
НЕЙРОШУМ КАК ДИАГНОСТИЧЕСКИЙ ИНСТРУМЕНТ: МАШИННОЕ ОБУЧЕНИЕ ДЛЯ ВЫЯВЛЕНИЯ ПАТОЛОГИЙ ПО ФОНОВОЙ АКТИВНОСТИ

Буракова Мария Сергеевна,

ассистент кафедры ИУК5 «Системы обработки информации» m.burakova@bmstu.ru

Фадеев Вячеслав Олегович,

ассистент кафедры ИУК5 «Системы обработки информации» fadeev.v@bmstu.ru

Ильичев Владимир Юрьевич,

к.т.н. доцент кафедры ИУК5 «Системы обработки информации» ilychev.vyu@bmstu.ru
МГТУ им. Н.Э. Баумана, адрес: 105005, г. Москва, ул. 2-я Бауманская, дом 5, стр. 1

Аннотация

В статье исследуется потенциал анализа фоновой активности мозга (нейрошума) для диагностики неврологических и психиатрических патологий методами машинного обучения (МО). Исследование выполнено на трех независимых датасетах ЭЭГ покоя (N=847), включающих записи здоровых субъектов и пациентов с эпилепсией, болезнью Альцгеймера (БА), шизофренией и депрессией. Разработана конвейерная архитектура обработки данных, включающая спектральный, энтропийный, фрактальный анализ и оценку функциональной связности. Ансамблевая модель (Stacking Ensemble) достигла точности 89,3% (AUC-ROC 96,7%). Наибольшую диагностическую ценность продемонстрировали показатели энтропии (32,4% важности), фрактальные характеристики и спектральные параметры альфа- и тета-диапазонов. Результаты подтверждают перспективность анализа нейрошума как неинвазивного инструмента скрининга и мониторинга.

Ключевые слова: нейрошум, ЭЭГ, машинное обучение, энтропия, фрактальный анализ, эпилепсия, болезнь Альцгеймера, шизофрения, депрессия.

NEURAL NOISE AS A DIAGNOSTIC TOOL: MACHINE LEARNING FOR THE DETECTION OF PATHOLOGIES BASED ON BACKGROUND ACTIVITY

Maria S. Burakova,

Assistant, Department of Information Processing Systems, m.burakova@bmstu.ru

Vyacheslav O. Fadeev,

Assistant, Department of Information Processing Systems, fadeev.v@bmstu.ru

Vladimir Yu. Ilichev,

Candidate of Technical Sciences, Associate Professor, Department of Information Processing Systems, ilychev.vyu@bmstu.ru
Bauman Moscow State Technical University, 2nd Baumanskaya St., 5/1, Moscow, 105005, Russia

ABSTRACT

This paper investigates the potential of analyzing background brain activity (neural noise) for the diagnosis of neurological and psychiatric pathologies using machine learning (ML) methods. The study was conducted on three independent resting-state EEG datasets (N=847), comprising recordings from healthy subjects and patients with epilepsy, Alzheimer's disease (AD), schizophrenia, and depression. A data processing pipeline architecture was developed, incorporating spectral, entropy, and fractal analyses, as well as functional connectivity assessment. The ensemble model (Stacking Ensemble) achieved an accuracy of 89.3% (AUC-ROC 96.7%). Entropy measures (32.4% importance), fractal characteristics, and spectral parameters of the alpha and theta bands demonstrated the greatest diagnostic value. The results confirm the promise of neural noise analysis as a non-invasive tool for screening and monitoring.

Keywords: neural noise, EEG, machine learning, entropy, fractal analysis, epilepsy, Alzheimer's disease, schizophrenia, depression.

Введение

Проблема ранней диагностики неврологических и психиатрических заболеваний остается критически актуальной, поскольку традиционные методы часто выявляют патологию на поздних стадиях. Электроэнцефалография (ЭЭГ) в состоянии покоя представляет собой неинвазивный и информативный метод, протоколы записи которого стандартизированы международными рекомендациями [1], однако классический анализ фокусируется на явных патологических паттернах, игнорируя фоновую активность.

Современные исследования показывают, что стохастическая компонента мозговой активности («нейрошум») играет фундаментальную роль в функционировании нейронных сетей и изменяется при патологических состояниях [2]. Методы машинного и глубокого обучения [3] позволяют выявлять тонкие паттерны в многомерных данных ЭЭГ, неразличимые при визуальной оценке. Несмотря на прогресс в диагностике отдельных заболеваний, сравнительная ценность различных характеристик нейрошума остается недостаточно изученной.

Цель: разработать и валидировать методы МО для диагностики неврологических и психиатрических патологий на основе анализа фоновой активности ЭЭГ покоя.

