

ИСПОЛЬЗОВАНИЕ МОДЕЛЕЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ ВЫЯВЛЕНИИ КОГНИТИВНЫХ ПРОЦЕССОВ ЯЗЫКОВОЙ ОБРАБОТКИ В РАМКАХ ТЕОРИИ ГЛОССЕМАТИКИ

Аннотация. Данная работа посвящена анализу электрической активности головного мозга человека, лежащей в основе обработки языковой информации. С помощью методов машинного обучения, а также генетического метода выявляются области мозга, задействованные при обработке изменений французских слов. Путем сопоставления полученных схем активности определяются закономерности в процессах обработки словесных изменений.

Ключевые слова: электроэнцефалограмма, план выражения, план содержания, внутренняя речь, генетический метод, машинное обучение.

Введение. Актуальность данной темы обусловлена тем, что на текущий момент одним из перспективных направлений научных исследований является проведение междисциплинарных исследований. Использование математических методов для изучения лингвистических процессов на уровне электрических сигналов головного мозга позволяет достичь новых, ранее недоступных результатов, которые могут найти применение как в математике и компьютерных науках, так и в области лингвистики и нейрофизиологии. Большой интерес также представляет анализ процессов внутреннего проговаривания через призму теории глоссематики, а именно — различия плана выражения и плана содержания слов. Процесс восприятия и порождения речи довольно сложен и состоит из множества компонентов, подразумевающих анализ языкового материала на различных лингвистических уровнях. Однако в данной работе мы сфокусировали внимание именно на слове, ввиду того, что это, как пишет А. М. Пешковский, «основная структурно-семантическая единица языка, служащая для именования предметов и их свойств, явлений, отношений действительности, обладающая совокупностью семантических, фонетических и грамматических признаков, специфичных для каждого языка» [1; 464]. Именно за счет того, что слово содержит в себе разнообразные признаки, а также является единством грамматической формы (плана выражения) и значения (плана содержания), изучение манипулирования человеком данной языковой единицей позволит выявить различные аспекты работы мозга при осуществлении им определенных языковых действий.

По словам Л. Ельмслева, слово можно представить как совокупность его структурных компонентов, т. е. «когда каждый знак рассматривается как состоящий из таких элементов, сравнительно небольшое число которых оказывается достаточным для описания», и при этом данный подход применим как для плана выражения, так и для плана содержания [2; 193]. Подобные механизмы обработки в рамках копенгагенского структурализма позволяют рассматривать слова в их совокупности, в группах, выделенных по определенному структурному признаку, что дает возможность определить деятельность мозга при выполнении тех же самых повторяющихся структурных преобразований. В рамках данной работы на примере слов французского языка (ввиду того, что в этом языке можно наблюдать черты аналитизма и синтетизма) мы выделяем орфографические преобразования (план выражения), семантические преобразования (план содержания) и морфологические преобразования (как параметр, влияющий и на план выражения, и на план содержания).

На текущий момент исследователи придерживаются мысли о том, что весь мозг человека задействован в речевой деятельности ввиду того, что он представляет собой «ассоциативное запоминающее устройство» — так его описывают Р. Ф. Шмидт, Ф. Ланг и М. Хекман, к тому же они подчеркивают, что «сенсорная и моторная области занимают гораздо меньшую площадь, чем ассоциативная кора» [3; 200]. Безусловно, зоны Вернике и Брока, находящиеся в левом полушарии, играют большую роль в порождении и восприятии речевой информации соответственно — об этом говорят Р. Ф. Шмидт, Ф. Ланг и М. Хекман, подчеркивая, что «первично в языковой области существует доминантность левого полушария для синтаксических функциональных слов и фраз» [3; 281], однако левое полушарие ответственно именно за логическую сторону речи (а также, по словам Р. Ф. Шмидта, Ф. Ланга и М. Хекмана, оно сконцентрировано «на каузальных интерференциях, на причинно-следственных отношениях и устранении логических противоречий» и задействовано «в последовательной переработке информации» [3; 282]), в то время как к функциям правого полушария относятся «понимание речи; узнавание слова <...>; создание мелодии предложения и ударения (просодия); классификация речевых актов...» [3; 286]. Ввиду этого в нашем исследовании мы анализируем все области мозга, что позволит получить более полную картину обработки головным мозгом человека речевой информации.

