



Определение эмоционального состояния человека на основе интеллектуального анализа электроэнцефалографических данных

В. Р. Романюк^а, младший научный сотрудник, orcid.org/0009-0003-3307-1497

А. М. Кашевник^а, канд. техн. наук, старший научный сотрудник, orcid.org/0000-0001-6503-1447, alexey@iias.spb.su

^аСанкт-Петербургский Федеральный исследовательский центр РАН, 14-я линия В. О., 39, Санкт-Петербург, 199178, РФ

Введение: определение эмоциональной валентности на основе электроэнцефалографических данных является актуальной проблемой, однако традиционные многоэлектродные системы непригодны для повседневного использования. Более того, сигналы портативных малоканальных устройств отличаются высоким уровнем шума и значительной вариативностью между пользователями, что усложняет их анализ и интерпретацию. **Цель:** разработать подход к интеллектуальному анализу электроэнцефалографических данных с использованием глубоких нейронных сетей, пригодный для надежного определения эмоциональной валентности по сигналам малоканальных носимых устройств. **Результаты:** предложен комплексный подход, включающий обработку сигналов и классификацию с помощью нейронных сетей. Выполнено обучение нейросетевых моделей на открытом наборе многоканальных электроэнцефалографических данных с последующим тестированием на собственном наборе данных, записанном с использованием четырехэлектродной носимой головной повязки. В результате экспериментов точность распознавания положительных, отрицательных и нейтральных эмоций составила от 70 до 75 % при межсубъектной проверке на открытых данных и достигла 85–91 % при валидации с использованием методов компьютерного зрения на собственном наборе данных. **Практическая значимость:** полученные результаты подтверждают возможность использования предложенных моделей в системах мониторинга эмоционального и когнитивного состояния человека на основе компактных носимых устройств. **Обсуждение:** выявлена необходимость дополнительной адаптации моделей для снижения влияния межсубъектной вариативности и шума.

Ключевые слова — интеллектуальный анализ данных, машинное обучение, сверточные нейронные сети, рекуррентные нейронные сети, мониторинг эмоционального состояния, электроэнцефалография.

Для цитирования: Романюк В. Р., Кашевник А. М. Определение эмоционального состояния человека на основе интеллектуального анализа электроэнцефалографических данных. *Информационно-управляющие системы*, 2025, № 5, с. 64–71. doi:10.31799/1684-8853-2025-5-64-71, EDN: KLTIBU

For citation: Romaniuk V. R., Kashevnik A. M. Assessment of psycho-emotional state of a person using AI-based EEG analysis. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 5, pp. 64–71 (In Russian). doi:10.31799/1684-8853-2025-5-64-71, EDN: KLTIBU

Введение

Интерес к анализу эмоционального состояния человека постоянно растет, поскольку внутренние переживания и когнитивные реакции оказывают существенное влияние на поведение, эффективность деятельности и социальное взаимодействие. Одним из наиболее информативных методов исследования мозговой активности является электроэнцефалография, неинвазивно регистрирующая изменения электрических потенциалов на поверхности головы. На протяжении десятилетий электроэнцефалография считалась преимущественно лабораторным инструментом, требующим множества электродов и фиксированных условий записи. Однако в последние годы широкое распространение получили портативные носимые устройства, обладающие меньшим числом каналов и сухими электро-

дами, что позволяет проводить исследования вне специализированных лабораторий и ближе к реальным жизненным условиям. Такое сдвигение в сторону компактных систем одновременно открывает перспективы и порождает новые трудности, связанные со значительными шумами, нестабильным контактом электродов и высокой межсубъектной вариативностью данных.

Одной из проблем, решаемых на основе электроэнцефалографии, является определение валентности эмоций, т. е. их положительной, отрицательной или нейтральной окраски. Традиционные подходы к распознаванию эмоций часто используют внешние признаки вроде выражений лица, речи или жестов, но эти сигналы не всегда отражают глубинные эмоциональные состояния, а также могут искажаться культурными особенностями, освещением или качеством записи видео и звука. Электроэнцефалография,

напротив, напрямую связана с динамикой мозговой активности и способна фиксировать даже те эмоциональные реакции, которые внешне почти не проявляются. Именно поэтому использование электроэнцефалографии становится все более востребованным в системах персонализированного пользовательского опыта и технологиях для психического здоровья. Однако классические стационарные системы с множеством электродов мало подходят для повседневного применения, поэтому разработка методов, способных распознавать эмоциональную валентность при всего нескольких регистрационных каналах, становится ключевой инновационной целью.

