

МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное учреждение
высшего образования
«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ Н.Г.ЧЕРНЫШЕВСКОГО»

Кафедра информатики и программирования

**ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНА-
ЛИЗА СЛОЖНОЙ ДИНАМИКИ**

АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ

студента 4 курса 441 группы
направления 02.03.03 Математическое обеспечение и администрирование
информационных систем
факультета компьютерных наук и информационных технологий
Кучишкина Александра Сергеевича

Научный руководитель:

д.ф.-м.н., доцент

Купцов П.В

Заведующий кафедрой:

к.ф.-м.н., доцент

Огнева М. В.

Саратов 2025

ВВЕДЕНИЕ

Актуальность темы. Нелинейная динамика — это область знаний, находящаяся на стыке нескольких дисциплин и занимающаяся исследованием характеристик нелинейных динамических систем. Под динамической системой подразумевается система любой природы — физическая, химическая, биологическая, социальная, экономическая и т. д. — состояние которой меняется во времени. Это изменение может происходить как непрерывно, так и дискретно. В процессе исследования систем нелинейная динамика применяет нелинейные модели, которые обычно представлены дифференциальными уравнениями и дискретными отображениями. Один из самых известных примеров нелинейной системы — это система Лоренца, которая демонстрирует поведение, известное как детерминированный хаос. Система Лоренца — это динамическая система, которую Лоренц исследовал в 1963 году. Её задача состояла в том, чтобы разработать упрощённую модель движения воздуха в атмосфере и выяснить, можно ли предсказывать погоду на длительный срок. Вплоть до появления работ Лоренца, основной причиной неточности прогнозов погоды считалось отсутствие высокопроизводительных вычислительных машин. В системах с детерминированными закономерностями, как полагали, можно точно определить состояние системы (например, составить достоверный прогноз погоды), даже если начальные условия известны лишь приблизительно, что неизбежно в реальных условиях. Однако Лоренц выявил то, что теперь известно как сильная зависимость от начальных условий — ключевую особенность хаотической динамики. Иногда говорят, что всё в мире взаимосвязано. Это понятие связано с тем, что невозможно точно предсказать поведение сложных систем в долгосрочной перспективе, включая прогноз погоды.

Исследование динамики нелинейных систем обычно затруднительно при помощи аналитических методов и чаще всего применяются методы численного эксперимента. В значительной степени это сводится к обработке

и анализу данных, генерируемых в ходе эволюции нелинейных систем. По этой причине для обогащения научного инструментария нелинейной динамики и для расширения круга решаемых задач представляется естественным обращаться к опыту бурно развивающихся в настоящее время дисциплин из области машинного обучения и науки о данных. С практической точки зрения развитие методов машинного обучения в приложении к нелинейной динамике можно рассматривать как своего рода альтернативный метод численного моделирования, предназначенный для использования с современным параллельным аппаратным и программным обеспечением. В частности, он подходит для так называемых AI-акселераторов - аппаратных средств, предназначенных для работы с искусственными нейронными сетями.

Цель бакалаврской работы – разработка методов численного анализа сложной динамики нелинейных систем на основе моделей машинного обучения.

Поставленная цель определила **следующие задачи**:

1. Изучение методов кластеризации в пространстве данных.
2. Изучение методов построения и обучения нейронных сетей.
3. Изучение основных понятий из области нелинейной динамики, такие как колебания, фаза и синхронизация.
4. Вычисление отношения частот двух сигналов с использованием кластерного анализа точек на плоскости фаз.
5. Применение нейронных сетей для идентификации синхронизации периодических осцилляторов на рекуррентных диаграммах и фазовых портретах.
6. Применение методов машинного обучения для выявления частотного состава сигналов.

Методологические основы. Методологической основой работы послужили положения теории нелинейной динамики, теории синхронизации,

анализа временных рядов, а также методы машинного обучения, включая глубокие нейронные сети.

Ключевыми теоретическими положениями при анализе взаимодействующих колебательных систем стали труды Анищенко В. С., Астахова В. В., Вадивасовой Т. Е. и Стрелковой Г. И., в которых обобщены закономерности синхронизации регулярных, хаотических и стохастических колебаний в нелинейных системах различной природы. В работе использованы их подходы к классификации режимов динамики, а также к выделению признаков, характерных для синхронизированных и несинхронизированных состояний.

Особое внимание в исследовании уделено прикладному подходу к изучению синхронизации, изложенному в работе Кузнецова А. П., Емельяновой Ю. П., Сатаева И. Р. и Тюрюкиной Л. В., где рассматривается большое число задач на определение и распознавание синхронизированных режимов. Эти примеры легли в основу выбора модельных уравнений и постановки экспериментов в настоящем исследовании.

Для оценки сложности поведения сигналов применялись методы визуализации и количественной интерпретации структуры временных рядов, в частности — метод рекуррентных диаграмм и связанных с ними характеристик (рекуррентная плотность, диагональные и вертикальные структуры и т.д.). Основу здесь составили методы, представленные в обобщающем обзоре N. Marwan, M. C. Romano, M. Thiel и J. Kurths, где формализована теория анализа сложных систем на основе рекуррентных структур и их статистической обработки.