Для нейролингвистических исследований, и в особенности для решения задачи классификации, Ю. Ю. Гавриленко, Д. Ф. Саада, А. О. Шевченко и Е. А. Ильюшин выделяют «метод опорных векторов, метод k-ближайших соседей, скрытую марковскую модель, нейронные сети, экстремальное машинное обучение» [4; 168]. Следует также выделить метод создания деревьев решений, который также популярен среди алгоритмов машинного обучения.

Метод ближайших соседей (или метод k-ближайших соседей) довольно прост и часто используется при решении задачи классификации. Однако для данного подхода необходимо подобрать нужный способ определения расстояния между объектами, что довольно сложно сделать для таких признаков, не имеющих явной корреляции, как значения электроэнцефалограммы (ЭЭГ) — к этому выводу мы пришли при проведении исследования, в ходе которого «классификация операторов и ЭЭГ данных на основе метода ближайших соседей показала средний результат», но тем не менее «данный метод может быть более эффективен в совокупности с другими способами обработки и анализа больших данных» [5; 123], а значит, при должном подходе метод ближайших соседей может показать хороший результат и для предсказания классов на основе значений электрической активности мозга.

Деревья решений также просты в интерпретации — они представляют собой «узлы», находящиеся в определенных бинарных отношениях. В основе формирования «узлов» могут лежать различные алгоритмы, но благодаря структуре самой модели полученный результат можно логически объяснить. Тем не менее у этого подхода есть и обратная сторона — возможные решения четко предопределены на «узлах», что не дает данной модели «гибкости» в принятии решений. Данная гибкость присуща другой модели — многослойному перцептрону. Его эффективность при предсказании значений на основе данных электроэнцефалограммы как в совокупности с другими моделями, так и самостоятельно, подтверждают многие исследования, например, он хорошо себя показал при предсказании эмоций в работе Н. Саланкар, П. Мишры и Л. Гарг, где «Метод опорных векторов (SVM) и Многослойный перцептрон с двумя скрытыми слоями используются для бинарной и многоклассовой классификации эмоций...» [6].

Но, в отличие от деревьев решений, результаты многослойного перцептрона плохо интерпретируемы.

Метод опорных векторов основан на разделении векторами гиперплоскости, которые отделяют объекты одних классов от других. Данный метод относится к группе линейных классификаторов, что означает его направленность на линейно разделяемые данные. И несмотря на то, что данные электроэнцефалограммы не имеют линейной зависимости, как уже было отмечено ранее, метод опорных векторов применяется при решении задач, связанных с анализом электроэнцефалограмм, поэтому мы также рассматриваем его в данном исследовании. Скрытая марковская модель получила широкое распространение в компьютерной лингвистике при решении задач распознавания речи и машинного перевода. И поскольку скрытая марковская модель применима для расшифровки последовательностей, это может быть использовано при работе с данными электроэнцефалограмм, в особенности при их обработке в определенном временном диапазоне.

Проблема исследования. Таким образом, наша гипотеза заключается в том, что методы машинного обучения позволят выявить закономерности в выполнении языковых задач головным мозгом человека в рамках плана выражения и плана содержания анализируемых слов.

Цель нашего исследования — выявить механизмы и закономерности возникновения электрической активности головного мозга человека и их локализацию при анализе плана выражения и плана содержания слов французского языка, определенные их грамматическими и семантическими изменениями, с использованием моделей искусственного интеллекта и генетического метода отбора признаков.

Для достижения цели были поставлены следующие задачи:

1. Изучить и обработать электроэнцефалограммы, являющиеся основой материала исследования.
2. Получить значения эффективности предсказания моделями машинного обучения протекающих в данный момент языковых процессов в мозге человека на основе данных электроэнцефалограммы.
3. Отобрать с помощью генетического метода отбора признаков наиболее весомые, с точки зрения модели, признаки, содержащие информацию о локализации и характере определенного электрического сигнала мозга.
4. Сравнить полученные паттерны активности мозга при осуществлении определенных языковых преобразований.