Настоящее исследование направлено на разработку и оценку подхода к интеллектуальному анализу электроэнцефалографических (ЭЭГ) сигналов для определения эмоциональной валентности с помощью нейронных сетей. В ходе исследования предпринимались попытки применить трансферное обучение: модель, обученная на публичном многоканальном наборе данных, переносилась на собственный набор данных, где число электродов меньше, а условия сбора сигналов более вариативны. Такой подход позволил оценить, насколько методы устойчивы к реальным помехам и индивидуальным различиям. В то же время проводится валидация методов ЭЭГ-анализа с использованием компьютерного зрения для определения эмоций.

Анализ существующих подходов к определению эмоционального состояния человека на основе электроэнцефалографии

На сегодня существует множество подходов и технологий анализа эмоционального состояния. Среди них наиболее распространены методы, основанные на использовании компьютерного зрения, физиологических сигналов, в частности электроэнцефалографии. Последний подход особенно актуален ввиду способности электроэнцефалографии фиксировать внутренние состояния человека, которые могут не проявляться внешне.

С теоретической точки зрения эмоции обычно рассматриваются либо как дискретные категории, либо как состояния, расположенные на непрерывных шкалах валентности (приятно–неприятно) и возбуждения (высокое–низкое). Например, модель Плутчика предлагает восемь базовых эмоций, организованных по интенсивности и полярности [1]. В то же время модель Лэнга описывает эмоции в двухмерной плоскости валентности и возбуждения [2].

Для провоцирования эмоций в лабораторных условиях чаще всего используются аудиовизу-

альные стимулы (видео, изображения, музыка), которые вызывают нужные эмоциональные состояния у испытуемых. Также применяется метод автобиографического воспоминания, в ходе которого участники вызывают эмоции, вспоминая личные переживания из прошлого. Маркировка эмоциональных состояний обычно выполняется через самооценку участников с использованием различных шкал.

Авторы ранних исследований распознавания эмоций на основе электроэнцефалографии широко применяли традиционные алгоритмы машинного обучения, использующие ручную выбранные признаки (мощность спектральной плотности в различных диапазонах частот, статистические параметры). Например, в работе [3] с помощью метода опорных векторов достигалась эффективная классификация положительных, отрицательных и нейтральных эмоций. Недостатком таких методов является необходимость экспертных знаний для выбора наиболее информативных признаков, а также низкая способность модели уловить сложные закономерности ЭЭГ-сигналов.

В последние годы стали популярны методы глубокого обучения, такие как сверточные нейронные сети (Convolutional Neural Network, CNN) и рекуррентные нейронные сети (Recurrent Neural Network, RNN). CNN способны автоматически извлекать локальные временные и пространственные паттерны из ЭЭГ-данных без необходимости вручную подбирать признаки. Например, авторы работы [4] продемонстрировали высокие результаты классификации валентности и возбуждения с помощью многоколоночной CNN. Рекуррентные сети, особенно LSTM и GRU, в свою очередь позволяют учитывать временные зависимости ЭЭГ-сигналов и эффективно моделировать динамику эмоциональных состояний, как показано в работе [5], где достигнута точность 96–99 % для классификации валентности, возбуждения и предпочтений. В работе [6] предложена гибридная модель 1D-CNN-BiLSTM для распознавания эмоций, вызванных музыкой, с подтвержденной высокой точностью распознавания отрицательных эмоций.

Одновременно развивается направление применения малоканальных носимых ЭЭГ-устройств, которые более удобны для использования в повседневной жизни. В исследованиях [7, 8] показано, что носимые устройства с небольшим числом электродов способны достигать приемлемой точности классификации эмоций (75–87 %), однако при этом возникает проблема снижения пространственного разрешения и качества сигнала.

Также следует выделить исследования, посвященные определению физиологических параметров из ЭЭГ-сигнала. Например, авторы работы

[9] выявили сильную корреляцию между ЭЭГ-сигналами и движениями глаз. В исследовании [10] была продемонстрирована высокая точность метода электроокулографии при определении амплитуды и направления саккад. Авторы [11] достигли точности определения направления взгляда до $1,008^\circ$ угла зрения при использовании 64-канального электроэнцефалографа.

Для повышения точности классификации некоторые исследователи используют комбинацию электроэнцефалографии и оптических систем [12, 13], что позволяет улучшить результаты в сравнении с отдельным использованием каждого из методов. В работе [14] был успешно протестирован интерфейс взаимодействия человек-компьютер на основе электроэнцефалографии и электроокулографии, подтвердивший свою эффективность в управлении роботами.

