иному классу с заданной вероятностью.

Следует отметить, что нейронная сеть Кохонена обучается без учителя, поэтому на вход сети не подавалась априорная диагностическая информация, а все выводы делались только на основании кластерной структуры данных. В целях предварительной обработки стабิโลграммы были нормированы в соответствии с рекомендациями по предобработке данных для нейронных сетей [25].

Используем в качестве метрической функции нейронной сети квадрат Евклидова расстояния между входным вектором x и вектором весов w_j для каждого нейрона j :

$$d_j(x) = \sum_{i=1}^p (x_i - w_{ij})^2. \quad (1)$$

При срабатывании нейрона его ближайшие соседи возбуждаются сильнее, чем те, которые находятся дальше. Существует топологическая окрестность нейрона-победителя, которая убывает с расстоянием. Если S_{ij} – это латеральное расстояние между нейронами i и j , то топологическая окрестность задаётся:

$$T_{j,I(x)} = \exp(-S_{j,I(x)}^2 / 2\sigma^2),$$

где $I(x)$ – индекс нейрона-победителя, который является максимальным на выигравшем нейроне, симметричен относительно этого нейрона, монотонно убывает до нуля по мере увеличения расстояния и не зависит от местоположения выигрывающего нейрона. При этом размер σ окрестности должен экспоненциально уменьшаться со временем:

$$\sigma(t) = \sigma_0 \exp(-t / \tau_\sigma). \quad (2)$$

Суть топографической окрестности в сети Кохонена состоит в том, что весовые коэффициенты обновляются не только у победившего нейрона, но и у его соседей (не в такой степени, как у победителя). Уравнением обновления весовых коэффициентов нейрона-победителя является соотношение:

$$\Delta W_{ij} = \eta(t) \cdot T_{j,I(x)}(t) \cdot (x_i - w_{ji}), \quad (3)$$

в котором имеется зависящая от времени (эпохи t) скорость обучения

$$\eta(t) = \eta_0 \exp(-t / \tau_\eta). \quad (4)$$

Обновления весовых коэффициентов применяются для всех обучающих шаблонов x в течение всех эпох нейросетевого обучения (самоорганизации).

Эффект каждого обновления обучающего веса заключается в приближении весовых векторов w_i победившего нейрона и его соседей к входному вектору x . Таким образом, повторные представления данных

обучения приводят к топологическому упорядочению. Результатом работы нейронной сети является кластеризация.

При условии, что параметры (σ_0 , τ_σ , η_0 , τ_η) выбраны правильно, алгоритм нейронной сети постепенно приведет к организованному представлению паттернов активации, взятых из входного пространства, начиная с состояния, в котором все весовые коэффициенты заданы случайным образом. На основе алгоритма Кохонена были исследованы стабиллометрические данные с целью выявления маркеров постинсультного состояния и объективизации заключений и диагнозов.

Альтернативным описанному выше подходу к анализу данных стабиллометрии является метод, называемый «решающие деревья» [14], где каждый отдельный вычислитель обрабатывает свой сегмент последовательности непрерывного сигнала, что может позволить выявить не обнаруживаемые до того специфические признаки болезни. Возможно также применение модели многослойной нейронной сети. Модель эта представляет собой полносвязный многослойный перцептрон [20], состоящий из линейных сумматоров, где нелинейность достигается с помощью комбинаций функций активации. Нейронная сеть принимает стабиллометрические данные спектров перемещения центра тяжести пациента по X и Y координатам, всего 138 элементов векторов, кодирующих спектры для X , и 138 спектров для Y , итого на вход подается массив из 276 чисел, кодирующих результаты стабиллометрического теста. Нейронная сеть производит бинарную классификацию последовательности входных данных и на выходе получается число от 0 до 1, после округления до целого, образуется два класса «0» – болен, а «1» – здоров. Выходной сигнал вычисляется по формуле

$$S_{out} = F\left(\sum_{i=0}^M S_i \cdot W_i\right), \quad (5)$$

где S_i – сигнал на отдельном «синапсе», M – количество синапсов, W_i – вес отдельного «синапса», а F – функция активации (ФА). Модель представляет собой цепочки слоёв, состоящих из десятков «нейронов». Чтобы не рисовать каждый нейрон по отдельности, для упрощения схемы в рамках одного слоя будем схематично изображать множество входных сигналов, нейронов, функций активации и выходных сигналов, как на рис. 4. В схематичном отображении слоя обозначаются номера нейронов.

