

Классификация эмоций по ЭЭГ с использованием выбора признаков на основе генетического алгоритма и динамического объединения признаков на основе гамма-функции

Джотирадитья Банерджи

Кафедра энергетики
Университет Джадавпур
Калькутта, Индия
joti.ban.2710@gmail.com

Асфак Али

Кафедра электроники и
телекоммуникационной
инженерии
Университет Джадавпур
Калькутта, Индия
asfakalietce@gmail.com

Ом Кармакар

Кафедра энергетики
Университет Джадавпур
Калькутта, Индия
omkarmakar07@gmail.com

Авигьян Рой

Dept. of Computer Science and
Engineering
Университет Джадавпур
Калькутта, Индия
emailavigyana@gmail.com

Дарья Сидорина

Кафедра автоматизации и
управления процессами
СПбГЭТУ «ЛЭТИ»
Санкт-Петербург, Российская
Федерация
FedotovaDora@yandex.ru

Рам Саркар

Кафедра компьютерных наук и
инженерии (CSE)
Университет Джадавпур
Калькутта, Индия
ramjucse@gmail.com

Аннотация. Распознавание эмоций на основе сигналов электроэнцефалограммы (ЭЭГ) является важной темой исследований в области человеко-компьютерного взаимодействия в приложениях оценки психического здоровья и технологии интерфейса мозг-компьютер (BCI). Тем не менее, поиск наиболее значимых характеристик, позволяющих точно классифицировать эмоции, по-прежнему остается сложной задачей. В связи с этим мы предлагаем новую схему, объединяющую оценку по принципу «минимум избыточности – максимум релевантности» (mRMR) с отбором признаков на основе генетического алгоритма (GA). Этот метод оптимизирует отбор признаков, балансируя между релевантностью и избыточностью, обеспечивая облегченный конвейер, который минимизирует сложность модели, повышая при этом общую производительность. Далее система использует две специализированные модели – одну искусственную нейронную сеть (ANN) и одну двунаправленную долговую кратковременную память (BiLSTM) – для извлечения отчетливых временных и пространственных паттернов из сигналов ЭЭГ. Предложен механизм слияния признаков на основе нечеткой гамма-функции, который динамически объединяет признаки с помощью схемы взвешивания, обеспечивая надежное и сбалансированное представление. На наборах данных SEED и EEG Brainwave эта система превосходит существующие методы, демонстрируя не только точность и устойчивость, но и превосходную вычислительную эффективность – всего 0,11 миллиона параметров. Данный фреймворк позволяет распознаванию эмоций на основе ЭЭГ продвигаться дальше и стать обобщенным решением для приложений реального времени, подчеркивая

важность оптимизации признаков и интеллектуального слияния в системах.

Ключевые слова: сигнал ЭЭГ, распознавание эмоций, гамма-функция, генетический алгоритм, отбор признаков, слияние признаков

I. ВВЕДЕНИЕ

Распознавание эмоций – одна из отраслей взаимодействия человека и компьютера (HCI), направленная на анализ и интерпретацию человеческих эмоций. Традиционные методы, использующие мимику или голосовые сигналы, субъективны и культурно изменчивы. В отличие от них, данные электроэнцефалограммы (ЭЭГ) обеспечивают объективное измерение эмоциональных состояний с высоким разрешением благодаря неинвазивному захвату нейронных сигналов. Однако распознавание эмоций на основе ЭЭГ сталкивается с проблемами межсубъектного обобщения. Различия в когнитивных характеристиках, психическом состоянии и возрасте влияют на сигналы ЭЭГ, что ограничивает производительность модели на неизвестных людях. Решение этой проблемы является ключевым для повышения надежности систем распознавания эмоций на основе ЭЭГ.

В последнее время распознавание эмоций на основе ЭЭГ развивается благодаря методам глубокого обучения и отбора признаков. Юань и другие [1] представили диагональный автоэнкодер с трансформацией на основе контрастного обучения, достигнув точности 75,09 % на

SEED. Юварадж и другие [2] использовали 3D-CNN MobileNet с трансферным обучением и ELM, достигнув точности 90,85 %. Ду и др. [3] предложили LSTM на основе внимания (ATDD-LSTM), улучшив обобщение с точностью 91,08 %. Цю и другие [4] разработали коррелированную сеть внимания (CAN), объединяющую данные ЭЭГ и движения глаз, и достигли точности 94,03 %.

