

Минобрнауки России
Федеральное государственное бюджетное учреждение науки
Институт динамики систем и теории управления имени В.М. Матросова
Сибирского отделения Российской академии наук
(ИДСТУ СО РАН)

На правах рукописи

Салимов Борис Гудратович

**Методы анализа зависимостей состояния ионосферы
от геофизических данных**

09.06.01 — Информатика и вычислительная техника

05.13.18 — Математическое моделирование, численные методы и
комплексы программ

НАУЧНЫЙ ДОКЛАД

об основных результатах научно-квалификационной работы (диссертации)
на соискание ученой степени
кандидата технических наук

Иркутск — 2021

Работа выполнена в лаборатории 4.1 Комплексных информационных систем
отделения 4 Информационных технологий и систем ИДСТУ СО РАН.

Научный руководитель:

Хмельнов Алексей Евгеньевич,
кандидат технических наук, доцент,
первый заместитель директора по
информатизации ИДСТУ СО РАН

Рецензенты:

Юрин Александр Юрьевич,
кандидат технических наук, доцент,
ведущий научный сотрудник,
зав. лабораторией 4.2 Информационно-
телекоммуникационных технологий
исследования техногенной безопасности
ИДСТУ СО РАН

Ойнац Алексей Владимирович,
кандидат физико-математических наук,
старший научный сотрудник лаборатории
диагностики ионосферы и распространения
радиоволн ИСЗФ СО РАН

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность темы. Характеристики ионосферы имеют важное прикладное значение для радиосвязи. Предсказание данных величин позволяет с большей надежностью оперировать аппаратными средствами радиосвязи и навигации. В свою очередь, накопленные данные измерений и возросшие в последние десятилетия вычислительные возможности ЭВМ позволяют использовать различные эмпирические модели предсказания, например такие, как искусственные нейронные сети. В исследовании освещаются аспекты применения эмпирических моделей для предсказания различных показателей ионосферы. Одним из таких показателей является частота f_oF2 . Критическая частота f_oF2 — максимальная частота отраженной от ионосферы радиоволны. Если частота радиоволны превышает критическую, то волна будет пронизывать ионосферу. Следовательно, знание этой частоты имеет важное практическое значение для радиосвязи.

В современном мире быстро развиваются технологии машинного обучения, а также накоплены большие данные измерений, что позволяет применять их для построения предсказательных геофизических моделей. Возросшие вычислительные мощности позволяют обработать большие объемы данных за приемлемое время. На основе этих данных, полученных с геофизических измерительных инструментов, возможно построение регрессионных моделей важнейших параметров ионосферы, в частности критических частот распространения электромагнитных волн. Современные вычислительные возможности и программные комплексы позволяют эффективно обрабатывать данные, а алгоритмы машинного обучения – находить неявные связи между заданными параметрами. С помощью моделей машинного обучения эмпирические модели можно представить не в виде черного ящика, а в виде математической формулы.

Сложные системы околоземного пространства, в частности магнитосфера, ионосфера, описываются также и физическими моделями, которые, однако, не

всегда учитывают скрытые параметры, влияющие на их состояние. В работе предлагается на основе регрессионных моделей зависимостей состояния ионосферы от внешних параметров дополнить физические модели ионосферы. В этом заключается актуальность работы.

Машинное обучение — современный и быстро развивающийся подход к анализу и прогнозу поведения сложных систем, который в последнее время часто используется при решении геофизических задач и задач прогноза состояния ионосферы в том числе. Большой вклад в исследование применения методов машинного обучения в геофизической среде внесли как российские, так и зарубежные ученые. В частности, в работах Н. А. Бархатова и С. Е. Ревунова освещается применение искусственных нейронных сетей^{1,2} в задачах солнечно-земной физики, упомянуты как задачи регрессии, так и классификации. В работах Е. О. Оуеуеми и А. W. V. Poole произведен анализ глобальной модели ионосферы и краткосрочного прогноза критической частоты ионосферы. Также стоит упомянуть таких исследователей, как R. Athieno, L. A. McKinnell, Ting Lan, J. Fan, I. L. Mallika.

Критическая частота foF2 ионосферы является одной из основных характеристик ионосферы, используемых при решении прикладных задач. В задачах вертикального зондирования это – максимальная частота отраженной от ионосферы радиоволны обыкновенной поляризации. В задачах наклонного распространения радиоволны с ее помощью можно оценить величину максимально применимой для радиосвязи частоты.

В задачах глобального позиционирования с помощью глобальных навигационных спутниковых систем ионосфера влияет на величину поправки, необходимой для повышения точности позиционирования.