Модель представляет собой полносвязный перцептрон, потому детальное отображение топологии входных и выходных «синапсов» на рис. 4 не требуется (связи между слоями «все со всеми»). С целью построения нейросетевой модели количество нейронов в скрытых слоях подбиралось экспериментально на основе сравнительного анализа различных вариантов. При этом рассматривались сети не только с различным числом нейронов, но и с различным числом слоёв и различными функциями активации нейронов. В результате серии вычислительных экспериментов была

отобрана сеть, которая дала наилучшие результаты. Следует отметить, что используемый авторами метод выбора архитектуры нейронной сети является эвристическим. В связи с тем, что не существует математической процедуры, гарантирующей оптимальную сходимость, все оптимизационные алгоритмы, включая методы нулевого, первого и второго порядков, гарантируют лишь достижение локального экстремума целевой функции, то есть нахождения хорошего решения, в той или иной степени близкого к оптимальному [4]. Таким образом, найденное решение с определённой структурой перцептрона является рациональным.

В качестве метода обучения выбран градиентный спуск [6] с оптимизатором адаптивной оценки момента обучения (*ADAM – Adaptive Moment Estimation*) [15] и бинарной кросс-энтропией [8] в качестве функции ошибки.

Функциями активации (ФА) для скрытых слоев будут являться сигмоида (*Sigmoid*)

$$F(x) = \frac{1}{1 + e^{-x}}, \quad (6)$$

гиперболический тангенс (*Tanh*)

$$F(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (7)$$

и усеченное линейное преобразование (*RELU*)

$$F(x) = \begin{cases} 0, & x < 0 \\ x, & x > 0 \end{cases}. \quad (8)$$

Результаты

В результате спектрального анализа амплитудно-частотных характеристик стабиллограмм испытуемых были получены спектральные портреты этих стабиллограмм в высоком разрешении, которые рассматривались в качестве исходных сигналов (векторов) для проведения нейросетевого анализа. Затем была проведена нейросетевая кластеризация с помощью нейронной сети Кохонена.

С помощью нейросетевой кластеризации спектральных характеристик статкинезиограмм были выявлены маркеры нарушений здоровья в виде информативных кластеров (групп). На рис. 5 приведены примеры некоторых кластеров. Здесь каждой строке соответствует группа, содержащая тот или иной тип спектров анализируемых сигналов. Кластеризации подвергались спектры статкинезиограмм во фронтальной и сагитальной проекциях, при этом полученные спектры были объединены в общий вектор (поэтому в каждой строке-кластере можно наблюдать по два пика, соответствующие началам спектров от этих двух сигналов). Данное изображение было сгенерировано автоматически разработанным нами программным обеспечением и содержит в себе служебную информацию, включая отношение разных типов спектров в кластере, координаты кластеров, параметры сети и итоговые вероятности обнаружения.




Рис. 4. Схематичное представление модели

Применение сетей Кохонена для анализа данных стабилотрии позволило провести их кластеризацию с целью получения информации, пригодной для диагностики состояний человеческого организма. При этом не все выявленные кластеры являются информативными. Например, кластеры с координатами (0, 1) и (0, 0) имеют низкую достоверность обнаружения патологических изменений. Для анализа данных, содержащихся в этих малоинформативных кластерах, целесообразно применение нейронных сетей другого типа, а именно адаптированных для решения соответствующих задач. В целом доля данных, содержащихся в информативных кластерах, превышает 58,14 % от всех обработанных данных стабилотрии, участвовавших в исследовании.