Для набора данных EEG Brainwave Bird и другие [15] использовали различные классификаторы, такие как байесовские сети, SVM и RF, достигнув общей точности более 87 %. Редди и другие [16] использовали GRU-тип RNN для классификации эмоций и достигли точности 96 %. Манохаран и другие [17] использовали модель CNN для классификации эмоций после применения таких методов предварительной обработки, как вейвлет-преобразование, извлечение признаков и выбор признаков, и достигли наилучшей точности 91,72 %. Гупта и др. [8] предложили гибридную модель GRU-1D CNN, достигнув точности 96,48 %.

Традиционные методы испытывают трудности при большом количестве признаков, а модели глубокого обучения часто страдают от высокой сложности. В связи с этим основными вкладами данной работы являются:

- Многоступенчатая система отбора признаков, объединяющая метод минимальной избыточности и максимальной релевантности (mRMR) и генетический алгоритм (GA) для определения оптимальных признаков при сокращении избыточности.
- Две специализированные модели обучения, искусственная нейронная сеть (ANN) и двунаправленная длинная кратковременная память (BiLSTM), используются для извлечения статистических, временных и пространственных паттернов из сигналов ЭЭГ, обеспечивая комплексное представление эмоциональных состояний.
- Внедрен механизм нечеткого слияния признаков на основе гамма-функции, использующий схему взвешивания для динамического баланса и слияния извлеченных признаков, что повышает эффективность классификации.
- Предложенная система оценивается на наборах данных SEED и EEG Brainwave, демонстрируя превосходную точность по сравнению с существующими методами, что делает ее перспективным решением для распознавания эмоций на основе ЭЭГ в режиме реального времени.

II. ПРЕДЛОЖЕННЫЙ МЕТОД

Предлагаемая модель состоит из пяти основных компонентов: (а) метод mRMR для отбора признаков, (б) генетический алгоритм (GA) для дальнейшей оптимизации, (с) извлечение признаков с помощью ANN и BiLSTM, (д) механизм слияния признаков на основе гамма-функции и (е) слой классификации. Подробнее каждый из этих компонентов рассматривается ниже.

А. Минимальная избыточность – максимальная релевантность

Метод mRMR [19] служит начальным этапом отбора признаков по сигналам ЭЭГ. mRMR нацелен на определение подмножества признаков, которое максимизирует релевантность целевой переменной и минимизирует избыточность признаков, уменьшая сложность данных и повышая эффективность модели.

Алгоритм ранжирует признаки на основе взаимной информации (MI), где релевантность – это MI между признаком и целью, а избыточность – MI между признаками. Критерий отбора определяется следующим образом:

$$\max \left(\sum_{f_i \in S} I(f_i, y) - \sum_{f_i, f_j \in S} I(f_i, f_j) \right)$$

где обозначает MI между признаком и целью.

Для каждого сигнала вычисляются показатели mRMR, и из набора данных EEG Brainwave выбираются 350 лучших признаков из 2132 с наибольшей степенью релевантности и наименьшей избыточностью, а из набора данных SEED – 150 лучших признаков из 310, что обеспечивает информативный и эффективный набор признаков для последующей оптимизации с помощью GA.

В. Генетический алгоритм

GA [18] – это метод эволюционной оптимизации, основанный на принципах естественного отбора. В этом исследовании GA уточняет подмножество признаков, выбранное методом mRMR, повышая производительность модели за счет обеспечения оптимального представления признаков. GA создает совокупность возможных решений, представленных в виде двоичных строк, посредством операций отбора, кроссинговера и мутации.

Каждая двоичная строка, или хромосома, кодирует комбинацию признаков, где каждый бит означает включение (1) или исключение (0) признака. Пригодность каждой хромосомы оценивается с помощью объективной функции, привязанной к показателям эффективности модели (в данном случае – точности классификации). С помощью отбора для воспроизводства выбираются наиболее приспособленные особи, а кроссинговер и мутация вносят изменчивость, позволяя эффективно исследовать высокоразмерные пространства признаков. Эволюционный процесс продолжается в течение заданного числа поколений или до достижения сходимости, о которой свидетельствуют минимальные изменения в показателях пригодности. Такой систематический подход обеспечивает сохранение наиболее информативных и нередуцируемых признаков, повышая предсказательную силу и обобщаемость предложенной модели.