¹ Бархатов, Н. А. Технология искусственных нейронных сетей для прогнозирования критической частоты ионосферного слоя F2 / Н. А. Бархатов, С. Е. Ревунов, В. П. Урядов // Известия вузов. Радиофизика. 2005. Т. 48, № 1. С. 1–15.

² Бархатов, Н. А. Комплексная классификация глобальных геомагнитных возмущений / Н. А. Бархатов, А. Е. Левитин, С. Е. Ревунов // Космические исследования. 2006. Т. 44, № 6. С. 488–499.

Целью научно-квалификационной работы является построение предсказательных эмпирических моделей лучшего или сопоставимого качества по сравнению с существующими моделями, поиск и изучение методологий проектирования, отладки и тестирования моделей машинного обучения в геофизической сфере.

Основные задачи для достижения поставленной цели:

1. Анализ существующих подходов при моделировании характеристик ионосферы, методов машинного обучения, применяемых в геофизике и астрофизике.

2. Разработка моделей наукастинга на основе ионосферных данных г. Иркутска и п. Арти (Свердловская область), а также данных геомагнитных и солнечных индексов.

3. Написание связующего программного обеспечения, а именно: реализация программ для преобразования табличных данных в удобный формат для машинного обучения, в частности, создание дополнительных признаков, агрегация данных из различных источников.

Объектом исследования является эмпирическое моделирование ионосферы.

Предметом исследования являются предсказательные модели характеристик ионосферы, алгоритмы для построения решений по выявлению зависимостей состояния ионосферы от геофизических данных.

Методы исследования. В работе использовались методы построения моделей машинного обучения, регрессионного анализа, математической статистики. Также применялся метод индукции при анализе применимости моделей машинного обучения.

Научная новизна

1. Разработан оригинальный алгоритм моделирования временных рядов с помощью двумерных сверточных нейронных сетей с усреднением по ансамблю моделей и выходным нейронам.

2. Показано, что модели машинного обучения, обученные на данных одного среднеширотного пункта, могут применяться для наукастинга критической частоты f_oF2 в другом населенном пункте. Такие модели обучены на данных г. Иркутска и п. Арти (Свердловская область).

На защиту выносятся следующие основные результаты:

1. Модели наукастинга (вычисляют текущее значение моделируемого параметра) на основе текущих значений геомагнитных индексов, временных параметров, а также солнечного индекса $f_{10.7}$, позволяющие определять текущую критическую частоту f_oF2 ионосферы со средней абсолютной ошибкой в 12–16%. Модели обучены на данных ионосферных наблюдений г. Иркутска и п. Арти (Свердловская область), а также данных геомагнитных индексов и солнечного индекса $f_{10.7}$.

2. Предсказательная модель прогноза критической частоты ионосферы f_oF2 , основанная на двумерной свертке истории наблюдений критической частоты и геомагнитных индексов при усреднении коэффициентов в плоскостях многократного обучения, а также выходных предсказательных нейронов. Данная модель позволяет совершать прогноз частоты f_oF2 на 24 часа вперед с достаточно высокой точностью (ошибка около 10%). В работе показано, что, несмотря на то, что модель обучена только на данных г. Иркутска, она выдает схожие показатели качества при предсказании частоты f_oF2 в других среднеширотных пунктах.

3. Программное обеспечение для создания глобальной БД геофизических данных, выполняющее загрузку данных из БД ионосферных наблюдений GIRO, а также из базы геомагнитных индексов OMNI. Также было реализовано связующее программное обеспечение для создания единой базы данных.

Соответствие диссертации паспорту специальности. Тема и основные результаты диссертации соответствуют следующим областям исследований, включенным в паспорт специальности 05.13.18 — Математическое моделирование, численные методы и комплексы программ:

– разработка, обоснование и тестирование эффективных вычислительных методов с применением современных компьютерных технологий;

– реализация эффективных численных методов и алгоритмов в виде комплексов проблемно-ориентированных программ для проведения вычислительного эксперимента;

– комплексные исследования научных и технических проблем с применением современной технологии математического моделирования и вычислительного эксперимента.

Теоретическая значимость работы заключается в применении новых подходов к задаче построения предсказательных моделей машинного обучения.

Практическая значимость. Разработанные в рамках диссертационной работы модели и программное обеспечение позволяют осуществлять прогноз космической погоды и, в частности, критической частоты ионосферы foF2, а также выполнять вычисление текущих характеристик ионосферы на основе геофизических данных.

Достоверность полученных результатов обусловлена сравнительным анализом результатов работы прогнозных моделей с данными измерений.