Информативными считали кластеры, в которых вероятность обнаружения или отсутствия патобиомеханических маркеров, связанных с нарушениями мозгового кровообращения у пациентов, перенёсших инсульт, составила выше 65 %. При этом 95%-ный доверительный интервал рассчитывали в соответствии со стандартной методикой вычисления доверительных интервалов для пропорций [2].

Параметры сети Кохонена и результаты нейрокластеризации приведены в табл. 1 и 2 соответственно. Для последующего восстановления исходных стабิโลграмм с привязкой к полученным кластерам по их спектрам были воспроизведены исходные кривые, отражающие форму стабิโลграмм. Таким образом, для анализа результатов нейрокластеризации восстановленные по спектрам кривые были сгруппированы по кластерам с сохранением идентификаторов кластеров, соответствующих координатам нейронов выходного слоя. Результаты проведенного исследования позволили выявить основные типовые паттерны постральной регуляции испытуемых, которые можно классифицировать на основе спектрального состава стабิโลграмм. Параметры сети Кохонена, включая топологию, количество эпох и коэффициенты обучения подбирались экспериментально. Примеры информативных

кластеров в виде набора статкинезиограмм представлены на рис. 6. Проведенный анализ данных стабилотрии позволил в автоматическом режиме выявлять типовую принадлежность групп пациентов, соответствующую норме или патологии. Одним из сопутствующих результатов исследования стало выявление возможности визуализации формируемых с использованием самоорганизующихся сетей Кохонена кластеров для удобства трактовки результатов анализа данных стабилотрии.

На рис. 7 видно, что слева приведена статкинезиограмма кластера (0; 1), справа – (2; 0), а в подписи к рисунку описывается кластер (0; 0).

В результате получен действующий нейросетевой алгоритм анализа данных стабилотрии, верифицированный на данных клиники постинсультной реабилитации.

Следующим шагом для построения модели предсказания болезни по данным стабилотрии с помощью алгоритма «решающих деревьев» была выбрана библиотека *CatBoost* [5]. Проведен поиск оптимальных параметров для модели, результаты которого показаны моделью с параметрами, представленными в табл. 3.

Модель «деревьев решений» очень быстро переобучалась. При этом, несмотря на незначительные ошибки на обучающей выборке, на тестовой выборке ошибка оказывалась значительной. Возможно, при таком подходе деревья не способны корректно распознать паттерны нарушений здоровья и переобучаются на специфичных для конкретного примера параметрах.

В экспериментах с многослойными нейронными сетями с учителем каждая модель обучалась в течение 140 эпох обучения. За одну эпоху модель учится на каждом примере из тестового набора хотя бы один раз. Исходный набор данных был разбит на тренировочную и тестовую выборки в пропорции 67 на 33 %. В результате серии экспериментов скорость обучения (*learning rate*) была выбрана 0,01. Результаты экспериментов представлены на в табл. 4. График обучения наилучшей модели представлен на рис. 7.




Рис. 5. Структура кластеров, полученных с помощью нейронной сети. В каждой строке приведены спектры проанализированных сигналов (покластерно). Красный цвет спектра соответствует патологии, синий — норме. По оси абсцисс указаны порядковые номера точек входных векторов, соответствующие частотам от 0 до 125 Гц. По оси ординат — амплитуды колебаний

Обсуждение

В структуре кластеров выявлены патофизиологические маркеры, обусловленные нарушениями мозгового кровообращения у пациентов, переживших инсульт. Установлено, что анализ данных стабилотриграфии с применением метода нейрокластеризации позволяет сопоставить индивидуальные особенности постурального регулирования с нарушениями здоровья, вызванными поражениями головного мозга.

Характерной особенностью предлагаемого метода является то, что идентифицированные патофизиологические маркеры, обусловленные нарушениями мозгового кровообращения у пациентов, переживших инсульт, являются параметрами найденных математических моделей.