Материалы и методы исследования

Исследование выполнено на трех публичных датасетах ЭЭГ:

TUH EEG Corpus (Temple University Hospital) — крупнейший клинический датасет [4]. Использована подвыборка ЭЭГ покоя (423 участника: 156 здоровых, 134 с эпилепсией, 78 с БА, 55 с шизофренией; система 10-20, 250 Гц).

DEAP Dataset — мультимодальный датасет для анализа эмоций [5]. Используются baseline-записи (32 участника, 32 канала, 512 Гц, 60 с).

Schizophrenia EEG Dataset — специализированный датасет (148 участников: 74 пациента с шизофренией, 74 контроля; 19 каналов, 500 Гц, 5 мин) [3].

Общая выборка после объединения и очистки составила 847 записей (262 здоровых, 134 эпилепсия, 133 БА, 129 шизофрения, 124 депрессия; 423 мужчины, 424 женщины; возраст 18–82 года).

Конвейер включал полосовую фильтрацию (0,5–45 Гц), режекторный фильтр (50 Гц), удаление артефактов методом ICA (FastICA) и порогового метода (± 100 мкВ), интерполяцию плохих каналов, сегментацию на эпохи (4 с, перекрытие 50%), z-score нормализацию. Отбраковано 3,2% эпох низкого качества.

Извлечено 342 признака в четырех категориях [1, 6, 7]:

Спектральные (44,4%): абсолютная и относительная мощность в дельта-, тета-, альфа-, бета-, гамма-диапазонах, спектральная энтропия, наклон спектра.

Энтропийные (22,2%): Sample Entropy (SampEn) [6], Approximate Entropy, Permutation Entropy, Multiscale Entropy (MSE).

Фрактальные (16,7%): показатель Хёрста, фрактальная размерность (метод Хигучи) [7], DFA.

Связность (16,7%): когерентность, PLV, корреляция огибающих, глобальная эффективность сети.

После фильтрации (удаление признаков с низкой дисперсией и высокой корреляцией) и отбора (ANOVA, RFE) осталось 267 признаков.

Реализованы традиционные методы (логистическая регрессия, SVM, Random Forest, XGBoost) и глубокое обучение (MLP, CNN, LSTM, гибридная CNN-LSTM). Разработана ансамблевая модель Stacking Ensemble (базовые: RF, SVM, XGBoost, CNN; мета-модель: логистическая регрессия). Валидация: k-fold ($k=10$), стратифицированное разделение (70/15/15). Метрики: Accuracy, Precision, Recall, F1, AUC-ROC, MCC.

Результаты исследования

ANOVA выявил значимые различия ($p < 0,001$) между группами для 187 признаков (70% отобранных). Распределение ключевых признаков по диагностическим группам представлено на рисунке 1.




Рисунок 1 - Распределение ключевых признаков нейрошузма по диагностическим группам [разработано авторами]

Анализ рисунка 1 показал следующие закономерности:

Sample Entropy (рис. 1A): максимальна при эпилепсии ($M=0,89$) и шизофрении ($M=0,85$), что отражает гипервозбудимость и нарушение синхронизации нейронных сетей [8, 9].

Hurst Exponent (рис. 1B): минимален при БА ($M=0,51$), указывая на потерю долгосрочной корреляции и переход к более случайному сигналу [10].

Alpha Peak Frequency (рис. 1C): замедлена при БА (8,7 Гц) и шизофрении (9,1 Гц) против 10,2 Гц у здоровых — маркер когнитивных нарушений.

Theta/Alpha Ratio (рис. 1D): повышено при всех патологиях, особенно при эпилепсии ($M=0,78$), отражая сдвиг спектральной мощности в сторону низких частот.

Frontal Alpha Asymmetry (рис. 1E): наиболее выражена при депрессии ($M=-0,18$), что указывает на сниженную активность левого полушария.

Все пять признаков демонстрируют высокую дискриминативную способность (one-way ANOVA, $p<0,001$) и могут служить биомаркерами для дифференциальной диагностики.

Stacking Ensemble достигла accuracy 89,3% на независимой тестовой выборке ($N=127$); матрица ошибок представлена на рисунке 2.




Рисунок 2 - Матрица ошибок классификации для Stacking Ensemble модели (А - абсолютные значения, В — нормализованные проценты) [разработано авторами]

Из 127 образцов правильно классифицировано 113:

Здоровые: Recall 92,3%, Specificity 96,2% (лишь 7,7% ложноположительных результатов).

Эпилепсия: Recall 85,0%, Precision 89,5%.

БА: Recall 81,0%, Precision 89,5%.

Шизофрения: Recall 73,7%.

Депрессия: Recall 77,8%.