Материалы и методы. При проведении данного исследования мы опираемся на материал, полученный и опубликованный К. Э. Кофлин, Р. Фиорентино, Ф. Ройл и К. Штайнхауэром [7]. В их работе анализировались «четыре условия: идентификация, морфологическая связанность, орфографическая связанность и семантическая связанность, а также их несвязанность» [7], используемые для выявления разницы в проведении языковых операций у носителей и не носителей французского языка на уровне их мозговой активности. Для этого участникам эксперимента предоставлялись слова-стимулы, связанные или не связанные между собой в рамках каждого из условий по определенному методу, называемому "masked priming" [7], где слова-стимулы показываются спустя определенный промежуток времени и отделены

друг от друга ничего не значащей «маской» (например, «#####»). Примеры используемых слов французского языка для четырех условий представлены в табл. 1 [8].

Таблица 1

Примеры слов-стимулов

<i>Условие</i>	<i>Связанное слово</i>	<i>Несвязанное слово</i>	<i>Целевое слово</i>
Идентификация	tire	fuyons	TIRE
Идентификация	mêle	parons	MÊLE
Идентификация	doute	causons	DOUTE
Орфография	aidons	battons	AIME
Орфография	fixons	gelons	FIGE
Орфография	ferrons	glaçons	FERME
Морфология	ajoutons	épousons	AJOUTE
Морфология	pleurons	assurons	PLEURE
Морфология	signons	testons	SIGNE
Семантика	aimons	vexons	ADORE
Семантика	crions	bayons	HURLE
Семантика	narrons	prêtons	RACONTE

При этом в базе данных, содержащих результаты записи электроэнцефалограмм [9], представлены пиковые значения определенных сигналов (N250 и N400, связываемые с реакциями на речевые стимулы (N в данном случае указывает на отрицательность отклонения электроэнцефалограммы, а число — время в миллисекундах после начала стимула), при этом авторы исследования отмечают, что, «в отличие от N250, во многих исследованиях с методом прайминга было показано, что N400 модулируется целым рядом лексических свойств, включая морфологическое родство» [7], однако N250 также имеет значение — по словам Р.Ф. Шмидта, Ф. Ланга и М. Хекмана, «медленные отрицательные изменения потенциалов (длящиеся больше 200 мс) и постоянные потенциалы отражают деполяризацию и мобилизацию расположенного под электродом участка коры», в то время как положительные изменения «связаны с ослаблением возбуждения нейронов» [3; 213]) для каждого из 20 электродов.

Для проведения исследования необходимо следовать определенному алгоритму. На первом этапе необходимо представить полученный датасет (набор данных) в том виде, в котором его будет удобно использовать при проведении нашего исследования. Затем, для получения большего числа записей, будет произведен синтез данных на основе имеющихся, после чего два набора данных (оригинальные и оригинальные+синтезированные) будут разделены на обучающий и тестовый датасеты для обучения и проверки предсказания пяти моделей (метод опорных векторов, метод k-ближайших соседей, скрытая марковская модель, многослойный перцептрон, деревья решений). Получив результаты эффективности моделей и проанализировав их кросс-таблицы, мы сможем отобрать наиболее действенную модель и использовать ее в качестве показателя точности предсказания для генетического метода отбора признаков. На основе результатов данного метода будут построены схемы расположения отобранных

электродов, которые в последствии будут проанализированы и сопоставлены. Все задачи, касающиеся применения программирования, были решены с помощью языка программирования Python.

Из изначального датасета нам необходимо выделить только те данные, которые будут рассматриваться нами в ходе исследования. К ним относятся: значения электродов каждого участника эксперимента для сигналов N250 и N400, условие, к которому относятся данные сигналы, и то, связаны или не связаны слова-стимулы, анализируемые в данный момент. Для этого мы переработали первоначальную базу данных и создали свою, которую впоследствии мы разделили на четыре базы данных, для каждого из условий, перемешали записи в псевдослучайном порядке и разделили их на два датасета — для обучения и для проверки. При этом значения электродов в пиках N250 и N400 будут служить признаками для предсказания классов, к которому данные записи с электродов относятся — к классу реакции на связанные друг с другом по данному условию (идентификация, морфология, орфография или семантика) слова-стимулы, или к классу реакции на не связанные друг с другом по данному условию слова-стимулы. В итоге мы получили 424 записи — по 106 записей на каждое условие, где количество записей для класса «не связаны» и «связаны» поровну — по 53.

Для того чтобы избежать переобучения моделей, мы прибегли к синтезу данных для увеличения количества записей. Для настоящего исследования мы увеличили количество записей для каждого класса со 106 до 318, чтобы оригинальные данные составляли треть от итогового числа записей. При этом точность синтеза данных (то, насколько синтезированные данные похожи на исходные) была довольно высока — в среднем 89,3%.