Тем не менее перенос ЭЭГ-методов на носимые устройства сопряжен с рядом технических ограничений, среди которых низкое качество сигнала из-за сухих электродов, меньшее количество каналов и чувствительность к движениям и внешним помехам [15, 16]. Для уменьшения шумов применяются методы обработки сигналов, такие как анализ независимых компонент (ICA), что подтверждается работами [17, 18].

Несмотря на сложности, портативные ЭЭГ-устройства успешно применяются в мониторинге психического состояния и когнитивной нагрузки в естественных условиях [19–21]. В последнее время методы глубокого обучения, такие как сети LSTM и гибридные CNN-LSTM-модели, активно внедряются для обработки ЭЭГ-сигналов и классификации глазодвигательной активности, демонстрируя высокие показатели точности (до 95–97 %) [22–24].

Таким образом, современные исследования подтверждают перспективность применения глубоких нейросетевых подходов в анализе эмоционального состояния на основе малоканальных носимых ЭЭГ-устройств, несмотря на возникающие технические трудности. Отчасти они проявляются в межсубъектной вариативности, сложностях сегментации и фильтрации, а так-

же в потребности в методах глубокого обучения, способных обрабатывать длинные и шумные временные ряды.


Предлагаемый подход

На основе анализа существующих методов и выявленных ограничений в области интеллектуального анализа ЭЭГ-данных в рамках настоящего исследования предлагается подход, изображенный на рис. 1. Особое внимание уделяется применению глубоких нейросетевых моделей, адаптированных к условиям использования малоканальных носимых ЭЭГ-устройств, а также изучению возможностей трансферного обучения.

Исследование сосредоточено на проблеме распознавания эмоциональной валентности (положительной, отрицательной, нейтральной) по данным электроэнцефалограммы, полученным в том числе с носимых устройств с небольшим числом электродов.

Для обучения и предварительной оценки подхода применялся открытый набор данных FACED [25], где регистрация велась многоканальной ЭЭГ-системой (30 каналов, 250 Гц), а участники просматривали видеофрагменты, вызывающие различные эмоции. Каждый ролик сопровождался субъективной самооценкой эмоции.

Собственный набор данных был собран на группе участников, которые в течение нескольких часов выполняли задания, целью которых было изменение эмоционального состояния. Запись электроэнцефалограммы велась носимой головной повязкой BrainBit (4 канала, 250 Гц) (рис. 2). Параллельно осуществлялась видеозапись лица для последующего сравнения эмоциональных меток, полученных с помощью компьютерного зрения и с помощью электроэнцефалографии. Это позволяло проверить, насколько модель, обученная на наборе данных FACED, способна переноситься на совершенно другой набор записей, сделанных в менее контролируемых ус-



■ **Рис. 1.** Подход для определения эмоционального состояния человека на основе интеллектуального анализа ЭЭГ-данных

■ **Fig. 1.** Approach to determine the psychoemotional state of a person based on intelligent analysis of electroencephalographic data



■ **Рис. 2.** Носимая головная повязка BrainBit, использованная для регистрации ЭЭГ-сигнала

■ **Fig. 2.** Wearable headband BrainBit employed for EEG signal registration

ловиях и с меньшим числом каналов. Поскольку BrainBit имеет четыре сухих электрода (O1, O2, T3, T4), из FACED выбирались каналы, наиболее близкие к такому покрытию (O1, O2, C3, C4), чтобы модель при обучении опиралась только на эти сигналы.

На обоих наборах данных выполнялись стандартные процедуры улучшения качества сигнала. Прежде всего применялся полосовой фильтр в пределах 0,5–40 Гц для подавления низкочастотных дрейфов и высокочастотных наводок. Затем сигналы разбивались на короткие интервалы без перекрытия, и для каждого интервала выполнялась нормализация путем вычитания медианы и масштабирования по амплитуде:

$$\mathbf{x}_{norm} = \frac{\mathbf{x} - \text{median}(\mathbf{x})}{\max(\mathbf{x} - \text{median}(\mathbf{x}))},$$

где $\mathbf{x}$ — это вектор признаков, представляющий ЭЭГ-сигнал на выделенном временном интервале.

Одной из моделей для классификации эмоциональной валентности был вариант сверточной сети TSception [26], подходящей для временных рядов электроэнцефалограммы. Модель включает несколько параллельных ветвей временных сверток, позволяющих охватывать разные масштабы, а также пространственные свертки по каналам для учета межэлектродных связей. На выходе сеть формирует внутреннее представление, которое далее проходит через полносвязный слой и классифицируется на три класса: положительная валентность, отрицательная и нейтральная.

