

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ В НЕЙРОНАУКЕ

Иосько М.А. студент гр.428504, Горбель А.А. студент гр.428503

*Белорусский государственный университет информатики и
радиоэлектроники г. Минск, Республика Беларусь*

Цегельник В.В. – доктор физ.-мат. наук, профессор каф. ВМ

Аннотация. Изучены современные методы машинного обучения для анализа данных мозга. Разработан концепт модели, позволяющий приматам с травмой спинного мозга восстановить подвижность конечностей. Подробно описаны этапы работы системы: сбор данных, предобработка, обучение модели и оценка её эффективности.

Современная нейронаука переживает эпоху цифровой трансформации благодаря машинному обучению. Такие методы помогают анализировать большие объемы данных, получаемых с помощью функциональной магнитно-резонансной томографии, позитронно-эмиссионной томографии и электроэнцефалографии. Например, машинное обучение выявляет паттерны активности мозга, связанные с болезнью Паркинсона, что невозможно сделать традиционными статистическими методами. Это позволяет раньше диагностировать заболевания и разрабатывать персонализированные методы лечения. Глубокие нейронные сети также играют ключевую роль в создании нейропротезов, адаптированных к индивидуальным особенностям пациентов [1].

На сегодняшний день были изобретены следующие типы нейросетей, такие как сверточные нейронные сети, рекуррентные нейронные сети, сети долгой краткосрочной памяти и автоэнкодеры. Каждая из этих архитектур обладает уникальными свойствами и применяется для решения различных задач в области нейронауки.

В эксперименте учёных из Швейцарской высшей технической школы использовали гибридную систему «мозг-машина», для восстановления двигательных функций у приматов с повреждением спинного мозга, как показано на рисунке 1. Имплантированные электроды регистрировали нейронную активность премоторной коры, связанную с планированием движений, в режиме реального времени. Сигналы обрабатывались многослойным перцептроном, который преобразовывал их в команды для электростимуляции спинного мозга. Это позволило обойти поврежденные нервные пути, активируя двигательные нейроны ниже уровня травмы. В результате 70% испытуемых восстановили способность к ходьбе с точностью управления до 92%. Дополнительные исследования показали, что долговременное применение нейроинтерфейса способствовало восстановлению координации движений и сокращению времени реакции.

Рисунок 1 – Системы «мозг-машина»



Анализ архитектуры моделей машинного обучения требует рассмотрения ключевых компонентов каждой подобной системы: входные данные, веса и смещения (константы полученные в ходе обучения), функции активации, выходные данные. В дальнейшем эти компоненты

взаимодействуют определённым образом, что позволяет трансформировать нейронные импульсы в управляющие сигналы для парализованных конечностей.

На первом этапе система «мозг-машина» фиксирует сигналы мозга обезьяны, во время ходьбы по беговой дорожке, как показано на рисунке 2. Регистрация осуществляется с помощью 96 электродов, установленных на её голове. Для мотивации используются пищевые стимулы или интерактивные объекты, побуждающие животное к активности.



Рисунок 2 – Обезьяна, идущая по беговой дорожке

Далее, на втором этапе собранная информация подвергается обработке для устранения помех и приведения сигналов к единому формату, так как нейронные импульсы содержат шумовые искажения, вызванные внешними факторами. Посторонние колебания затрудняют анализ, поэтому применяется полосовой фильтр, пропускающий только сигналы в заданном диапазоне частот и блокирующий остальные. Например, фильтрация в пределах 0,5–40 Гц позволяет выделить компоненты, характерные для мозговой активности. Дополнительно проводится нормализация, так как различия в амплитудах усложняют обучение модели. Приведение данных к единому масштабу делает их сопоставимыми, а один из методов нормализации — масштабирование значений в интервале [0, 1] по методу мин-макс масштабирования:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}, \quad (1)$$

где x — исходные данные; $\min(x)$ и $\max(x)$ — минимальное и максимальное значения частот в рассматриваемом наборе данных.

На следующем этапе собранные данные распределяются на обучающую, валидационную и тестовую выборки для оценки качества модели и предотвращения её переобучения. Обучающая выборка применяется для обучения модели, помогая ей установить связи между сигналами мозга, движениями и сжатием мышц, а также выявлять паттерны и зависимости, настраивая параметры для минимизации ошибки предсказания. Валидационная выборка используется для контроля качества модели на каждом этапе обучения, позволяя корректировать параметры и предотвращать переобучение, при котором модель слишком сильно адаптируется к обучающим данным, теряя способность работать с новыми. Тестовая выборка предназначена для финальной оценки модели, так как данные из этой выборки не использовались ни в процессе обучения, ни в процессе валидации, что позволяет объективно оценить её производительность.

После того как данные распределены, выделяют этап, в котором для решения задачи применяется многослойный перцептрон, состоящий из нескольких слоев нейронов, каждый из которых связан с нейронами предыдущего и следующего слоя. Входной слой принимает нервные импульсы, в скрытых слоях происходят нелинейные преобразования, а выходной слой генерирует команды, которые передаются на электроды. Нелинейные преобразования на скрытых слоях вычисляются по следующей формуле:

$$z_i = \sum_{j=0}^n (w_{ij} \cdot x_j) + b_i, \quad (2)$$

где z_i — значение каждого нейрона перед применением функции активации; x_j — значение нейрона на предыдущем слое; w_{ij} — веса, соответствующие каждому входному x_j ; b_i — смещение нейрона на текущем слое.