С. Извлечение признаков с помощью ANN и BiLSTM

Предварительно обработанные сигналы ЭЭГ, нормализованные с помощью масштабирования Min-Max для однородности, используются для извлечения признаков с помощью моделей ANN и BiLSTM, которые обеспечивают дополнительные преимущества при анализе сложных сигналов ЭЭГ, повышая надежность извлеченных признаков.

Процесс извлечения признаков с помощью ANN формулируется следующим образом:

$$f_{ANN} = \phi_{ANN}(S_{EEG}),$$

где S_{EEG} представляет входные сигналы ЭЭГ, ϕ_{ANN} обозначает средство извлечения признаков ANN, а f_{ANN} соответствует выученным нелинейным признакам высокого порядка. ANN состоит из плотно связанных слоев с активацией ReLU, что позволяет модели улавливать абстрактные представления признаков. Полученные с помощью ИНС признаки впоследствии используются в задачах классификации для улучшения распознавания когнитивных состояний.

Чтобы уловить временные зависимости, последовательности ЭЭГ обрабатываются с помощью сети BiLSTM, которая моделирует прямые и обратные зависимости в данных. Извлеченные BiLSTM-функции представлены в виде:

$$f_{BiLSTM} = \phi_{BiLSTM}(S_{EEG}),$$

где ϕ_{BiLSTM} обозначает средство извлечения признаков BiLSTM, а f_{BiLSTM} представляет выученные временные представления. Сеть BiLSTM состоит из одного слоя, который имеет скрытую размерность 64 единицы, что позволяет извлекать более богатые нейрофизиологические паттерны.

Интегрируя ANN и BiLSTM, предлагаемый подход улучшает классификацию ЭЭГ, используя пространственные и временные представления признаков.

Д. Слияние признаков на основе гамма-функций

В задачах слияния разнородные признаки, извлеченные из различных источников или слоев сети, объединяются с помощью механизма, основанного на гамма-функции. Каждый признак получает ненормированный вес w_i , определяемый

$$w_i = \frac{F_i^{\gamma-1} e^{-F_i}}{\Gamma(\gamma)},$$

где $\gamma > 0$ – обучаемый параметр формы, а $\Gamma(\gamma)$ обозначает гамма функцию. Эта формулировка отражает функцию плотности вероятности гамма-распределения, известную своей унимодальной формой и гибкостью при моделировании неотрицательных данных с правым сдвигом.

Веса нормируются для обеспечения вероятностно согласованного слияния $\hat{w}_i = \frac{w_i}{\sum_{j=1}^n w_j}$, так что объединенный признак становится

$$F_{\text{fused}} = \sum_{i=1}^n \hat{w}_i F_i.$$

Эта нормализация позволяет получить устойчивую выпуклую комбинацию, уменьшающую влияние особенностей-выбросов.

Чтобы понять механизм взвешивания, рассмотрим логарифм от w_i :

$$\log w_i = (\gamma - 1) \log F_i - F_i - \log \Gamma(\gamma).$$

Дифференцирование по отношению к F_i дает:

$$\frac{d}{dF_i} \log w_i = \frac{\gamma - 1}{F_i} - 1.$$

Приравнивание этой производной к нулю показывает, что максимальный вес имеет место при $F_i = \gamma - 1$. Таким образом, параметр γ управляет тем, на каких значениях признаков делается акцент, усиливая те, которые близки к $\gamma - 1$, и подавляя признаки, которые значительно отклоняются.

Экспоненциальный член e^{-F_i} дополнительно снижает влияние признаков с чрезмерно высокими значениями, повышая устойчивость к изменениям масштаба при неоднородных исходных данных. Непрерывная дифференцируемость w_i по отношению к γ и F_i позволяет градиентам плавно перетекать в процессе обратного распространения, что обеспечивает сквозную оптимизацию в рамках глубокого обучения.