Второй используемой моделью стала нейронная сеть LSTM, принимающая на вход протяженный по времени сигнал с каждого из каналов электроэнцефалограммы. Классификация происходит с помощью полносвязного слоя, который преобразует внутреннее состояние в один из трех классов валентности. Модели последовательно передается исследуемый отрезок электроэнце-


фалогаммы и в качестве результата берется последний вывод модели.

Обучение модели проходило в среде PyTorch с использованием алгоритма Adam, при этом применялась кросс-энтропия в качестве функции потерь. При неравномерном распределении примеров по классам использовался взвешенный саплер, чтобы модель видела больше примеров редко встречающихся меток. Для выбора оптимальных гиперпараметров модели TSception был проведен поиск по сетке, включавшей число временных ядер модели, пространственных ядер модели, нейронов скрытого слоя, вероятность исключения нейрона и начальную скорость обучения. Сетка для модели LSTM состояла из количества нейронов скрытого слоя, количества скрытых слоев, вероятности исключения нейрона и начальной скорости обучения.

Процесс обучения осуществлялся в течение максимум 100 эпох с использованием техники ранней остановки. Остановка происходила при достижении лучшего результата на валидационном наборе данных для предотвращения переобучения. По итогам всех итераций поиска по сетке выбиралась модель, показавшая наивысшую точность на валидационных данных. Для используемого набора данных лучшие результаты показала модель TSception с пятью временными и пространственными ядрами, 512 нейронами скрытого слоя, 50 %-й вероятностью исключения нейрона и начальной скоростью обучения, равной 0,001. Модель LSTM показала лучший результат при 128 нейронах скрытого слоя, одном скрытом слое, 50 % вероятности исключения нейрона и начальной скорости обучения, равной 0,0001.

Основными метриками при оценке выступали точность (Accuracy) и F1-мера. В публичном наборе данных FACED было проведено классическое разбиение «обучение–валидация–тест» (80/10/10), а также тестировалась схема leave-one-subject-out (LOSO-CV), когда на каждом шаге данные одного участника полностью исключались из обучения. Переносимость на собственный набор данных проверялась сопоставлением результатов работы модели на основе электроэнцефалографии с оценкой, полученной компьютерным зрением, обрабатывающим видеоролики лиц [27].

По итогам экспериментов на FACED модель TSception достигла наибольшей точности в 73,33 %, а при LOSO-CV (рис. 3) показатели несколько снижались из-за индивидуальных отличий. Сравнение моделей TSception и LSTM представлено в табл. 1. На собственном наборе данных согласованность модели TSception с методом компьютерного зрения превосходит 80–85 % в большинстве случаев (табл. 2). Полученные



■ **Рис. 3.** Точность определения валентности эмоций при исключении тестового участника из тренировочной выборки
 ■ **Fig. 3.** Emotion valence recognition accuracy when excluding the test participant from the training set

■ **Таблица 1.** Сравнение моделей при определении валентности эмоций на публичном наборе данных

■ **Table 1.** Comparison of models for emotion valence recognition on a public dataset

Модель	Точность, %	F1-мера, %
LSTM	61,19	62,12
TSCaption	73,33	68,07

■ **Таблица 2.** Оценка точности определения валентности эмоций моделью на основе электроэнцефалографии при сравнении с результатами работы модели компьютерного зрения

■ **Table 2.** Evaluation of emotion valence recognition accuracy of the EEG-based model against computer vision model results

Участник	Точность, %
1	91,0
2	89,5
3	63,6
4	88,5
5	85,7
6	90,2
7	87,4
8	92,5
9	70,0

данные указывают на высокую точность модели и ее потенциал для применения в реальных условиях.

Обсуждение

Несмотря на полученные в рамках исследования высокие результаты, был отмечен ряд трудностей, которые необходимо учитывать при проектировании и внедрении подобных систем.

Одной из ключевых проблем оказался высокий уровень шума при использовании носимых устройств. Сухие электроды, характерные для компактных повязок или гарнитур, не обеспечивают столь надежного контакта, как гелевые, что приводит к паразитным артефактам. Движения головы и лица, а также внешние электромагнитные помехи могут вносить заметные искажения в сигнал. Поэтому необходимо тщательно фильтровать данные и нормализовывать значения.

Важную роль играет и межсубъектная вариативность. Параметры и структура ЭЭГ-сигналов могут сильно отличаться от человека к человеку. Это снижает возможность применения одной «универсальной» модели для всех пользователей, для чего требуется либо обучать сеть персонально, либо искать механизмы переноса обучения.