Как показали результаты нейросетевого анализа, только в части случаев сеть способна распознать информативные кластеры. Однако приведённые на рис. 6 отдельные выявленные случаи позволяют не только распознать искомые признаки, но и визуализировать геометрию сходных между собой стабилотриграмм, объединённых по определённому априорному заданному диагностическому признаку. В этом смысле нейросетевой подход с кластеризацией выигрышен, так как позволяет получить наглядную визуальную интерпретацию решений в виде формы кластеров. При этом для повышения точности распознавания можно применять другие методы, которые, однако, не позволяют визуализировать искомые признаки. Рассмотрим деревья решений и нейронные сети, обучаемые с учителем.

Что же дают обнаруженные кластеры, можно ли их

Таблица 1

Параметры сети Кохонена

Параметр сети	Значение параметра
Размерность выходного слоя	30×1
Частота обучения (lr) η_0	0,2
Количество эпох обучения	10000
σ_0	0,3
τ_σ	0,001
τ_η	0,001

Таблица 2

Результаты нейросетевой кластеризации спектральных характеристик статкинезиограмм

Координаты информативных кластеров	Маркер	Достоверность кластера, %	95%-ный доверительный интервал
(25, 0)	Нарушения обнаружены	91,67	(0,76 – 1,07)
(5, 0)	Нарушения обнаружены	88,89	(0,74 – 1,03)
(6, 0)	Нарушения обнаружены	95,92	(0,91 – 1,0)
(1, 0)	Нарушений не обнаружено	65,0	(0,5 – 0,8)
(0, 0)	Нарушения обнаружены	75,0	(0,51 – 0,99)
(1, 1)	Нарушения обнаружены	60,87	(0,41 – 0,81)

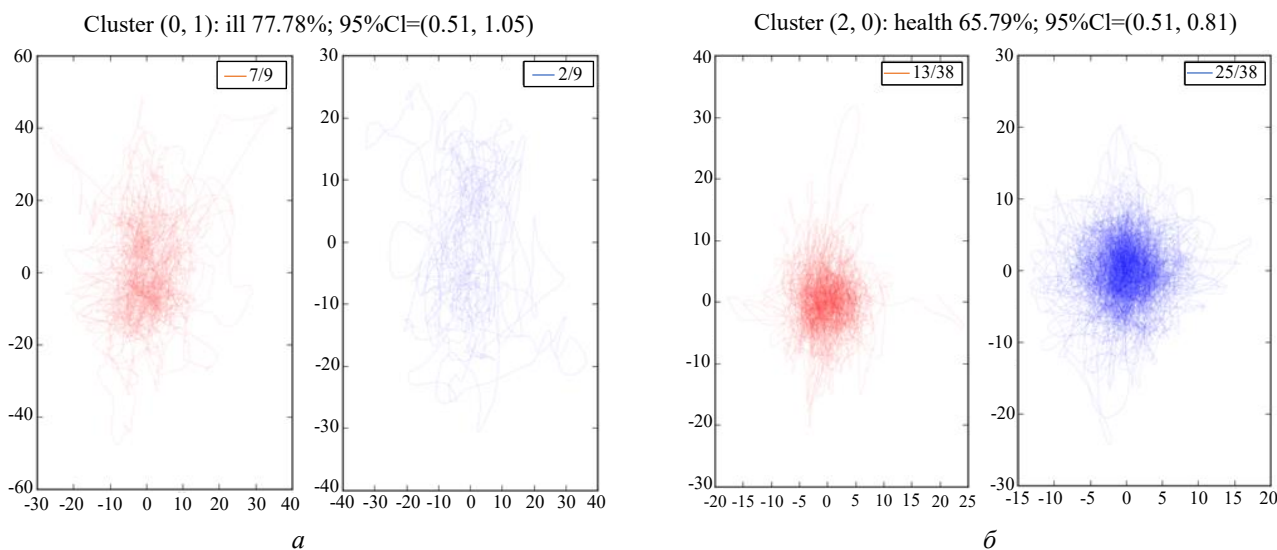


Рис. 6. Кластер {0,1}. Слева – кривые, отнесённые к классу «признаки патологии обнаружены», справа кривые, отнесённые к классу «признаков патологии не обнаружено». Точность распознавания патологических процессов 77,78 %, 95%-ный доверительный интервал: (0,51, 1,05) – а; кластер {2,0}. Слева кривые, отнесённые к классу «признаки патологии обнаружены», справа кривые, отнесённые к классу «признаков патологии не обнаружено». Точность распознавания патологических процессов 65,79 %, 95%-ный доверительный интервал: (0,51, 0,81) – б