Когда признаки F_i соответствуют гамма-распределению Gamma ($\gamma, 1$), веса соответствуют масштабированным правдоподобиям. Хотя этот метод не является строгим оценщиком максимального правдоподобия, он опирается на принципы правдоподобия, отдавая предпочтение признакам вблизи моды при $\gamma - 1$. В целом, данный подход использует статистические свойства гамма функции для достижения адаптивного, дифференцируемого и устойчивого к выбросам слияния признаков, что особенно полезно для интеграции многомасштабных или зашумленных входов в глубокие нейронные сети.

Е. Классификация

Объединенные признаки F_c передаются через классификационную голову, состоящую из скрытого слоя с 64 нейронами, активации ReLU и последующего слоя из 32 нейронов. Выходной слой предоставляет окончательные результаты классификации с количеством нейронов, равным количеству классов эмоций. Предложенная модель объединяет механизмы слияния признаков на основе mRMR, GA и Fuzzy Gamma для эффективного извлечения признаков и повышения общей эффективности методики.




Рис. 1. Архитектура модели выделения признаков на основе mRMR-GA и слияния признаков на основе гамма-функции, используемой для распознавания эмоций в ЭЭГ

III. ЭКСПЕРИМЕНТАЛЬНАЯ СХЕМА И ПОЛУЧЕННЫЕ РЕЗУЛЬТАТЫ

A. Наборы данных

В исследовании использовались два набора данных ЭЭГ: SEED [9] и EEG Brainwave [10].

SEED, созданный лабораторией BCMI в Шанхайском университете Цзяо Тун, записывает ЭЭГ-ответы 15 участников в течение трех сессий с использованием 62-электродной установки. Пятнадцать видеоклипов вызывают три эмоции: положительную, нейтральную и отрицательную, обозначенные как 1, 0 и -1 соответственно. Сигналы фильтруются по полосе пропускания (0–75 Гц) и понижаются по частоте (200 Гц).

ЭЭГ мозговых волн: Собранный с помощью головной повязки Muse EEG (TP9, AF7, AF8, TP10), этот набор данных включает 2 132 образца записей ЭЭГ, соответствующих положительным, нейтральным и отрицательным эмоциям. Стимулы из таких фильмов, как «Ла-Ла Ленд» и «Марли и я», вызывают эмоциональные состояния. Образцы разделены на три класса: 0 (негативные), 1 (нейтральные) и 2 (позитивные).

Обучение и настройка гиперпараметров: Модель обучается с использованием ключевых гиперпараметров: размер партии (32), размер скрытой части (8), скорость обучения (0,01) и оптимизатор Адама с планировщиком ReduceLROnPlateau. Обучение включает в себя прямой и обратный проходы, вычисление потерь и валидацию после каждой эпохи. Лучшая модель, основанная на потерях при валидации, сохраняется для окончательной оценки. Для оценки эффективности используются такие показатели, как точность, прецизионность, отзыв и F1-мера.

ТАБЛИЦА I. СРАВНЕНИЕ ПРОИЗВОДИТЕЛЬНОСТИ НА НАБОРАХ ДАННЫХ SEED И EEG BRAINWAVE

SEED		EEG Brainwave	
Работа	Точность (%)	Работа	Точность (%)
Ювардж и др. [2]	81,60	Берд и др. [15]	87,00
Яо и др. [11]	96,67	Редди и др. [16]	96,00
Лю и др. [12]	94,58	Манохаран и др. [17]	91,72
Сидхарт и др. [13]	93,10	Бардак и др. [5]	95,97
Ляо и др. [1]	95,09	Цин и др. [6]	75,00
Асгар и др. [14]	95,09	Чжун и др. [7]	94,24
Предлагаемая модель	100,0	Предлагаемая модель	96,79

ТАБЛИЦА II. ИССЛЕДОВАНИЕ АБЛЯЦИИ НА НАБОРЕ ДАННЫХ ЭЭГ МОЗГОВЫХ ВОЛН

Конфигурация	Acc	Prec	Rec	F1	* КП
mRMR+GA+GAMMA (ПРЕДЛАГАЕТСЯ)	96.79	96.79	96.79	96.79	119
mRMR+GA+ANN	93.68	93.79	93.67	93.70	119
mRMR+GA+BiLSTM	95.72	95.73	95.72	95.72	119
mRMR+ANN	90.63	90.70	90.62	90.64	350
mRMR+BiLSTM	87.82	88.04	87.81	87.69	350
mRMR+GAMMA	87.59	88.98	87.56	87.02	350
GA+GAMMA	93.91	93.89	93.90	93.86	270
GA+ANN	95.08	95.16	95.07	95.05	270
GA+BiLSTM	95.08	95.15	95.08	95.05	270

*КП – количество признаков.