Для каждой из моделей мы выбирали параметры, которые могли бы уравнивать их возможности на одних и тех же данных. За отправную точку мы выбрали метод ближайших соседей, где при количестве соседей, равном пяти, результат предсказания был наиболее высоким. Среднее значение точности по всем условиям для каждой модели представлено в табл. 2, значение округлено до тысячной.

Таблица 2

Средняя точность предсказания моделей

Метод ближайших соседей	0,778
Деревья решений	0,814
Многослойный перцептрон	0,816
Метод опорных векторов	0,811
Скрытая марковская модель	0,465

Получив результаты точности и распределения объектов тестовой выборки по классам для каждого условия, мы можем сравнить анализируемые модели. Все модели лучше всего справляются с одними и теми же условиями — связанными по морфологии и не связанными по семантике словами-стимулами. Однако худшие показатели точности различны (хотя среди них и преобладает ложноотрицательность при отнесении объектов к классам того или иного условия), а потому нельзя сказать, что модели имеют равную эффективность при решении

каждой из задач распознавания. Тем не менее, наивысший средний результат точности предсказания при обучении на исходных и синтезированных данных, который присущ многослойному перцептрону (0,82), нас устраивает, а потому мы приняли решение о выборе данной модели для следующего этапа — отбора признаков с помощью генетического метода, о чем пойдет речь далее.

Генетический метод отбора признаков необходим, с одной стороны, для повышения точности предсказания модели за счет отсеивания неважных признаков, а с другой — для получения наиболее весомых, с точки зрения модели, признаков, что, в рамках нашей задачи, позволяет выделить те сигналы и те области головного мозга человека, которые наиболее важны, повторимся, с точки зрения модели, для решения той или иной лингвистической задачи, и которые вовлечены в эту деятельность.

В общих чертах, генетический метод заключается в «кодировании комбинаций признаков нулями и единицами, подобно генам, и скрещиванию „особей“ с тем или иным „геномом“, оставляя только наиболее приспособленных — тех, чья комбинация признаков дает наибольший результат точности при предсказании» [5; 121], где 0 — это отсутствие данного признака при обучении и предсказании, а 1 — присутствие.

Для нашего исследования также «было сгенерировано псевдослучайным способом 20 «особей» и оставлено 90% с наилучшим показателем приспособленности» [5; 121], после чего пары «особей» скрещивались, и для полученных дочерних «особей» применялся аспект мутации — псевдослучайной замены значения (0 или 1) одного из признаков на противоположный. Алгоритм был зациклен до выхода на «плато» — когда разность точности десяти поколений подряд не превышала 0,05. При этом лучшей комбинацией—«геномом особи» считается та, что давала наилучшую точность за все итерации, а не финальная комбинация.

С помощью многослойного перцептрона, дающего, как мы выяснили, лучший результат предсказания среди всех остальных рассмотренных нами моделей машинного обучения, и генетического метода отбора признаков, мы смогли обозначить те пиковые значения сигналов головного мозга человека и те его области, которые, по мнению модели, были наиболее вовлечены в процессы осуществления таких языковых операций как идентификация слов-стимулов французского языка, определение морфологических различий французских глаголов, установление орфографической схожести слов-стимулов и выявление семантической взаимосвязи между данными словами. Благодаря генетическому методу удалось повысить точность предсказания до 90% и отобрать значимые признаки, характеризующие анализ обоих планов слов.

Результаты. Отобранные признаки позволили нам выделить регионы мозга, которые проявлялись чаще всего: лобная доля, зона Вернике, зона Брока, зрительная область и правое полушарие. Области, активация которых прослеживается при выполнении каждого из лингвистических преобразований, представлены в табл. 3.

В результате, с точки зрения модели, общей для всех языковых операций оказалась значимость лобной доли и зрительной области. Зона Вернике проявлялась при анализе орфографии и семантики, а зона Брока — при анализе морфологии и семантики. Правое полушарие было больше задействовано при обработке семантики и орфографии. Задача идентификации объединяет все критерии сравнения выявленных паттернов.

Также мы обращаем внимание, что разделение областей, задействованных в том или ином лингвистическом процессе, может иметь погрешность ввиду ограниченного количества

использованных в исследовании электродов и особенностей регистрации электрической активности головного мозга человека путем записи электроэнцефалограммы.