Основные ошибки классификации приходятся на перекрестную дифференциацию шизофрении и депрессии (5 случаев), что отражает общность нейрофизиологических механизмов этих расстройств.

Пермутационная важность выявила иерархию категорий признаков (рисунок 3).




Рисунок 3. Относительная важность категорий признаков (А) и топ-15 конкретных признаков (В) для классификации [разработано авторами]

Анализ рисунка 3 показал следующее распределение важности:

Энтропийные меры — 32,4% (SampEn, Permutation Entropy, MSE).

Спектральные характеристики — 28,7% (Alpha Peak, Theta/ Alpha Ratio).

Фрактальные параметры — 21,3% (Hurst Exponent, FD) [7].

Функциональная связность — 17,6% (когерентность, PLV) [9].

Топ-5 признаков: SampEn (F3) — 8,7%, Hurst (Cz) — 8,2%, Alpha Peak (O1) — 7,8%, Theta/ Alpha (Pz) — 7,4%, Global Theta Coherence — 7,1%. Топ-10 признаков обеспечивают 68,6% общей важности, что позволяет сократить размерность модели без существенной потери точности.

Эпилепсия: частота приступов коррелирует с SampEn ($r=0,42$); нарушения функциональной связности коррелируют с тяжестью [9].

БА: MMSE положительно коррелирует с Alpha Peak ($r=0,51$); CDR отрицательно — с MSE ($r=-0,47$) [10, 11].

Шизофрения: PANSS коррелирует с Permutation Entropy ($r=0,39$) [8, 12]; снижение MSE отражает когнитивный дефицит.

Депрессия: HAM-D коррелирует с фронтальной альфа-асимметрией ($r=0,48$).

Полученные результаты подтверждают гипотезу о диагностической ценности нейрошума. Доминирующая роль энтропийных мер (32,4%) согласуется с теорией о нарушении баланса между порядком и хаосом в нейронных сетях при патологиях [2]. Повышенная энтропия при эпилепсии и шизофрении отражает избыточную стохастичность [8, 9], а снижение MSE при БА — потерю адаптивности нейронных сетей [10, 11].

Изменения фрактальных характеристик (снижение Hurst Exponent) указывают на переход от персистентной динамики к случайному блужданию, что отражает дезорганизацию нейронных сетей [7]. Замедление альфа-ритма и повышение theta/alpha ratio при БА и шизофрении подтверждают известные данные о нарушении таламо-кортикальных взаимодействий.

Превосходство Stacking Ensemble над индивидуальными моделями (+4,2%) обусловлено диверсификацией ошибок и комплементарностью алгоритмов: традиционные методы работают с табличными признаками, CNN извлекает пространственные паттерны, LSTM улавливает временные зависимости.

Клинические импликации: система может использоваться для скрининга (высокая специфичность 96,2%), поддержки врачебных решений и мониторинга прогрессирования

заболеваний. Корреляция характеристик нейрошума с тяжестью симптомов открывает возможности для прогнозирования течения и оценки эффективности терапии.

Ограничения: отсутствие лонгитюдных данных, гетерогенность датасетов, влияние фармакотерапии не контролировалось полностью, ограниченное представление пожилых пациентов (>80 лет).

Заключение

Разработана и валидирована система диагностики неврологических и психиатрических патологий на основе анализа нейрошума. Ансамблевая модель достигла точности 89,3% (AUC-ROC 96,7%) для различения здоровых субъектов и пациентов с эпилепсией, БА, шизофренией и депрессией.

Ключевые биомаркеры:

Эпилепсия: повышенная энтропия и фрактальная размерность.

БА: замедление альфа-активности, снижение MSE на крупных масштабах.

Шизофрения: нарушения связности, повышенная пермутационная энтропия.

Депрессия: фронтальная альфа-асимметрия.

Результаты поддерживают теорию о нарушении критичности нейронных сетей при патологиях. Разработанные алгоритмы перспективны для внедрения в клиническую практику в качестве скрининговых инструментов и систем поддержки принятия решений. Дальнейшие исследования должны быть направлены на лонгитюдную валидацию, интеграцию с другими модальностями нейровизуализации и разработку real-time систем.