После этого в каждом нейроне выполняются нелинейные преобразования с использованием функций активации, например, *ReLU* (*Rectified Linear Unit* или выпрямленный линейный блок), которая определяет выходное значение следующим образом:

$$ReLU(x) = \max(0, x), \quad (3)$$

где $\max(0, x)$ — функция, которая выбирает максимальное число из нуля и значения нейрона x .

Данная функция (*ReLU*) игнорирует отрицательные значения, что снижает лишние вычисления и помогает модели работать точнее.

Этот процесс повторяется для каждого скрытого слоя нейронной сети, пока не будет достигнут выходной слой, который генерирует итоговое предсказание, в данном случае — нейронные импульсы для конечности с частичной дисфункцией.

Ключевым этапом в обучении нейронной сети является обратное распространение ошибки — это процесс обучения нейросети, позволяющий корректировать её параметры (веса и смещения) для минимизации расхождений между предсказаниями и реальными данными. На примере задачи управления парализованными конечностями этот этап можно представить как систему «обратной связи», где сеть учится на своих ошибках, постепенно улучшая точность преобразования нейронных сигналов в двигательные команды. Для нейроинтерфейсов, где критична точность декодирования сигналов, среднеквадратичная ошибка является оптимизационным ориентиром: чем меньше значение функции потерь L , тем точнее модель воспроизводит целевые движения. В основе процесса лежит функция, которая количественно оценивает отклонения предсказанных значений ($\hat{y}$) от истинных (y):

$$L = \frac{1}{N} \sum_{i=0}^N (y_i - \hat{y}_i)^2, \quad (4)$$

где L — среднеквадратичная ошибка; N — количество нейронов на предыдущем уровне.

Градиенты функции потерь по параметрам сети (w_{ij} , b_i) определяют, как сильно каждый вес или смещение влияют на итоговую ошибку. Согласно правилу цепочки, градиенты вычисляются в обратном порядке — от выходного слоя к входному:

$$\nabla L = \left(\frac{\partial L}{\partial w_1}, \frac{\partial L}{\partial w_2}, \dots, \frac{\partial L}{\partial w_n}, \frac{\partial L}{\partial b_1}, \frac{\partial L}{\partial b_2}, \dots, \frac{\partial L}{\partial b_m} \right), \quad (5)$$

где ∇L — градиент функции потерь; $\frac{\partial L}{\partial w_n}$ — частные производные L по весам w_n ; n — число весов; $\frac{\partial L}{\partial b_m}$ — частные производные L по смещениям b_j ; m — число смещений.

Найденные градиенты используются для корректировки весов и смещений. Обновление происходит по следующей формуле:

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla L, \quad (6)$$

где θ — вектор параметров; η (скорость обучения) — гиперпараметр.

Гиперпараметр регулирующий «шаг» корректировки. Для задач нейроинтерфейсов типичные значения η лежат в диапазоне 0.001–0.1, что обеспечивает баланс между скоростью обучения и стабильностью.

После обучения модель оценивается на тестовой выборке, чтобы проверить, как хорошо она справляется с задачами. Тестовая выборка состоит из данных, которые не использовались в процессе обучения и валидации, что позволяет объективно измерить способность модели обрабатывать новые, незнакомые данные. Для оценки качества работы модели применяется функция потерь, которая вычисляет разницу между предсказанными результатами и реальными значениями.

Применение нейросетевых методов в трансляции нейросигналов в управляющие команды демонстрирует значительное превосходство по сравнению с традиционными линейными моделями. Эти технологии обеспечивают не только анализ многомерных данных, но и адаптацию к индивидуальной нейронной активности, что критично для персонализированной медицины. Модели машинного обучения характеризуются высокой устойчивостью к артефактам и шумам, что значительно повышает надежность обработки сигналов. Важным преимуществом является также возможность работы в реальном времени с минимальной задержкой обработки, что особенно актуально для управления нейропротезами и взаимодействия с интерфейсами мозг-компьютер [2].

Перспективные направления исследований включают разработку энергоэффективных нейросетевых моделей для имплантируемых устройств, интеграцию гибридных алгоритмов, сочетающих статистические и глубокие методы, а также изучение механизмов нейропластичности в

контексте интерфейсов мозг-компьютер. В конечном итоге, это может привести к созданию автономных адаптивных систем для пациентов с параличом, что потенциально позволит преодолеть последствия травм спинного мозга и восстановить полноценную жизнь.

Список использованных источников:

- [1] Capogrosso, m., milekovic, t., borton, d. *Et al.* A brain–spine interface alleviating gait deficits after spinal cord injury in primates. *Nature* 539, 284–288 (2016).
- [2] Lorach h, galvez a, spagnolo v, martel f, karakas s, intering n. Walking naturally after spinal cord injury using a brain-spine interface. *Nature* 2023, 618: 126–133.

APPLICATION OF MACHINE LEARNING IN NEUROSCIENCE

Iosko M.A. student gr.428504, Gorbel A.A. student gr.428503

*Belarusian State University of Informatics and Radioelectronics,
Minsk, Republic of Belarus*

Tsegelnik V.V. – Doctor of Physical and Mathematical Sciences, Professor of the Department of HM

Annotation. Modern machine learning methods for analyzing brain data have been studied. A model concept has been developed that allows primates with spinal cord injury to restore limb mobility. The stages of the system's operation are described in detail: data collection, preprocessing, model training and evaluation of its effectiveness.