Алгоритмическая и вычислительная основа исследования базируется на методах глубокого обучения. В частности, применялись модели на основе LSTM и BiLSTM, эффективность которых в обработке временных последовательностей подтверждена в фундаментальных трудах С. Хайкина, где изложены математические принципы построения нейросетей, а также основные алгоритмы обучения и регуляризации.

Практическая реализация нейросетевых моделей, в том числе с использованием TensorFlow 2.0, опиралась на принципы, изложенные в работе S. PATTANAYAK, где представлены подходы к построению архитектур нейросетей, методы обучения на временных данных и приёмы борьбы с переобучением. Дополнительные методические рекомендации и обзор современных тенденций глубокого обучения были почерпнуты из труда С. Николенко, А. Кадурина и Е. Архангельской, где детально рассмотрены вопросы архитектурного дизайна нейросетей, работы с последовательностями и выбор метрик для оценки качества классификации.

Таким образом, совокупность методов, заимствованных из теории нелинейной динамики, прикладной синхронизации, анализа временных рядов и современных технологий глубокого обучения, сформировала методологическую базу настоящего исследования.

Теоретическая и/или практическая значимость бакалаврской работы. Теоретическая значимость работы состоит в расширении научного инструментария нелинейной динамики за счёт внедрения современных методов машинного обучения. Разработанные подходы позволяют перейти от традиционных методов численного моделирования к алгоритмам, лучше использующим возможности параллельных вычислительных систем. Практическая значимость проявляется в демонстрации эффективности предложенных методов на конкретных задачах анализа сигналов сложной динамики. В частности, модели машинного обучения показали высокую точность в выявлении отношения частот, идентификации синхронизации осцилляторов и оценке спектрального состава сигналов. Полученные результаты подтверждают перспективность использования современных методов искусственного интеллекта в изучении динамических систем и дают основания для их дальнейшего практического применения в задачах обработки сложных сигналов.

Структура и объём работы. Работа состоит из введения, двух разделов основной части (теоретической и практической), заключения,

списка использованных источников и 13 приложений (А–П). Общий объём работы составляет 102 страниц, из них 70 страниц – основное содержание, включающее 40 рисунков и 1 таблицу. Список используемой литературы содержит 24 наименований.

КРАТКОЕ СОДЕРЖАНИЕ РАБОТЫ

Первый раздел «Теоретический обзор» посвящен теоретическим основам анализа сложной динамики и возможности применения современных методов машинного обучения к задаче классификации режимов поведения нелинейных систем. Особое внимание уделено модели осциллятора Ван-дер Поля, как одному из классических примеров нелинейной колебательной системы, демонстрирующей широкий спектр режимов — от регулярных до хаотических.

Рассматриваются основные принципы кластерного анализа как метода автоматической группировки данных на основе заданных метрик расстояния. Приводятся типы метрик: евклидово, манхэттенское, расстояние Чебышева и др. Показано, как формируются выборки, нормализуются признаки, и строится матрица расстояний между объектами. Обосновывается применение кластеризации для сегментации фазового пространства сигналов нелинейных систем.

Далее изложены принципы нисходящего и восходящего подходов. Описаны методы объединения кластеров: одиночная, полная связь и попарное среднее. Подробно рассмотрены способы выбора числа кластеров: анализ дендрограммы, индекс силуэта и статистика разрывов. Указаны преимущества и недостатки метода, включая высокую вычислительную сложность.

Также описан алгоритм К-средних, включая выбор начальных центров, итеративное обновление центров и проверку сходимости. Указаны преимущества метода — простота и эффективность на больших данных, и его недостатки — чувствительность к выбору K и инициализации, а также склонность к выявлению кластеров только выпуклой формы

Рассматриваются принципы плотностной кластеризации: определение ε -окрестности и minPts. Метод позволяет находить кластеры произвольной формы и устойчив к шуму, однако чувствителен к выбору параметров и плохо работает при сильно различной плотности кластеров

В том числе рассматривается алгоритм спектральной кластеризации: построение матрицы смежности, вычисление собственных векторов, проецирование в пространство меньшей размерности и применение метода К-средних. Метод эффективен для кластеров сложной формы, но ресурсоёмок из-за вычислений спектра матрицы смежности.

Далее даются определения гармонических и автоколебательных систем. Рассматриваются параметры, характеризующие колебания: амплитуда, частота, фаза. Приведены примеры периодических и квазипериодических колебаний в нелинейных системах.

Описывается метод оценки частотного состава сигнала с помощью спектрального анализа. Поясняется использование преобразования Фурье и представление плотности энергии во временной и частотной областях. Отмечается его значимость для диагностики режимов работы динамической системы.

Излагаются численные методы решения ОДУ второго порядка, применимые к системам типа осциллятора Ван-дер Поля. Приводятся алгоритмы метода Эйлера и метода Рунге–Кутты. Поясняется важность точного решения ОДУ для генерации данных о поведении системы.