Таблица 3

**Сопоставление областей и сигналов головного мозга человека
при обработке различной языковой информации**

	Идент.	Морф.	Орф.	Сем.
Лобная доля — N250	+	-	-	+
Лобная доля — N400	+	+	+	-
Зона Вернике — N250	-	-	+	-
Зона Вернике — N400	-	-	-	+
Зона Брока — N250	+	+	-	-
Зона Брока — N400	-	+	-	+
Зрительная область — N250	+	-	+	+
Зрительная область — N400	-	+	+	+
Правое полушарие — N250	+	-	+	-
Правое полушарие — N400	-	-	+	+

Заключение. Следовательно, принципы обработки плана выражения и плана содержания слов французского языка имеют различную структуру и различные закономерности, которые больше характеризуют слово не как совокупность внешней оболочки и внутреннего содержания, а как совокупность определенных языковых изменений.

Полученные в ходе проведенной работы результаты могут быть использованы, за счет междисциплинарности исследования, в различных прикладных областях. Данные о структуре языковых процессов могут быть учтены при составлении упражнений для развития лингвистических навыков у людей, изучающих французский язык как иностранный, а также при создании алгоритмов генерации речи и распознавания ее семантики для голосовых помощников и систем машинного перевода. С точки зрения непосредственно компьютерной нейролингвистики, полученные результаты могут найти применение при разработке программного обеспечения для нейроинтерфейсов систем «мозг-компьютер», и стать основой для дальнейшей разработки систем декодирования внутренней речи человека на основе данных электрической активности его головного мозга.

СПИСОК ЛИТЕРАТУРЫ

1. Пешковский А.М. Слово // Лингвистический энциклопедический словарь / под ред. В.Н. Ярцевой. Москва: Советская энциклопедия, 1990. — ISBN 5-85270-031-2.
2. Ельмслев Л. Прологомены к теории языка / Л. Ельмслев — Москва: КомКнига, 2006. — 248 с. — ISBN 5-484-00346-6.
3. Шмидт Р.Ф. Физиология человека с основами патофизиологии: в 2 т. Т. 1. / под ред. Р.Ф. Шмидта, Ф. Ланга, М. Хекманна. — Москва: Лаборатория знаний, 2021. — 540 с.
4. Гавриленко Ю.Ю. Обзор методов распознавания внутренней проговаривания на основе данных электроэнцефалограммы / Ю.Ю. Гавриленко, Д.Ф. Саада, А.О. Шевченко, Е.А. Ильющин // Современные информационные технологии и ИТ-образование. — 2019. — № 1. — С. 164-171.

5. Шлычкова Е.О. Предсказание операторов внутренней речи на основе данных ЭЭГ с помощью метода ближайших соседей / Е.О. Шлычкова, А.Н. Шевляков // Математическое и информационное моделирование: материалы Всероссийской конференции молодых ученых. — 2023. — С. 116-124.
6. Salankar N. Emotion recognition from EEG signals using empirical mode decomposition and second-order difference plot / N. Salankar, P. Mishra, L. Garg // Biomedical Signal Processing and Control. — 2021. — № 65. — URL: <https://www.sciencedirect.com/science/article/abs/pii/S174680942030495X> (дата обращения: 07.03.2023).
7. Coughlin C.E. Sensitivity to Inflectional Morphology in a Non-native Language: Evidence From ERPs / C.E. Coughlin, R. Fiorentino, Ph. Royle, K. Steinhauer // Frontiers in Communication. — 2019. — № 4. — URL: <https://www.frontiersin.org/articles/10.3389/fcomm.2019.00021/full> (дата обращения: 20.05.2023).
8. "Real Word Stimuli". — URL: https://frontiersin.figshare.com/articles/dataset/Data_Sheet_6_Sensitivity_to_Inflectional_Morphology_in_a_Non-native_Language_Evidence_From_ERPs_PDF/8159810/1 (дата обращения: 01.04.2023).
9. "Datashet 4: EEG mean voltage". — URL: https://frontiersin.figshare.com/articles/dataset/Data_Sheet_4_Sensitivity_to_Inflectional_Morphology_in_a_Non-native_Language_Evidence_From_ERPs_xlsx/8153153/1 (дата обращения: 01.04.2023).