Немаловажным вызовом при разработке является сложность разметки. Для валентности эмоций эталон зачастую субъективен, так как самооценка участника может не совпадать с объективной реальностью или с независимой оценкой, например системой компьютерного зрения.

Отдельное затруднение заключается в потребности в сегментации и синхронизации разных потоков данных. Это включает в себя согласование частоты дискретизации и временных шкал экспериментов.

Еще одним ограничением в обоих сценариях оказалось неравномерное распределение классов. В записанных данных для распознавания эмоций участники зачастую гораздо больше времени находятся в нейтральном состоянии, тогда как выраженные положительные или отрицательные эпизоды могут занимать меньшее количество записей. Для борьбы с дисбалансом применялись разные стратегии вроде взвешивания классов или увеличения количества повторений редких классов.

Заключение

Проведенное исследование продемонстрировало, что методы глубокого обучения, адаптированные к записям малоканальных ЭЭГ-устройств, могут решать проблему определения эмоционального состояния. В части распознавания эмоций удалось достичь значимых результатов даже при использовании всего четырех

каналов и переносе модели, обученной на многоканальном публичном наборе, на собственный набор данных. Точность при этом была подтверждена сравнением с методом компьютерного зрения, что продемонстрировало согласованность в большинстве случаев и подчеркнуло способность электроэнцефалографии фиксировать эмоциональные реакции.

Основная практическая ценность таких методов связана с тем, что носимые ЭЭГ-устройства делают возможным непрерывный мониторинг психофизиологических состояний в обычной среде человека. Подобная система может пригодиться в интерактивных системах обучения, виртуальной реальности, медицине и нейрореабилитации.

Финансовая поддержка

Исследования выполнены в рамках бюджетной темы FFZF-2025-0003.

Литература

1. Plutchik R. The nature of emotions. *American Scientist*, 2001, vol. 89, pp. 344–350. doi:10.1511/2001.28.344
2. Lang P. J. The emotion probe: Studies of motivation and attention. *American Psychologist*, 1995, vol. 50, no. 5, pp. 372–385.
3. Rahman M. A., Hossain M. F., Hossain M., Ahmmed R. Employing PCA and t-statistical approach for feature extraction and classification of emotion from multichannel EEG signal. *Egyptian Informatics Journal*, 2020, vol. 21, iss. 1. doi:10.1016/j.eij.2019.10.002
4. Yang H., Han J., Min K. A multi-column CNN model for emotion recognition from EEG signals. *Sensors (Switzerland)*, 2019, vol. 19, iss. 21. doi:10.3390/s19214736
5. Algarni M., Saeed F., Al-Hadhrani T., Ghabban F., Al-Sarem M. Deep learning-based approach for emotion recognition using Electroencephalography (EEG) signals using Bi-Directional Long Short-Term Memory (Bi-LSTM). *Sensors*, 2022, vol. 22, iss. 8. doi:10.3390/s22082976
6. Du R., Zhu S., Ni H., Mao T., Li J., Wei R. Valence-arousal classification of emotion evoked by Chinese ancient-style music using 1D-CNN-BiLSTM model on EEG signals for college students. *Multimedia Tools and Applications*, 2023, vol. 82, iss. 10. doi:10.1007/s11042-022-14011-7
7. Wu S., Xu X., Shu L., Hu B. Estimation of valence of emotion using two frontal EEG channels. *Proceedings of IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 2017, pp. 1127–1130. doi:10.1109/BIBM.2017.8217815
8. Moontaha S., Schumann F. E. F., Arnrich B. Online learning for wearable EEG-based emotion classification. *Sensors*, 2023, vol. 23, iss. 5. doi:10.3390/s23052387
9. Lin C., Zhang C., Xu J., Liu R., Leng Y., Fu C. Neural correlation of EEG and eye movement in natural grasping intention estimation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, vol. 31, pp. 4329–4337. doi:10.1109/TNSRE.2023.3327907
10. Jia Y., Tyler C. Measurement of saccadic eye movements by electrooculography for simultaneous EEG recording. *Behavior Research Methods*, 2019, vol. 51, iss. 5, pp. 2139–2151. doi:10.3758/s13428-019-01280-8
11. Sun R., Cheng A., Chan C., Hsiao J., Privitera A., Gao J., Fong C., Ding R., Tang A. Tracking gaze position from EEG: Exploring the possibility of an EEG-based virtual eye-tracker. *Brain and Behavior*, 2023, vol. 13, iss. 10. https://doi.org/10.1002/brb3.3205
12. Kang J., Han X., Song J., Niu Z., Li X. The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data. *Computers in Biology and Medicine*, 2020, vol. 120, Article 103722. doi:10.1016/j.compbiomed.2020.103722
13. Armengol-Urpi A., Salazar-Gómez A., Sarma S. Brainwave-augmented eye tracker: High-frequency SSVEPs improves camera-based eye tracking accuracy. *International Conference on Intelligent User Interfaces, Proceedings IUI*, 2022, no. 2, pp. 258–276. https://doi.org/10.1145/3490099.3511151
14. Ma J., Zhang Y., Cichocki A., Matsuno F. A novel EOG/EEG hybrid human-machine interface adopting eye movements and ERPs: Application to robot control. *IEEE Transactions on Biomedical Engineering*,