Далее рассматривается метод рекуррентных диаграмм и анализ соответствующих количественных характеристик (RQA): детерминированности, плотности, энтропии и др. Метод применяется для выявления периодических и хаотических участков сигнала и построения обучающих выборок для нейросетей.

Приводится базовая архитектура полносвязных сетей. Описаны функции активации, обратное распространение ошибки, функции потерь и методы оптимизации. Отмечаются слабые стороны DNN при работе с последовательностями: отсутствие памяти и чувствительность к размерности входных данных.

Рассматриваются сверточные сети с одномерными ядрами (Conv1D), применяемые к временным рядам. Описана архитектура сверточных блоков,

pooling-слоев, fully connected-слоёв. Отмечается, что CNN хорошо работают с локальными признаками, но могут терять глобальную структуру сигнала.

Подробно рассматриваются RNN и их расширения: LSTM и BiLSTM. Приведены формулы работы элементов LSTM (входной, забывающий, выходной вентили и ячейка памяти). Эти сети обеспечивают высокую точность в задачах классификации сигналов за счёт запоминания долгосрочных зависимостей и устойчивости к шуму.

Второй раздел «Практическая часть» посвящен реализации задач работы. В разделе 2.1 описана разработка программы на языке C++ для вычисления отношения частот двух сигналов методом кластерного анализа точек фазовых соотношений. Для этой цели был реализован алгоритм кластеризации и создан класс FrequencyRatio, в котором реализованы функции разбора исходных данных, численного дифференцирования сигналов, вычисления их фаз и группировки точек на фазовой плоскости. На основе рассчитанных кластеров определяется соотношение фаз сигналов (отношение $m:n$) и, следовательно, отношение частот.

Раздел 2.2 посвящён задаче идентификации синхронизации двух связанных осцилляторов. В нём описана генерация синтетического набора данных с помощью численного решения системы уравнений Ван-дер-Поля, моделирующей пару связанных осцилляторов. Был реализован код на Python, который при варьировании параметров связи и частот осцилляторов формирует фазовые портреты и рекуррентные диаграммы системы. Полученный размеченный датасет (10000 рекуррентных диаграмм и 10000 фазовых портретов размером 1000×1000 и 496×369 пикселей соответственно) использовался для обучения сверточной нейронной сети. Сеть обучалась классифицировать режимы системы на наличие или отсутствие синхронизации по входному изображению – этот этап (генерация данных и обучение модели) выполнен успешно.

В разделе 2.3 рассматривается задача регрессии спектральных характеристик сигнала. Для обучения нейросети был сгенерирован

синтетический датасет сигналов с известным частотным составом. Была создана программа для генерации сигналов, содержащих как целевые гармоники, так и шумовые компоненты, и сформированы метки в виде вектора амплитуд этих гармоник. На основе этого датасета были построены три нейросетевые модели (сверточная, LSTM и двунаправленная LSTM), ориентированные на анализ временных рядов, – все архитектуры реализованы и обучены в рамках работы. Результаты предсказания моделей по тестовым данным сравнены с классическим спектральным анализом методом Уэлча. Изучение экспериментальных данных показало высокую точность моделей LSTM-архитектуры в восстановлении амплитудных характеристик сигнала и эффективность предложенного подхода.

ЗАКЛЮЧЕНИЕ

В ходе выполнения работы были решены все сформулированные задачи и достигнута поставленная цель. Модели машинного обучения, созданные на основе как классических так и нейросетевых подходов, продемонстрировали свою эффективность в задачах выявления отношения частот сигналов, идентификации синхронных режимов и анализа спектрального состава сигналов. Полученные результаты подтверждают перспективность использования современных подходов искусственного интеллекта в изучении динамических систем и открывают возможности для дальнейших исследований в данной области.

Основные источники информации:

1. Анищенко В.С., Астахов В.В., Вадивасова Т.Е., Стрелкова Г.И. Синхронизация регулярных, хаотических и стохастических колебаний. — 2008.
2. Кузнецов А.П., Емельянова Ю.П., Сатаев И.Р., Тюрюкина Л.В. Синхронизация в задачах. — 2010.
3. Marwan N., Romano M.C., Thiel M., Kurths J. Recurrence plots for the analysis of complex systems / N. Marwan, M.C. Romano, M. Thiel, J. Kurths // Physics Reports. — 2007. — № 438 (5-6). — С. 237-329.
4. Хайкин С. Нейронные сети. Полный курс // М.: ООО «И.Д. Ви-льямс». — 2016. — 1104 с.
5. Pattanayak S. Pro Deep Learning with TensorFlow 2.0: A Mathematical Approach to Advanced Artificial Intelligence in Python / S. Pat-tanayak. — Second Edition. — 2023.
6. Николенко С., Кадури А., Архангельская Е. Глубокое обучение / С. Николенко, А. Кадури, Е. Архангельская. — СПб. — 2018.