использовать как признаки восстановления пациента, перенёсшего инсульт? Как было отмечено выше, признаком наличия патологии является геометрия стабиллометрической кривой, которая задаёт ближайший по Евклидову расстоянию центр соответствующего кластера. При этом весь диапазон частот анализируемого сигнала содержит в себе тот или иной патобиомеханический признак (в зависимости от кластера), задаваемый определённой конфигурацией амплитуд спектра колебаний. В случае, если испытуемый начнёт демон-

стрировать достоверное и устойчивое отсутствие патобиомеханических признаков, то можно говорить о его восстановлении. Однако итоговый диагноз должен выносить врач.

Также в ходе исследований был получен вывод о том, что деревья решений не позволили построить достоверную модель. В связи с этим авторы рекомендуют опираться на эффективные модели и методы, изложенные в данной статье, а именно на нейронные сети с самоорганизацией (Кохонена) и обучаемые с учителем

Таблица 3

Параметры модели на «деревьях решений»

Параметр модели	Значение параметра
Число раундов до ранней остановки (<i>early_stopping_rounds</i>)	600
Скорость обучения (<i>lr</i>)	0,02
Максимальная глубина дерева (<i>max_depth</i>)	6
Параметр L2 регуляризации (<i>l2_leaf_reg</i>)	3
Размер подмножества сигнала (<i>subsampling</i>)	0,5
Число деревьев (<i>n_estimators</i>)	2000

Таблица 4

Результаты проведения экспериментов

Число скрытых слоев (<i>N</i>)	Функция активации (ФА)	Точность модели, %
0	-	64,59
1	Сигмоида	65,59
1	Тангенс гиперболический	68,18
1	Усеченное линейное преобразование	71,09
2	Сигмоида	69,81
2	Тангенс гиперболический	68,18
2	Усеченное линейное преобразование	72,13
3	Сигмоида	65,72
3	Тангенс гиперболический	68,31
3	Усеченное линейное преобразование	71,9

Таким образом, в сравнении с другими методами, сети Кохонена оказались довольно интересной моделью. Нельзя сказать, что эти сети позволяют выявлять патобиомеханические марки во всех случаях, однако в ряде случаев они дают довольно высокие показатели распознавания и при этом позволяют получить наглядные визуальные характеристики этих маркеров. С другой стороны, классические нейронные сети, обучаемые с учителем, сработали также довольно хорошо, давая высокую точность и надёжность выявления нарушений здоровья.

В связи с изложенным авторы полагают, что описанные результаты представляют интерес не только специалистам в области нейросетевого моделирования, но, прежде всего (из-за сравнительно малого числа публикаций, посвящённых кластеризации стабилметрических данных для оценки устойчивости позы), данная статья представляет интерес для практикующих специалистов в области биомеханики.

Заключение

Был разработан и опробован нейросетевой алгоритм, верифицированный на данных, полученных из клиники постинсультной реабилитации. Проведена нейросетевая кластеризация стабилметрических данных для выявления основных типовых паттерно нарушений функционирования системы постурального баланса.

Разработана методика анализа данных стабилметрии с использованием нейросетевой технологии путём выявления кластерной структуры спектральных характеристик стабิโลграмм. Методика открыла дополнительные возможности в оперативном выявлении закономерностей и аномалий в структуре полученных стабилметрических данных.

Выявлено, что в полученных спектральных кластерах содержится диагностическая, биометрическая и другая индивидуализированная информация, выделяемая из данных стабилметрии. Разработанная нейросетевая технология легла в основу экспертной системы экспресс-анализа состояния функциональных систем человека по данным стабилметрии.