B. Результаты и обсуждение

Предложенная модель представляет собой облегченную структуру для распознавания эмоций на основе ЭЭГ, сочетающую оценку признаков по методу mRMR с выбором признаков на основе GA для повышения точности классификации при минимизации сложности. В ней используется двухмодельный подход: ANN для извлечения признаков и BiLSTM для последовательного обучения, наряду с механизмом слияния признаков на основе гамма-функции для адаптивного взвешивания признаков.

Как показано в табл. I, модель достигает 100,00% точности на наборе данных SEED и 95,99 % точности на наборе данных EEG Brainwave, превосходя большинство существующих методов. Высокая точность и масштабируемость делают его перспективным решением для приложений реального времени в области психического здоровья, аффективных вычислений и технологии BCI. На рис. 2a показан график tSNE для набора данных SEED, демонстрирующий четкое разделение между различными классами сигналов. Для набора данных EEG Brainwave (рис. 2b) модель достигает четких границ классов с минимальной внутриклассовой вариацией, хотя небольшое перекрытие между положительными и нейтральными классами приводит к незначительным ошибкам в классификации в случае набора данных EEG Brainwave.




Рис. 2. Графики t-SNE предложенной модели на двух наборах данных (a) SEED и (b) EEG Brainwave

C. Исследование абляции

Предложенная конфигурация mRMR+GA+Gamma достигает наивысшей производительности на наборе данных EEG Brainwave: точность, прецизионность, отзыв и F1-мера составляют 96,79 % (табл. II). Другие конфигурации, такие как mRMR+GA+ANN и mRMR+GA+BiLSTM, показывают более низкие результаты. Без GA производительность падает еще больше, например, mRMR+ANN и mRMR+BiLSTM. Конфигурации без mRMR, такие как GA+Gamma, GA+ANN и GA+BiLSTM, показывают умеренные результаты.

IV. ЗАКЛЮЧЕНИЕ

В данном исследовании представлена новая методология, объединяющая выбор признаков, извлечение признаков и классификацию для повышения точности и вычислительной эффективности распознавания эмоций на основе ЭЭГ. Предложенный метод использует оптимизированный набор признаков вместе со структурированной моделью классификации

для обеспечения более высокой точности и надежности классификации. Экспериментальные результаты подтверждают эффективность метода, демонстрируя его потенциал для улучшения задач классификации, управляемых данными. Архитектуры глубокого обучения и ансамблевые методы открывают потенциальные возможности для повышения эффективности классификации на еще более сложных наборах данных, что может стать возможным направлением дальнейшей работы.