- 2015, vol. 62, iss. 3, pp. 876–889. doi:10.1109/TBME.2014.2369483
15. Park S., Han C., Im C. Design of wearable EEG devices specialized for passive brain–computer interface applications. *Sensors (Switzerland)*, 2020, vol. 20, iss. 16. <https://doi.org/10.3390/s20164572>
 16. Biasiucci A., Franceschiello B., Murray M. Electroencephalography. *Current Biology*, 2019, vol. 29, iss. 3, pp. R80–R85. doi:10.1016/j.cub.2018.11.052
 17. Klug M., Gramann K. Identifying key factors for improving ICA-based decomposition of EEG data in mobile and stationary experiments. *European Journal of Neuroscience*, 2021, vol. 54, iss. 12, pp. 8406–8420. doi:10.1111/ejn.14992
 18. Seok D., Lee S., Kim M., Cho J., Kim C. Motion artifact removal techniques for wearable EEG and PPG sensor systems. *Frontiers in Electronics*, 2021, vol. 2. <https://doi.org/10.3389/felec.2021.685513>
 19. Arnal P., Thorey V., Debellemanniere E., Ballard M., Bou Hernandez A., Guillot A., Jourde H., Harris M., Guillard M., Van Beers P., Chennaoui M., Sauvet F. The dreem headband compared to polysomnography for electroencephalographic signal acquisition and sleep staging. *Sleep*, 2020, vol. 43, iss. 11, p. zsa097.
 20. Yu Z., Guo S. A low-cost, wireless, 4-channel EEG measurement system used in virtual reality environments. *HardwareX*, 2024, vol. 17. <https://doi.org/10.1016/j.ohx.2024.e00507>
 21. Krigolson O., Williams C., Norton A., Hassall C., Colino F. Choosing MUSE: Validation of a low-cost, portable EEG system for ERP research. *Frontiers in Neuroscience*, 2017, vol. 11. <https://doi.org/10.3389/fnins.2017.00109>
 22. Gong S., Xing K., Cichocki A., Li J. Deep learning in EEG: Advance of the last ten-year critical period. *IEEE Transactions on Cognitive and Developmental Systems*, 2022, vol. 14. doi:10.1109/TCDS.2021.3079712
 23. Zhang G., Davoodnia V., Sepas-Moghaddam A., Zhang Y., Etemad A. Classification of hand movements from EEG using a deep attention-based LSTM network. *IEEE Sensors Journal*, 2019, vol. 20, pp. 3113–3122. doi:10.1109/JSEN.2019.2956998
 24. Iyer A., Das S., Teotia R., Maheshwari S., Sharma R. CNN and LSTM based ensemble learning for human emotion recognition using EEG recordings. *Multimedia Tools and Applications*, 2023, vol. 82, iss. 4, pp. 4883–4896. doi:10.1007/s11042-022-12310-7
 25. Chen J., Wang X., Huang C., Hu X., Shen X., Zhang D. A large finer-grained affective computing EEG dataset. *Scientific Data*, 2023, vol. 10, Article 740. doi:10.1038/s41597-023-02650-w
 26. Ding Y., Robinson N., Zhang S., Zeng Q., Guan C. TSception: Capturing temporal dynamics and spatial asymmetry from EEG for emotion recognition. *IEEE Transactions on Affective Computing*, 2023, vol. 14, no. 3. doi:10.1109/TAFFC.2022.3169001
 27. Ryumina E., Dresvyanskiy D., Karpov A. In search of a robust facial expressions recognition model: A large-scale visual cross-corpus study. *Neurocomputing*, 2022, vol. 514, pp. 435–450. doi:10.1016/j.neucom.2022.10.013