Многослойная нейронная сеть позволила выявлять маркеры нарушений здоровья с вероятностью 71,9 %. Данный результат позволяет говорить о наличии маркеров нарушений здоровья внутри анализируемого сигнала. Таким образом, была подтверждена гипотеза исследования, заключающаяся в том, что в спектральных кластерах данных стабилметрии содержится важная диагностическая информация, связанная с нарушениями мозгового кровообращения у пациентов. Таким образом, метод нейрокластеризации может быть с успехом применён для объективизации анализа данных стабилметрии при формировании заключений и выводов о состоянии здоровья испытуемого.

На базе разработанного инструментария авторы планируют заняться перспективными исследованиями




Рис. 7. Процесс обучения наилучшей модели.

для ранней диагностики заболеваний и успешности процесса реабилитации, для оценки состояния космонавтов после космических перелётов, оценки состояния спортсменов, а также в предменструальном контроле

операторов опасных профессий. Авторы открыты к сотрудничеству с исследователями и практикующими специалистами.

Список литературы

1. Бабанов Н. Д. и др. Динамика параметров малоамплитудных движений рук при повторяющейся двигательной задаче // Российский физиологический журнал им. ИМ Сеченова. – 2020. – Т. 106, № 11. – С. 1370–1384.
2. Вентцель Е. С. Теория вероятностей. – М. Юстиция, 2018. – 658 с.
3. Иванова Г.Е. и др. Формирование консенсуса специалистов в применении стабилотрии и биоуправления по опорной реакции // Вестник восстановительной медицины. – 2019. – № 1. – С. 16–21.
4. Тархов Д. А. Нейронные сети как средство математического моделирования // Нейрокомпьютеры: разработка, применение. – 2006. – № 2. – С. 1–49.
5. Al Daoud E. Comparison between XGBoost, LightGBM and CatBoost using a home credit dataset // International Journal of Computer and Information Engineering. – 2019. – Vol. 13(1). – P. 6–10.
6. Amari S. Backpropagation and stochastic gradient descent method // Neurocomputing. – 1993. – Vol. 5(4–5). – P. 185–196.
7. Araujo E., Bentes G. E. F., Zangaro R. Body sway and global equilibrium condition of the elderly in quiet standing posture by using competitive neural networks // Applied Soft Computing. – 2018. – Vol. 69. – P. 625–633.
8. De Boer P. T. et al. A tutorial on the cross-entropy method // Annals of operations research. – 2005. – Vol. 134(1). – P. 19–67.
9. Fey A., Sommer D., Golz M. Comparison of Time and Spectral Domain Features on Postural Signals Utilizing Neural Networks. Proc 1st Int Workshop Biosignal Processing and Classification.
10. Fiołka J., Kidoń Z. Method for stabilogram characterization using angular-segment function // Bulletin of the Polish Academy of Sciences. Technical Sciences. – 2013. – Vol. 61(2).
11. Garkavenko V. V. et al. Modifications of the stabilogram during upright standing posture under conditions of inclines of the support surface // Neurophysiology. – 2012. – Vol. 44(2). – P. 131–137.
12. Golz M. et al. Discriminance analysis of postural sway trajectories with neural networks // Proceedings of the 8th World Multi-Conference on Systemics, Cybernetics and Informatics, Orlando, Florida USA. – 2004. – Vol. 7. – P. 151–155.
13. Halfar R. Effects of Age and Illness to the Complexity of Human Stabilogram // Chaos and Complex Systems. – Springer, Cham, 2020. – P. 83–88.
14. Hastie T., Tibshirani R., Friedman J. Boosting and additive trees // The elements of statistical learning. – Springer, New York, NY, 2009. – P. 337–387.
15. Kingma D. P., Ba J. Adam: A method for stochastic optimization // arXiv preprint arXiv:1412.6980. – 2014.
16. Kohonen T. Self-organizing maps. – Springer Science & Business Media, 2012. – Vol. 30.
17. Kolomiets B., Popov A. Analysis of Stabilograms of Healthy Human Using Time and Frequency Characteristics // 2018 IEEE 38th International Conference on Electronics and Nanotechnology (ELNANO). – IEEE, 2018. – P. 316–320.
18. Maatar D. et al. Discrete wavelet and modified PCA decompositions for postural stability analysis in biometric applications // Journal of Biomedical Science and Engineering. – 2011. – Vol. 4(8). – P. 543.
19. Mataar D. et al. Biometric application and classification of individuals using postural parameters // Int J Comput Technol. – 2013. – Vol. 7(2). – P. 580–593.
20. Noriega L. Multilayer perceptron tutorial // School of Computing. Staffordshire University, 2005.
21. Peterka R. J. Postural control model interpretation of stabilogram diffusion analysis // Biological cybernetics. – 2000. – Vol. 82(4). – P. 335–343.

