

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОТСЛЕЖИВАНИЯ ЕЖЕДНЕВНОЙ АКТИВНОСТИ НА НОСИМЫХ УСТРОЙСТВАХ ПОД УПРАВЛЕНИЕМ IOS

Д. А. Семенович

Белорусский государственный университет, г. Минск;

dima.semenovich.01@icloud.com;

науч. рук. – М. И. Давидовская, ст. преп.

Статья посвящена исследованию обучения нейронных сетей для классификации пользовательской активности на основе показателей с сенсоров мобильных носимых устройств и использование классифицированных данных для демонстрации пользователю в прикладном мобильном приложении под управлением iOS и watchOS.

Ключевые слова: iOS; watchOS; нейронные сети; классификация активности; мобильное приложение.

ВВЕДЕНИЕ

На данный момент в мире возник огромный спрос на услуги сферы здравоохранения и ухода за собой. Активный образ жизни — один из способов сохранить свое долголетие, поддержать свое физическое и ментальное здоровье. В связи с этим фактором чрезвычайно перспективным направлением является разработка мобильных приложений для поддержания здорового образа жизни.

При помощи мобильных программ можем считать количество пройденных шагов, оптимальное время сна и спортивных занятий, потраченные калории, измерять пульс и давление. Также существуют цифровые продукты, которые напоминают о необходимости принять лекарство, улучшают жизнь диабетикам, контролируя уровень сахара, и отправляют врачам данные о работе сердца пациентов с сердечными заболеваниями. Мобильные приложения, которые помогают следить за здоровьем, относятся к категории Health-приложений. При помощи Health-приложений уже сейчас человечество собирает огромные массивы данных о здоровье по всей планете, а нейросети учатся их анализировать. Искусственный интеллект помогает по-новому взглянуть на медицину и методы лечения людей.

ДАТЧИКИ МОБИЛЬНЫХ УСТРОЙСТВ

Большинство современных смартфонов оснащается акселерометром. Акселерометр или G-сенсор — это датчик, определяющий угол наклона электронного устройства по отношению к земной поверхности. На основании данных от датчика программное обеспечение понимает положение смартфона, и поворачивает изображение на дисплее. Иными словами, именно акселерометр способствует автоматическому повороту экрана в альбомную ориентацию при повороте телефона.

Также этот датчик фиксирует ускорение перемещения устройства в пространстве, одновременно сопоставив три пространственные координаты. В рамках проведённого исследования показания акселерометра применяются для классификации пользовательской активности.

Дополнительно в работе был задействован сенсор частоты сердечных сокращений. Это специальный тип датчика, который размещается с обратной стороны умных часов, например Apple Watch. Данный датчик работает по принципу фотоплетизмографии.

Датчик имеет зелёный светодиод, который подсвечивает кровь и фотодиод, который считывает отражение. Во время каждого сокращения сердца объем крови, поступающий в сосуды, увеличивается, а в промежутке, наоборот, уменьшается. Эти параметры и регистрирует датчик. Такой метод позволяет определять количество сердечных сокращений в диапазоне от 30 до 210 ударов в минуту.

В 2017 году Стэнфордский университет провёл исследование [4], где подробно описал качество работы измерителей пульса в носимых устройствах. Оказалось, что в погрешность Apple Watch составляет 2%, что является весьма высоким показателем.

В рамках данной работы была поставлена задача классификации стадий сна. Исследуемая задача относится к задаче классификации, так как имеется изначально определённый набор классов, к которым необходимо соотнести фазы сна, в которых пользователь на основе показаний акселерометра и пульсометра находится в данный момент.

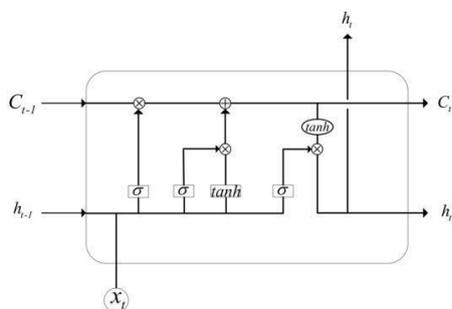
РЕКУРРЕНТНАЯ НЕЙРОННАЯ СЕТЬ LSTM

В нашей задаче среди потока данных нет точного разделения, когда и какая фаза сна происходит. Продолжительность колебаний и количество сокращений сердца будет отличаться, а переход из одной стадии к другой будет неявным. Анализ данных построчно будет неэффективным. Следовательно, необходимо анализировать данные

«блоками». Иными словами, разделим данные, получаемые с датчиков на части фиксированной длины и фиксированное количество записей.

Для анализа блоков данных используем рекуррентные нейронные сети. Их особенность заключается в том, что позволяют обрабатывать серии событий во времени. Рекуррентные нейронные сети LSTM — нейронные сети с долгой краткосрочной памятью. В них присутствуют циклы, сохраняющие информацию. Рекуррентную нейронную сеть можно развернуть, как цепочку повторяющихся слоёв нейронной сети.

Сети LSTM содержат нейроны для выполнения вычислений, которые называют ячейками памяти. Эти ячейки содержат веса и гейты или ворота; гейты являются отличительной чертой моделей LSTM. Внутри каждой ячейки есть 3 гейта (gate): входной гейт (input gate), гейт утраты (forget gate) и выходной гейт (output gate) (см. Рис.1).



Структура нейрона нейронной сети LSTM

C_{t-1} - Состояние предыдущей ячейки

C_t - Состояние текущей ячейки

h_{t-1} - Входной результат предыдущей ячейки

h_t - Входной результат текущей ячейки

x_t - Входные данные

σ - Сигмоидная функция активации

\tanh - Гиперболическая функция активации

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Данные используемые нами при обучении модели были собраны в Мичиганском университете с июня 2017 года по март 2019 года, и в общей сложности состоят из 31-го эксперимента. Набор данных состоит из класса стадии сна, времени замера показателей, идентификатора эксперимента и значения акселерометра по трём осям, количества

шагов, показателей пульса. Классы активности включают в себя 5 классов: wake (пользователь не спит), N1, N2, N3, REM.

Обучение нейронной сети происходило при помощи фреймворка iOS SDK Core ML. По результатам тестирования нейронная сеть показала точность 80% для показателя отличия сна от пробуждения. Также при тестировании классификации 5-ти классов (awake, N1, N2, N3, REM) была достигнута точность 58%. Проведя исследование специфики каждой из стадий возможно достичь большей точности, объединив классы N1 и N2 в один и сузив задачу до 4-х классов (awake, N1+N2, N3, REM), так как два данных класса представляют собой быструю стадию сна, а также возможно объединить классы до 3-х (awake, NREM, REM).

Библиографические ссылки

1. Семенович Д. А. Проектирование и реализация мобильного приложения отслеживания ежедневной активности для iOS. / Д. А. Семенович, М. И. Давидовская, НАУЧНЫЕ ИССЛЕДОВАНИЯ XXI ВЕКА, № 1 (15), 2022. — С. 15-20. URL — <http://scientific-research.ru/files/JOURNAL--1--15-.pdf>
2. Hermans M. and Schrauwen B. Training and analyzing deep recurrent neural networks, 2013.
3. Goodfellow I., Bengio Y., Courville A. Deep Learning, 2016
4. Shcherbina A., et al. Accuracy in wrist-worn, sensor-based measurements of heart rate and energy expenditure in a diverse cohort. J. Personal. Med. 7, 3 (2017). <https://doi.org/10.3390/jpm7020003>.