СПИСОК ЛИТЕРАТУРЫ

- [1] Liao, Yuan, Yuhong Zhang, Shenghuan Wang, Xiruo Zhang, Yiling Zhang, Wei Chen, Yuzhe Gu, and Liya Huang. "CLDTA: Contrastive Learning based on Diagonal Transformer Autoencoder for Cross-Dataset EEG Emotion Recognition." arXiv preprint arXiv:2406.08081 (2024).
- [2] Yuvaraj, Rajamanickam, Arapan Baranwal, A. Amalin Prince, M. Murugappan, and Javeed Shaikh Mohammed. "Emotion recognition from spatio-temporal representation of EEG signals via 3D-CNN with ensemble learning techniques." *Brain Sciences* 13, no. 4 (2023): 685.
- [3] Du, Xiaobing, Cuixia Ma, Guanhua Zhang, Jinyao Li, Yu-Kun Lai, Guozhen Zhao, Xiaoming Deng, Yong-Jin Liu, and Hongan Wang. "An efficient LSTM network for emotion recognition from multi-channel EEG signals." *IEEE Transactions on Affective Computing* 13, no. 3 (2020): 1528-1540.
- [4] Qiu, Jie-Lin, Xiao-Yu Li, and Kai Hu. "Correlated attention networks for multimodal emotion recognition." In 2018 IEEE international conference on bioinformatics and biomedicine (BIBM), pp. 2656-2660. IEEE, 2018.
- [5] Bardak, F. Kebire, M. Nuri Seyman, and Feyzullah Temurtas. "Adaptive neuro-fuzzy based hybrid classification model for emotion recognition from EEG signals." *Neural Computing and Applications* 36, no. 16 (2024): 9189-9202.
- [6] Qing, Chunmei, Rui Qiao, Xiangmin Xu, and Yongqiang Cheng. "Interpretable emotion recognition using EEG signals." *Ieee Access* 7 (2019): 94160-94170.
- [7] Zhong, Peixiang, Di Wang, and Chunyan Miao. "EEG-based emotion recognition using regularized graph neural networks." *IEEE Transactions on Affective Computing* 13, no. 3 (2020): 1290-1301.
- [8] Gupta, Shubh, Aman Srivastava, Syed Naved, S. K. Somasundaram, and V. Ilayaraja. "EEG signals analysis with 1D CNN-GRU architecture via transfer learning." In 2024 8th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC), pp. 465-472. IEEE.
- [9] Cimtay, Yucel, and Erhan Ekmekcioglu. "Investigating the use of pretrained convolutional neural network on cross-subject and cross-dataset EEG emotion recognition." *Sensors* 20, no. 7 (2020): 2034.
- [10] Bird, Jordan J., Aniko Ekart, Christopher D. Buckingham, and Diego R. Faria. "Mental emotional sentiment classification with an eeg-based brain-machine interface." In *Proceedings of the International Conference on Digital Image and Signal Processing (DISP'19)*. 2019.
- [11] Yao, Xiuzhen, Tianwen Li, Peng Ding, Fan Wang, Lei Zhao, Anmin Gong, Wenya Nan, and Yunfa Fu. "Emotion classification based on transformer and CNN for EEG spatial-temporal feature learning." *Brain sciences* 14, no. 3 (2024): 268.
- [12] Lan, Yu-Ting, Wei Liu, and Bao-Liang Lu. "Multimodal emotion recognition using deep generalized canonical correlation analysis with an attention mechanism." In *2020 International Joint Conference on Neural Networks (IJCNN)*, pp. 1-6. IEEE, 2020.
- [13] Sidharth, Sidharth, Ashish Abraham Samuel, H. Ranjana, and Jerrin Thomas Panachakel. "Emotion detection from EEG using transfer learning." In *2023 45th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, pp. 1-4. IEEE.
- [14] Asghar, Muhammad Adeel, Muhammad Jamil Khan, Yasar Amin, and Adeel Akram. "EEG-based emotion recognition with combined deep neural networks using decomposed feature clustering model." In *2019 13th International Conference on Open Source Systems and Technologies (ICOSST)*, pp. 1-6. IEEE, 2019.
- [15] Bird, Jordan J., Luis J. Manso, Eduardo P. Ribeiro, Aniko Ekart, and Diego R. Faria. "A study on mental state classification using eeg-based brain-machine interface." In *2018 international conference on intelligent systems (IS)*, pp. 795-800. IEEE, 2018.
- [16] Reddy, G. Ravi Kumar, A. Durga Bhavani, and Venkata Krishna Odugu. "Optimized recurrent neural network based brain emotion recognition technique." *Multimedia Tools and Applications* (2024): 1-20.
- [17] Manoharan, Goutham, and Diego Resende Faria. "Enhanced Mental State Classification Using EEG-Based Brain-Computer Interface Through Deep Learning." In *Intelligent Systems Conference*, pp. 570-586. 2024.
- [18] Holland, John H. "Adaptation in Natural and Artificial Systems". University of Michigan Press.
- [19] Radovic Milos Ghalwash, Mohamed Filipovic, Nenad Obradovic Zoran. "Minimum redundancy maximum relevance feature selection approach for temporal gene expression data." *BMC Bioinformatics* (2017).