UDC 004.8

doi:10.31799/1684-8853-2025-5-64-71

EDN: KLTIBU

Assessment of psycho-emotional state of a person using AI-based EEG analysisV. R. Romaniuk^a, Junior Researcher, orcid.org/0009-0003-3307-1497A. M. Kashevnik^a, PhD, Tech., Associate Professor, orcid.org/0000-0001-6503-1447, alexey@ias.spb.su^aSt. Petersburg Federal Research Center of the RAS, 39, 14th Line, 199178, Saint-Petersburg, Russian Federation

Introduction: Determining emotional valence based on electroencephalographic (EEG) data is an urgent issue. Nonetheless, traditional multi-electrode EEG systems are unsuitable for everyday use. In addition, signals from portable, low-channel devices exhibit high noise levels and significant variability across users, complicating their analysis and interpretation. **Purpose:** To develop a deep-learning-based approach for EEG data analysis suitable for a reliable assessment of emotional valence using low-channel wearable devices. **Results:** We propose a comprehensive approach combining signal processing with classification via convolutional and recurrent neural networks. Neural network models were trained on a publicly available multi-channel dataset, with the subsequent transfer to our recordings obtained with the use of a wearable four-electrode headband BrainBit. The experimental results demonstrate an emotion valence recognition accuracy (positive, negative, and neutral emotions) of 70–75% during cross-subject validation on public data, reaching 85–91% accuracy as compared to computer vision methods using our own data. **Practical relevance:** The findings confirm the feasibility of applying these models in wearable systems for monitoring human emotional and cognitive states. **Discussion:** There is a recognized need for further model adaptation to reduce inter-subject variability and noise, as well as for the refinement of signal synchronization methods and data labeling approaches.

Keywords — data mining, machine learning, convolutional neural networks, recurrent neural networks, psycho-emotional state monitoring, electroencephalography.

For citation: Romaniuk V. R., Kashevnik A. M. Assessment of psycho-emotional state of a person using AI-based EEG analysis. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 5, pp. 64–71 (In Russian). doi:10.31799/1684-8853-2025-5-64-71, EDN: KLTIBU

Financial support

This work was supported by the Russian State Research FFZF-2025-0003.