Список литературы:

1. Babiloni C., et al. International Federation of Clinical Neurophysiology (IFCN) – EEG: Guidelines for resting state // Clinical Neurophysiology. – 2020. – Vol. 131, No. 2. – P. 474–484.
2. McDonnell M.D., Ward L.M. The many faces of noise in neural systems // Nature Reviews Neuroscience. – 2011. – Vol. 12. – P. 415–416.
3. de Miras J.R., et al. Schizophrenia classification using machine learning on resting state EEG // Biomedical Signal Processing and Control. – 2023. – Vol. 79. – Art. 104023.
4. Obeid I., Picone J. The Temple University Hospital EEG Data Corpus // Frontiers in Neuroscience. – 2016. – Vol. 10. – Art. 448. – DOI: 10.3389/fnins.2016.00448.
5. Koelstra S., Muhl C., Soleymani M., et al. DEAP: A Database for Emotion Analysis Using Physiological Signals // IEEE Transactions on Affective Computing. – 2012. – Vol. 3, No. 1. – P. 18–31. – DOI: 10.1109/T-AFFC.2011.15.
6. Richman J.S., Moorman J.R. Physiological time-series analysis using approximate entropy and sample entropy // American Journal of Physiology-Heart and Circulatory Physiology. – 2000. – Vol. 278, No. 6. – P. H2039–H2049.
7. Higuchi T. Approach to an irregular time series on the basis of the fractal theory // Physica D: Nonlinear Phenomena. – 1988. – Vol. 31, No. 2. – P. 277–283.
8. Xiang J., et al. Abnormal Entropy Modulation of the EEG Signal in Patients With Schizophrenia // Frontiers in Neuroscience. – 2019. – Vol. 13. – Art. 472.
9. Elkholy M.M., et al. Disruption of EEG resting state functional connectivity in patients with epilepsy // The Journal of Headache and Pain. – 2023. – Vol. 24. – Art. 102.
10. Abasolo D., Hornero R., Escudero J., Gomez C. Entropy analysis of the EEG background activity in Alzheimer's disease patients // Physiological Measurement. – 2006. – Vol. 27, No. 11. – P. 1165–1179.

11. Simons S., Tibubos R., et al. Fuzzy Entropy Analysis of the Electroencephalogram in Patients with Alzheimer's Disease // Entropy. — 2018. — Vol. 20, No. 1. — Art. 21.
12. Takahashi T., Cho R.Y., Murata T., et al. Antipsychotics reverse abnormal EEG complexity in drug-naïve schizophrenia: a multiscale entropy analysis // NeuroImage. — 2010. — Vol. 51, No. 1. — P. 173–182.

References:

1. Babiloni C., et al. International Federation of Clinical Neurophysiology (IFCN) – EEG: Guidelines for resting state // Clinical Neurophysiology. — 2020. — Vol. 131, No. 2. - P. 474–484.
2. McDonnell M.D., Ward L.M. The many faces of noise in neural systems // Nature Reviews Neuroscience. - 2011. - Vol. 12. - P. 415–416.
3. de Miras J.R., et al. Schizophrenia classification using machine learning on resting state EEG // Biomedical Signal Processing and Control. — 2023. — Vol. 79. - Art. 104023.
4. Obeid I., Picone J. The Temple University Hospital EEG Data Corpus // Frontiers in Neuroscience. — 2016. — Vol. 10. - Art. 448. - DOI: 10.3389/fnins.2016.00448.
5. Koelstra S., Muhl C., Soleymani M., et al. DEAP: A Database for Emotion Analysis Using Physiological Signals // IEEE Transactions on Affective Computing. - 2012. - Vol. 3, No. 1. - P. 18–31. — DOI: 10.1109/T-AFFC.2011.15.
6. Richman J.S., Moorman J.R. Physiological time-series analysis using approximate entropy and sample entropy // American Journal of Physiology-Heart and Circulatory Physiology. - 2000. - Vol. 278, No. 6. - P. H2039–H2049.
7. Higuchi T. Approach to an irregular time series on the basis of the fractal theory // Physica D: Nonlinear Phenomena. - 1988. - Vol. 31, No. 2. - P. 277–283.
8. Xiang J., et al. Abnormal Entropy Modulation of the EEG Signal in Patients With Schizophrenia // Frontiers in Neuroscience. — 2019. — Vol. 13. — Art. 472.
9. Elkholy M.M., et al. Disruption of EEG resting state functional connectivity in patients with epilepsy // The Journal of Headache and Pain. — 2023. — Vol. 24. - Art. 102.
10. Abasolo D., Hornero R., Escudero J., Gomez C. Entropy analysis of the EEG background activity in Alzheimer's disease patients // Physiological Measurement. - 2006. - Vol. 27, No. 11. - P. 1165–1179.
11. Simons S., Tibubos R., et al. Fuzzy Entropy Analysis of the Electroencephalogram in Patients with Alzheimer's Disease // Entropy. — 2018. — Vol. 20, No. 1. - Art. 21.
12. Takahashi T., Cho R.Y., Murata T., et al. Antipsychotics reverse abnormal EEG complexity in drug-induced schizophrenia: a multiscale entropy analysis // NeuroImage. - 2010. - Vol. 51, No. 1. — P. 173–182.