Апробация результатов работы. Результаты научно-квалификационной работы докладывались и обсуждались на ежегодных конференциях ИДСТУ СО РАН “Ляпуновские чтения” (Иркутск, 2018–2019 гг.), а также на семинаре “III International workshop “Data life cycle in physics”, DLC-2019 (Иркутск, 2019 г.).

Публикации и личный вклад автора. По материалам научно-квалификационной работы (диссертации) опубликовано 5 работ, список которых приведен в конце научного доклада. В число указанных работ входит статья, опубликованная в журнале, рекомендованном ВАК для опубликования результатов диссертаций. Разработка методов применения машинного обучения для прогноза и вычисления характеристик ионосферы, а также все выносимые на защиту положения получены автором лично.

КРАТКОЕ СОДЕРЖАНИЕ РАБОТЫ

Во введении приведена постановка задачи, исследуемой в научной работе, сделан акцент на важности исследования околоземного пространства, в частности ионосферы, а также его характеристик.

В **главе 1** выполняется обзор текущих исследований в области моделирования ионосферы. Обсуждается применение различных эмпирических моделей, как устоявшихся (модель IRI), так и современных, основанных на машинном обучении. Произведен анализ проблем, возникающих при применении моделей машинного обучения для вычисления и предсказания характеристик ионосферы.

Также в **главе 1** дано описание геомагнитных индексов, приведена история их возникновения, особенности расчета.

Глава 2 посвящена исследованию архитектуры многослойной искусственной нейронной сети для предсказания критической частоты foF2 на данных г. Иркутска и данных геомагнитных и солнечных индексов. Пример суточного хода критической частоты по данным среднеширотного ионозонда ИСЗФ СО РАН (г. Иркутск, 52° 16' СШ, 104° 17' ВД) представлен на рисунке 1. Имеет место зависимость критической частоты foF2 от индексов солнечной и геомагнитной активности. Особенно значима зависимость частоты foF2 от потока радиоизлучения солнца на длине волны 10.7 см, однако существует и ее зависимость от индексов геомагнитной активности (Kp, ap, Dst-индексов).

В **разделе 2.1** обсуждается построенная модель на основе искусственной нейронной сети, обученная на четырех различных наборах данных, отличие которых заключается как в способе разделения обучающей и тестовой выборки, так и в наборе признаков. Обучение производилось на данных г. Иркутска с 2009 по 2016 гг., а также данных геомагнитных индексов и солнечного индекса f10.7. Было показано, что обучение в случае, когда временные интервалы обучающей и тестовой выборок совпадают, дает лучшие результаты прогноза, чем когда они не пересекаются. Это говорит о том, что либо входные параметры модели неполны

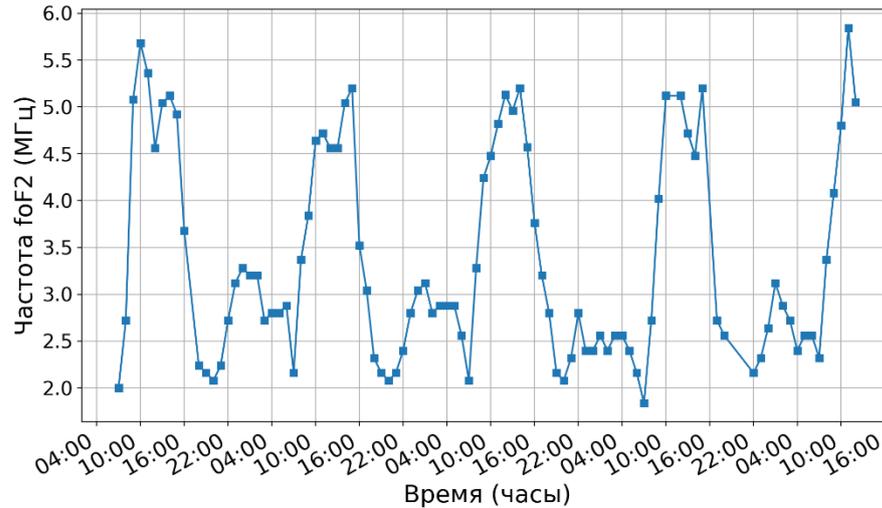


Рисунок 1 — Суточный ход критической частоты foF2 по данным среднеширотного ионозонда (г. Иркутск, 52° 16' СШ, 104° 17' ВД) как функция локального времени

(и не были учтены какие-то физические параметры или процессы), либо объем выборки нестационарного процесса недостаточен для построения адекватной модели (несмотря на большой объем данных, все точки относятся к относительно малому фрагменту области определения функции и, в частности, не затрагивают весь 12-летний цикл солнечной активности).