References

1. Plutchik R. The nature of emotions. *American Scientist*, 2001, vol. 89, pp. 344–350. doi:10.1511/2001.28.344
2. Lang P. J. The emotion probe: Studies of motivation and attention. *American Psychologist*, 1995, vol. 50, no. 5, pp. 372–385.
3. Rahman M. A., Hossain M. F., Hossain M., Ahmmed R. Employing PCA and t-statistical approach for feature extraction and classification of emotion from multichannel EEG signal. *Egyptian Informatics Journal*, 2020, vol. 21, iss. 1. doi:10.1016/j.eij.2019.10.002
4. Yang H., Han J., Min K. A multi-column CNN model for emotion recognition from EEG signals. *Sensors (Switzerland)*, 2019, vol. 19, iss. 21. doi:10.3390/s19214736
5. Algarni M., Saeed F., Al-Hadhrani T., Ghabban F., Al-Sarem M. Deep learning-based approach for emotion recognition using Electroencephalography (EEG) signals using Bi-Directional Long Short-Term Memory (Bi-LSTM). *Sensors*, 2022, vol. 22, iss. 8. doi:10.3390/s22082976
6. Du R., Zhu S., Ni H., Mao T., Li J., Wei R. Valence-arousal classification of emotion evoked by Chinese ancient-style music using 1D-CNN-BiLSTM model on EEG signals for college students. *Multimedia Tools and Applications*, 2023, vol. 82, iss. 10. doi:10.1007/s11042-022-14011-7
7. Wu S., Xu X., Shu L., Hu B. Estimation of valence of emotion using two frontal EEG channels. *Proceedings of IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 2017, pp. 1127–1130. doi:10.1109/BIBM.2017.8217815
8. Moontaha S., Schumann F. E. F., Arnrich B. Online learning for wearable EEG-based emotion classification. *Sensors*, 2023, vol. 23, iss. 5. doi:10.3390/s23052387
9. Lin C., Zhang C., Xu J., Liu R., Leng Y., Fu C. Neural correlation of EEG and eye movement in natural grasping intention estimation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, vol. 31, pp. 4329–4337. doi:10.1109/TNSRE.2023.3327907
10. Jia Y., Tyler C. Measurement of saccadic eye movements by electrooculography for simultaneous EEG recording. *Behavior Research Methods*, 2019, vol. 51, iss. 5, pp. 2139–2151. doi:10.3758/s13428-019-01280-8
11. Sun R., Cheng A., Chan C., Hsiao J., Privitera A., Gao J., Fong C., Ding R., Tang A. Tracking gaze position from EEG: Exploring the possibility of an EEG-based virtual eye-tracker. *Brain and Behavior*, 2023, vol. 13, iss. 10. https://doi.org/10.1002/brb3.3205
12. Kang J., Han X., Song J., Niu Z., Li X. The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data. *Computers in Biology and Medicine*, 2020, vol. 120, Article 103722. doi:10.1016/j.compbiomed.2020.103722
13. Armengol-Urpi A., Salazar-Gómez A., Sarma S. Brain-wave-augmented eye tracker: High-frequency SSVEPs improves camera-based eye tracking accuracy. *International Conference on Intelligent User Interfaces, Proceedings IUI*, 2022, no. 2, pp. 258–276. https://doi.org/10.1145/3490099.3511151
14. Ma J., Zhang Y., Cichocki A., Matsuno F. A novel EOG/EEG hybrid human-machine interface adopting eye movements and ERPs: Application to robot control. *IEEE Transactions on Biomedical Engineering*, 2015, vol. 62, iss. 3, pp. 876–889. doi:10.1109/TBME.2014.2369483
15. Park S., Han C., Im C. Design of wearable EEG devices specialized for passive brain-computer interface applications. *Sensors (Switzerland)*, 2020, vol. 20, iss. 16. https://doi.org/10.3390/s20164572
16. Biasucci A., Franceschiello B., Murray M. Electroencephalography. *Current Biology*, 2019, vol. 29, iss. 3, pp. R80–R85. doi:10.1016/j.cub.2018.11.052
17. Klug M., Gramann K. Identifying key factors for improving ICA-based decomposition of EEG data in mobile and stationary experiments. *European Journal of Neuroscience*, 2021, vol. 54, iss. 12, pp. 8406–8420. doi:10.1111/ejn.14992
18. Seok D., Lee S., Kim M., Cho J., Kim C. Motion artifact removal techniques for wearable EEG and PPG sensor systems. *Frontiers in Electronics*, 2021, vol. 2. https://doi.org/10.3389/felec.2021.685513
19. Arnal P., Thorey V., Debellemanniere E., Ballard M., Bou Hernandez A., Guillot A., Jourde H., Harris M., Guillard M., Van Beers P., Chennaoui M., Sauvet F. The dream headband compared to polysomnography for electroencephalographic signal acquisition and sleep staging. *Sleep*, 2020, vol. 43, iss. 11, p. zsa097.
20. Yu Z., Guo S. A low-cost, wireless, 4-channel EEG measurement system used in virtual reality environments. *HardwareX*, 2024, vol. 17. https://doi.org/10.1016/j.ohx.2024.e00507
21. Krigolson O., Williams C., Norton A., Hassall C., Colino F. Choosing MUSE: Validation of a low-cost, portable EEG system for ERP research. *Frontiers in Neuroscience*, 2017, vol. 11. https://doi.org/10.3389/fnins.2017.00109
22. Gong S., Xing K., Cichocki A., Li J. Deep learning in EEG: Advance of the last ten-year critical period. *IEEE Transactions on Cognitive and Developmental Systems*, 2022, vol. 14. doi:10.1109/TCDS.2021.3079712
23. Zhang G., Davoodnia V., Sepas-Moghaddam A., Zhang Y., Etemad A. Classification of hand movements from EEG using a deep attention-based LSTM network. *IEEE Sensors Journal*, 2019, vol. 20, pp. 3113–3122. doi:10.1109/JSEN.2019.2956998
24. Iyer A., Das S., Teotia R., Maheshwari S., Sharma R. CNN and LSTM based ensemble learning for human emotion recognition using EEG recordings. *Multimedia Tools and Applications*, 2023, vol. 82, iss. 4, pp. 4883–4896. doi:10.1007/s11042-022-12310-7
25. Chen J., Wang X., Huang C., Hu X., Shen X., Zhang D. A large finer-grained affective computing EEG dataset. *Scientific Data*, 2023, vol. 10, Article 740. doi:10.1038/s41597-023-02650-w
26. Ding Y., Robinson N., Zhang S., Zeng Q., Guan C. TSception: Capturing temporal dynamics and spatial asymmetry from EEG for emotion recognition. *IEEE Transactions on Affective Computing*, 2023, vol. 14, no. 3. doi:10.1109/TAF-FC.2022.3169001
27. Ryumina E., Dresvyanskiy D., Karpov A. In search of a robust facial expressions recognition model: A large-scale visual cross-corpus study. *Neurocomputing*, 2022, vol. 514, pp. 435–450. doi:10.1016/j.neucom.2022.10.013