22. Richer N., Lajoie Y. Automaticity of postural control while dual-tasking revealed in young and older adults // *Experimental aging research*. – 2020. – Vol. 46(1). – P. 1–21.
23. Shan G., Daniels D., Gu R. Artificial neural networks and center-of-pressure modeling: a practical method for sensorimotor-degradation assessment // *Journal of aging and physical activity*. – 2004. – Vol. 12(1). – P. 75–89.
24. Shunkina A. Computer stabilogram method like one of the physiological and biomechanical method of research different motor actions on slippery surface // *Journal of economics and social sciences*. – 2018. – №. 12. – P. 78–80.
25. Sola J., Sevilla J. Importance of input data normalization for the application of neural networks to complex industrial problems // *IEEE Transactions on nuclear science*. – 1997. Vol. 44(3). P. 1464–1468.
26. Tokita T. et al. Classification of stabilograms in healthy subjects using neural network // *Equilibrium Research*. – 2001. – Vol. 60(3). – P. 181–187.
27. Tokita T. et al. Discrimination of Stabilograms by a Neural Network in Patients with Equilibrium Disturbances // *Equilibrium Research*. – 1997. – Vol. 56(6). – P. 542–549.

IDENTIFICATION OF PATHOBIOMECHANICAL MARKERS OF STATOKINESIOGRAMS ON THE EXAMPLE OF NEURAL NETWORK IDENTIFICATION OF A POST-STROKE STATE

I.V. Stepanyan¹, S.S. Grokhovsky², M.A. Savkin³

¹ Mechanical Engineering Research Institute of the Russian Academy of Sciences (IMASH RAN), Moscow, Russia

² Research Center "MERA", Moscow, Russia

³ Peoples' Friendship University of Russia (RUDN University), Moscow, Russia

ARTICLE INFO

Received: 29 June 2022

Approved: 09 March 2023

Accepted for publication: 27 March 2023

Key words:

support reaction, force platform, posturography, stabilometry, cluster analysis, spectral characteristics, visualization, clustering centroids.

ABSTRACT

The purpose of this study is neural network modeling and determination of the parameters of statokinesiograms, which are carriers of useful information about the features of postural regulation, which determined the obtained trajectory of movements of the human center of mass. A technique for obtaining informative markers by identifying clustering centroids based on self-organizing Kohonen neural networks with the Euclidean metric has been developed. Kohonen networks trained without a teacher (that is, without the use of a priori diagnostic information about the state of the subjects) are a powerful and informative method that allows you to obtain not only graphic, but also mathematical markers of health disorders in subjects, to explore the biomechanics of micromovements of the center of pressure based on a flexible mathematical apparatus — neural network cluster analysis. On the example of the identification of the post-stroke state, a neural network analysis of stabilometric data was carried out and a method for identifying pathobiomechanical markers of statokinesiograms was shown, which made it possible to standardize the type affiliation of the groups of subjects. With the help of neural networks, it was possible to identify clusters that are amenable to biomedical interpretation with a reliability of up to 95.9%, which determines the theoretical significance of the results obtained. Decision trees and a supervised multilayer neural network were also considered. A multilayer neural network made it possible to identify markers of health disorders with a probability of 71.9 %.

© PNRPU