В разделе 2.2 подробно анализируется структура полученной модели искусственной нейронной сети. Выявляются наиболее сильные весовые коэффициенты в нейронах, и делаются выводы о влиянии на предсказанную частоту foF2 тех или иных признаков, а именно: насколько сильно влияет на результат предсказания тот или иной геомагнитный или солнечный индекс, либо характеристика времени. Сделан вывод, что критическая частота foF2 наиболее сильно зависит от времени, а также от параметра f10.7. В меньшей степени критическая частота foF2 зависит от геомагнитных индексов Dst, ap и Kp. Это подтверждает физический смысл зависимости критической частоты foF2 от солнечного излучения, заключающийся в увеличении степени ионизации верхних слоев атмосферы при увеличении интенсивности солнечного излучения.

В разделе 2.3 приводится описание и сравнительный анализ нейросетевых моделей наукастинга foF2 по данным разнесенных среднеширотных станций. В качестве входных данных для построения моделей использовались измерения критической частоты foF2 в г. Иркутске, произведенные с помощью дигизонда DPS-4, и измерения критической частоты foF2 в п. Арти (Свердловская область), полученные с помощью ионозонда «Парус». Эти станции расположены приблизительно на одинаковой географической и геомагнитной широте, что позволяет исключить из рассмотрения широтные эффекты и сосредоточиться только на долготных эффектах, а также на эффектах, связанных с проявлениями космической погоды. Для сравнительного анализа и доработки нейросетевой модели были использованы данные, вычисленные с помощью ионосферной модели IRI для пунктов г. Иркутск и п. Арти за 2017 год. Выделяются три варианта моделирования, показатели качества которых сравнивались:

– нейросетевая модель, обученная на данных измерений критической частоты foF2, а также геомагнитных и солнечных индексов, характеристик времени;

– нейросетевая модель, обученная на данных измерений критической частоты foF2, геомагнитных и солнечных индексов, характеристик времени, а также признаков, вычисленных с помощью модели IRI: максимальной и минимальной частоты foF2 за предыдущие 24 часа;

– модель IRI.

Первая модель нейронной сети имеет 7 входов и 1 выход (значение критической частоты foF2). Помимо геомагнитных индексов, в качестве входных данных для обучения нейронной сети также были использованы временные параметры, основой которых является локальное солнечное время, так как влияние солнечного излучения на ионосферу зависит в том числе от положения солнца на горизонте. Для того чтобы учесть периодичность изменения частоты foF2, были использованы периодические величины на основе синуса и косинуса. В моделировании были задействованы две выборки: первая, содержащая данные

г. Иркутска за 2017 г.; вторая, содержащая данные п. Арти за 2017 г. Было произведено два вычислительных эксперимента:

1. Обучение нейросетевой модели по данным п. Арти, построение прогноза с помощью этой модели для г. Иркутска, сравнение получившегося прогноза с реальными данными г. Иркутска и данными модели IRI для г. Иркутска.

2. Обучение нейросетевой модели по данным г. Иркутска, построение прогноза с помощью этой модели для п. Арти, сравнение получившегося прогноза с реальными данными п. Арти и данными модели IRI для п. Арти.

По результатам эксперимента выявлено, что при использовании модели выбранной географической точки для построения прогноза для другой географической точки в сходной широте коэффициент корреляции между данными измерений ионозондов и данными, вычисленными при помощи нейронной сети, остается довольно высоким, что свидетельствует о схожем характере процессов в ионосфере на данных широтах. При этом характеристики модели IRI в целом уступают показателям нейронной сети и, в частности, обладают меньшим коэффициентом корреляции с экспериментальными данными и большей средней абсолютной ошибкой на данных г. Иркутска.

При анализе распределения ошибок эмпирических моделей выяснилось, что ошибки нейронной сети имеют гораздо более смещенный характер, чем ошибки модели IRI, однако обладают меньшим значением среднеквадратичного отклонения.

Для улучшения качества прогноза было предложено соединить два типа эмпирических моделей в одну, а именно, при обучении нейросетевой модели подать на ее вход два дополнительных признака, вычисленных с помощью модели IRI: максимальную и минимальную частоты foF2 за предыдущие 24 часа. Конфигурация нейронной сети при этом была выбрана идентичной предыдущей для того, чтобы исключить влияние изменившихся гиперпараметров нейросети на результат. Как видно из таблицы 1, средние абсолютные ошибки комбинированных моделей значительно снизились, коэффициент корреляции незначительно увеличился. Это говорит об улучшении качества комбинированной

модели по сравнению с использованием моделей нейронных сетей и модели IRI по отдельности.

Таблица 1 — Корреляция и ошибки нейросетевых и эмпирических моделей

Данные для прогноза	Данные для обучения ИНС	Нейронная сеть		Модель IRI		Нейронная сеть + модель IRI	
		r	MAPE, %	R	MAPE, %	r	MAPE, %
г. Иркутск	п. Арти	0,89	13.1	0.82	15.37	0.9	11.15
п. Арти	г. Иркутск	0,90	16,0	0,84	14,64	0,92	13,03

Анализ распределения ошибок комбинированной модели показал, что, несмотря на улучшение показателей по сравнению с обычной нейронной сетью, у данной модели также присутствует неравномерное распределение ошибок, указывающее на то, что предсказание работает лучше в дневные часы по локальному солнечному времени. В конце **раздела 2.4** сделаны следующие выводы:

- модель IRI обладает худшими, чем нейросетевая модель, показателями средней абсолютной ошибки (при прогнозе для г. Иркутска) и коэффициентом корреляции Пирсона с данными измерений;

- использование дополнительных признаков, рассчитанных, с помощью модели IRI для обучения нейронной сети позволяет улучшить качество этой нейронной сети;

- при предсказании критической частоты foF2 нейросетевые модели работают хуже в ночное время, чем в дневное.

В **главе 3** обсуждается применение и проводится сравнение моделей машинного обучения различных архитектур. Для данного анализа предлагается рассмотреть следующие методы машинного обучения: искусственную нейронную сеть, градиентный бустинг и случайный лес. Сравнение различных архитектур машинного обучения показало, что модель нейронной сети обладает чуть лучшими показателями качества при ее проверке на валидационной выборке, чем методы, основанные на деревьях решений. Кривая обучения модели градиентного

бустинга показала, что во время обучения наступает определенный момент, после которого нет смысла увеличивать количество деревьев, из которых состоит модель, так как она начинает переобучаться (т.е. начинает увеличиваться ошибка предсказания на валидационной выборке), поэтому на каждой итерации обучения важно отслеживать величину функции потерь, используемую при оптимизации данного алгоритма, не только на обучающей, но и на валидационной выборке. При анализе модели градиентного бустинга было выяснено, что на результат предсказания критической частоты foF2 наиболее сильно влияют признаки времени, а также солнечный индекс f10.7, что подтверждает анализ искусственной нейронной сети, проведенный в **разделе 2.2**.

Глава 4 посвящена исследованию инерционных процессов и выявлению долговременных зависимостей в ионосфере. В частности, в **разделе 4.1** проводится анализ рекуррентной нейронной сети LSTM для предсказания критической частоты ионосферы foF2. Делается обзор различных архитектур рекуррентных нейронных сетей с точки зрения их достоинств и недостатков при решении задач рассматриваемого вида. Например, рекуррентная сеть Элмана обладает некоторыми сложностями при обработке больших временных последовательностей. В частности, имеет место проблема исчезающего градиента при обучении нейронной сети. Рекуррентная нейронная сеть под названием Long Short-Term Memory позволяет более эффективно обрабатывать долговременные последовательности, поэтому она была выбрана для построения модели, выполняющей предсказание критической частоты ионосферы foF2 на 24 часа вперед. В качестве данных для анализа использовались измеренные значения частоты foF2 со скважностью в 1 час, полученные на среднеширотном Иркутском ионозонде DPS-4, а также индекс геомагнитной возмущенности Dst и индекс f10.7 интенсивности солнечного излучения на длине волны 10,7 см за период с 2009 по 2016 гг., полученные из базы данных геомагнитных OMNI. Выборка размером 61675 элементов была разделена в следующей пропорции: 80% — обучающая, 20% — тестовая. Пропущенные значения в количестве 8456 из 61675 были заполнены линейной интерполяцией по соседним значениям, дополнительно

ступенчатые данные индекса $f_{10.7}$ были сглажены квадратичной кривой. Перед моделированием данные были нормализованы. После обучения была произведена оценка качества полученной модели. При сравнении предсказанных и измеренных значений в тестовой выборке были выявлены следующие показатели качества: коэффициент корреляции Пирсона — 0,923, корень среднеквадратичной ошибки (RMSE) — 0,605, средняя абсолютная ошибка в процентах (MAPE) — 10,067, что позволяет сделать вывод о хорошей эффективности данного метода предсказания критической частоты ионосферы foF2 на 24 часа вперед.

Раздел 4.2 посвящен применению сверточных нейронных сетей для предсказания критической частоты foF2. Проведено построение сверточной нейронной сети, способной предсказывать значения частоты foF2 на 24 часа вперед по истории данных, и проведен анализ ее коэффициентов с точки зрения регрессионного анализа. Данная работа состояла из двух этапов, в каждом из которых использовалась собственная архитектура нейросети: первая, основанная на двумерной свертке истории наблюдений критической частоты и геомагнитных индексов, и вторая, использующая усредненные по ансамблю моделей первого типа коэффициенты. В качестве исходных данных для анализа применялись ряды данных foF2, полученные обработкой ионограмм, измеренных на среднеширотном Иркутском ионозонде — дигизонде DPS-4, а также индекс геомагнитной возмущенности Dst и индекс $f_{10.7}$ интенсивности солнечного излучения на длине волны 10,7 см за период с 2009 по 2016 гг. Для заполнения пропущенных данных была использована линейная интерполяция. Дополнительно данные геомагнитного индекса $f_{10.7}$, имеющие временное разрешение 1 сутки, были интерполированы гладкой (квадратичной) кривой.

В разделе **4.2.2** приводится алгоритм формирования исходных данных для моделирования. Обучающая и тестовая выборки были нормализованы и преобразованы от векторнозначной (3х-мерной) функции времени (представляющей собой значения foF2, $f_{10.7}$, Dst с временным разрешением 1 час) к последовательности матриц размером 90×24 для каждого из параметров (90 дней до текущего момента, 24 часа относительно текущего часа),

характеризующих исторические значения соответствующих параметров за предыдущие 3 месяца. Последовательность матриц строилась таким образом, чтобы каждому часу каждого дня измерений соответствовала своя тройка матриц. Двадцать четыре значения foF2, следующие за текущим моментом, являлись целевыми, подлежащими прогнозу по значениям трех матриц (foF2, f10.7, Dst), соответствующих текущему моменту. Для обучения было сгенерировано ~ 65 тыс. элементов данных. Сформированные данные разделены на две выборки объемом ~ 56 тыс. (обучающая) и ~ 9 тыс. (тестовая).

Следующий **раздел 4.2.3** посвящен структуре исходной сети, ее обучению и свойствам. Сеть представляет собой три независимых параллельных сверточных слоя (для каждого из входных параметров foF2, Dst, f10.7), затем результат соединяется и подается на вход однослойной сети с линейной функцией активации, выполняющей функцию линейной комбинации результатов работы сверточных слоев (рисунок 2).

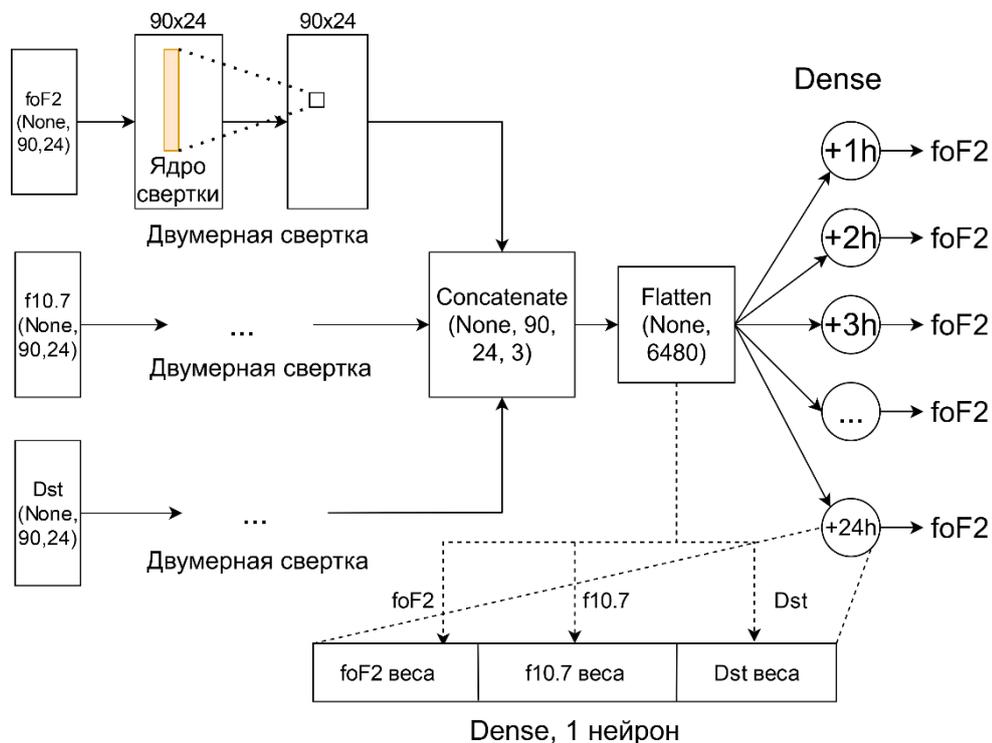


Рисунок 2 — Архитектура исходной нейронной сети

После чего модель многократно обучается и строится ансамбль из моделей. Простейшим ансамблевым методом, позволяющим в некоторых случаях

увеличить точность прогноза, является бэггинг, заключающийся в независимом обучении ансамбля сетей и суперпозиции результатов, прогнозируемых каждой сетью неким фиксированным алгоритмом, обычно усреднением. Было обучено 200 моделей, затем составлено три разных варианта ансамбля. Поскольку заранее не известно, какое количество моделей оптимально, после обучения 200 моделей было составлено три разных ансамбля: из 30, 100 и 200 моделей. Затем в данном разделе описаны алгоритмы усреднения, как в рамках ансамбля, так и в рамках коэффициентов выходных нейронов, учитывающие влияние исторических часов на час предсказания. Итогом первого этапа моделирования являются три матрицы усредненных коэффициентов размером 90×24 для каждого из моделируемых параметров: foF2, f10.7, Dst.

В разделе 4.2.4 обсуждается методика построения итоговой модели машинного обучения, которая, помимо данных, используемых исходной моделью, оперирует матрицами усредненных коэффициентов. Вместо двумерной свертки в этой модели используется поточечное умножение входных матриц данных на значения усредненных коэффициентов. В таблице 2 приведены показатели качества итоговых моделей, основанных на анализе ансамблей в 30, 100 и 200 независимых обучений, а также приведено сравнение с показателями качества модели IRI.

Таблица 2 — Показатели качества модели IRI и нейросетевых моделей при различных коэффициентах модели

Количество независимых обучений	Pearson (R)	RMSE (МГц)	MAPE, %
30	0,930	0,542	9,35
100	0,929	0,542	9,410
200	0,929	0,543	9,458
Модель IRI	0,880	0,757	12,645

Данные показатели позволяют сделать вывод, что не происходит улучшение качества модели с ростом количества независимых обучений, и для получения

средних коэффициентов модели достаточно провести 30 независимых обучений исходной модели и усреднить их коэффициенты. На рисунке 3 изображен пример результата предсказания итоговой модели.

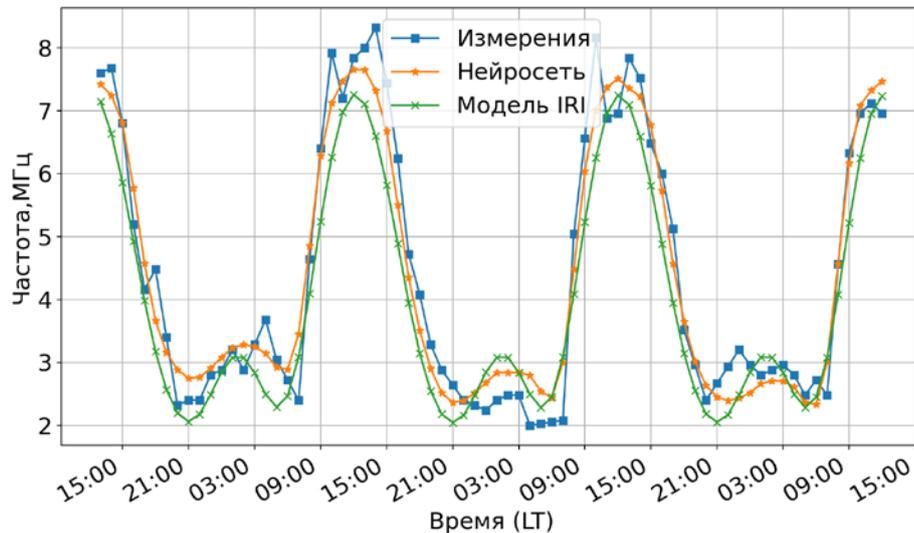


Рисунок 3 — Графики предсказания частоты foF2 нейронной сетью, моделью IRI и ее суточного хода с 15.09.2015 13:00 по 18.09.2015 13:00 (г. Иркутск) для итоговой модели с коэффициентами, рассчитанными на ансамбле из 200 независимых обучений

В разделе 4.2.5 выполнена проверка модели на данных различных среднеширотных ионозондов, расположенных в Свердловской области, п. Арти ($56^{\circ}25'$ СШ, $58^{\circ}32'$ ВД), Польше, г. Варшаве ($52^{\circ}13'$, СШ $21^{\circ}02'$ ВД), Китае, г. Мохе ($52^{\circ}58'$ СШ, $122^{\circ}31'$ ВД). При создании моделей прогноза важна их обобщающая способность, которая может быть проверена показателями качества на различных валидационных выборках, не пересекающихся с обучающей выборкой. Показатели качества прогноза, полученные в результате тестирования данных среднеширотных ионозондов, приведены в таблице 3.

Полученные результаты свидетельствуют о хорошей общности построенной модели, абсолютная ошибка которой составляет порядка 0,5–0,6 МГц и слабо зависит от долготы станции. Это позволяет сделать вывод о пригодности модели для прогноза foF2 по данным среднеширотных ионозондов.

Таблица 3 — Показатели качества модели на данных различных среднеширотных ионозондов

	Pearson(R)	RMSE (МГц)	MAPE, %
п. Арти (Свердловская область)	0,903	0,515	9,907
г. Варшава (Польша)	0,866	0,573	10,855
г. Мохе (Китай)	0,876	0,502	9,953

В главе 5 обсуждается построение глобальной модели машинного обучения на основе данных мировой сети ионозондов GIRO. Описан интерфейс базы данных ионосферных наблюдений и геомагнитных индексов.

ОСНОВНЫЕ ВЫВОДЫ И РЕЗУЛЬТАТЫ РАБОТЫ

Выполненная работа посвящена разработке методов применения машинного обучения для построения вычислительных и предсказательных моделей. В результате проведенного исследования были получены следующие результаты:

1. Обучены модели наукастинга на ионосферных данных г. Иркутска и п. Арти, которые на основе текущих значений геомагнитных индексов, временных характеристик и солнечного индекса $f_{10.7}$ определяют текущую критическую частоту f_oF2 ионосферы с достаточно большой точностью (ошибка 12–16%). Особенностью этих моделей является то, что их можно применять для наукастинга не только в точке, на данных которой модель обучалась, но и в другой среднеширотной географической точке.

2. Построена предсказательная модель прогноза критической частоты ионосферы f_oF2 , основанная на двумерной свертке истории наблюдений критической частоты и геомагнитных индексов. Модель проверена на данных различных среднеширотных пунктов.

3. Разработан набор связующего программного обеспечения, в частности для регистрации, определенной по ионограмме критической частоты f_oF2 , для предварительной обработки данных перед моделированием, для создания

объединенной базы данных характеристик ионосферы и геомагнитных и солнечных индексов.

Задачи, поставленные перед исследованием, были успешно выполнены.

ОСНОВНЫЕ ПУБЛИКАЦИИ ПО ТЕМЕ ИССЛЕДОВАНИЯ

Статьи в журналах из перечня ВАК:

1. Ларюнин, О.А. Аномальные ионосферные отражения по данным Иркутского ЛЧМ-ионозонда за 2012–2016 гг. / О.А. Ларюнин, В.И. Куркин, О.И. Бернгардт, А.В. Подлесный, Б.Г. Салимов // Геомагнетизм и аэрономия. РАН. — 2019. — Т. 59, № 1. — С. 110–113.

Статьи в других изданиях:

1. Салимов, Б.Г. Построение модели foF2 по индексам солнечной и геомагнитной активности и данным Иркутского дигизонда / Б.Г. Салимов, А.Е. Хмельнов, О.И. Бернгардт // Материалы конф. «Ляпуновские чтения» (г. Иркутск, 3–5 декабря 2018 г.). — Иркутск: ИДСТУ СО РАН, 2018. — С. 74.

2. Salimov, B.G. The analysis of current neural network configuration used to predict the critical frequency FoF2 of the ionosphere / B.G. Salimov, A.E. Hmelnov, O.I. Berngardt // Intern. Workshop on Data Life Cycle in Physics, DLC 2019 (Irkutsk, Russian Federation, April 2–7, 2019). CEUR Workshop Proceedings, 2019. — Vol. 2406. — P. 100–105.

3. Салимов, Б.Г. Сравнение различных моделей машинного обучения для предсказания критической частоты foF2 / Б.Г. Салимов, А.Е. Хмельнов // Материалы конф. «Ляпуновские чтения» (г. Иркутск, 2–5 декабря 2019 г.). — Иркутск: ИДСТУ СО РАН, 2019. — С. 73.

4. Салимов, Б.Г. Предсказание критической частоты ионосферы foF2 с помощью нейронной рекуррентной LSTM сети / Б.Г. Салимов, А.Е. Хмельнов // Материалы конф. «Ляпуновские чтения» (г. Иркутск, 7–11 декабря 2020 г.). — Иркутск: ИДСТУ СО РАН, 2020. — С. 60–61.