

**Федеральное государственное бюджетное учреждение
«Гидрометеорологический научно-исследовательский центр Российской Федерации»**

На правах рукописи

Быков Филипп Леонидович

**ПОСТПРОЦЕССИНГ ЧИСЛЕННЫХ ПРОГНОЗОВ
ПРИЗЕМНЫХ МЕТЕОРОЛОГИЧЕСКИХ ПАРАМЕТРОВ
НА ОСНОВЕ НЕЙРОСЕТЕВЫХ МЕТОДОВ**

25.00.29 – физика атмосферы и гидросферы

АВТОРЕФЕРАТ

диссертации на соискание ученой степени
кандидата физико-математических наук

Москва – 2022

Работа выполнена в федеральном государственном бюджетном учреждении «Гидрометеорологический научно-исследовательский центр Российской Федерации» (ФГБУ «Гидрометцентр России»), отдел анализа и усвоения данных.

Научный руководитель:

доктор физико-математических наук **Гордин Владимир Александрович**

Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский университет «Высшая школа экономики», профессор.

Официальные оппоненты:

доктор физико-математических наук, профессор **Чаликов Дмитрий Викторович**

Институт океанологии им. П.П.Ширшова Российской академии наук, Санкт-Петербургский филиал, главный научный сотрудник. Университет Мельбурна, почетный профессор

доктор физико-математических наук **Оселедец Иван Валерьевич**

Автономная некоммерческая образовательная организация высшего образования "Сколковский институт науки и технологий", профессор

Ведущая организация:

Федеральное государственное учреждение "Федеральный исследовательский центр Институт прикладной математики им. М.В. Келдыша Российской академии наук"

Защита диссертации состоится « » июня 2022 г. в часов на заседании Диссертационного совета по защите докторских и кандидатских диссертаций Д 327.003.01 при федеральном государственном бюджетном учреждении «Гидрометеорологический научно-исследовательский центр Российской Федерации» (ФГБУ «Гидрометцентр России») по адресу: 123376, Россия, Москва, Большой Предтеченский переулок, д. 13, строение 1.

С диссертацией можно ознакомиться в научной библиотеке ФГБУ «Гидрометцентр России» и на сайте <https://meteoinfo.ru/disserboard/>

Автореферат разослан “__” _____ 2022 г.

Ученый секретарь Диссертационного совета,

кандидат физико-математических наук

М.В. Шатунова

Общая характеристика работы

Актуальность темы исследования. Пользователи метеопрогноза могут быть неудовлетворены прогнозом численной модели прогноза погоды (далее ЧМПП) по двум основным причинам: а) если в прогнозе не представлена (или представлена в неудовлетворительной форме) интересующая пользователя информация о погоде; б) если качество предоставленной информации недостаточно высокое.

Уменьшить эти недостатки можно, применив методы статистической интерпретации (постпроцессинга) ЧМПП. Для применения методов статистической интерпретации используется архив прогностических и фактических данных и разумный и строго математически сформулированный критерий качества.

Постпроцессинг ЧМПП принимают на вход некоторый набор предикторов $\vec{X}(t, \vec{x})$, в том числе выходная продукция ЧМПП (direct model output), и применяют к ним модель машинного обучения из некоторого параметрического семейства $\vec{F}(\vec{X}, \vec{\theta})$, где $\vec{\theta} \in \mathbb{R}^n$ – параметры модели F , которые нужно оптимизировать в силу минимизации заранее заданного штрафного функционала («обучить модель»).

Выделим четыре основных подхода к построению моделей машинного обучения:

1. Линейный подход: модель – линейная [Wilks, 2006];
2. Решающие деревья: модель – кусочно-постоянная [Quinlan, 1986], [Breiman, 2001];
3. Нейронные сети: модель – нейронная сеть [Rosenblatt, 1958], [Хайкин, 2006];
4. Генетическое программирование: модель – композиция заранее заданных «элементарных» функций [Koza, 1992].

Во многих методах при нахождении оптимальных в смысле штрафного функционала параметров $\vec{\theta}$ используются *гиперпараметры*, то есть параметры метода машинного обучения, не участвующие непосредственно в модели F , но влияющие на найденные оптимальные параметры $\vec{\theta}$. Примеры гиперпараметров: параметры алгоритма обучения модели и выбранные размерности скрытых (латентных) пространств. Значения гиперпараметров определяют валидацией модели F на независимой выборке.

В линейном подходе (например, в методе наименьших квадратов) рассматривается семейство линейных функций от предикторов. Линейный подход не гарантирует достижения наилучшего значения штрафного функционала, но он сравнительно прост, общепринят и наиболее разработан. Существенно улучшить качество прогнозов с помощью линейных моделей возможно лишь, конструируя (то есть, добавляя новые или заменяя старые)

предикторы, что требует ручной работы специалиста (это так называемая задача feature engineering).

Нелинейный подход предоставляет дополнительные возможности для использования уже отобранных предикторов. Рассматриваемые в современных нелинейных подходах классы моделей машинного обучения $F(\vec{X}, \vec{\theta})$ позволяют приблизить любую непрерывную функцию с любой наперед заданной точностью.

Статистические методы в метеорологии применяются традиционно [Багров, 1959], [Пановский, Брайер, 1972], [Груза, Рейтенбах, 1982], [Wilks, 2006]. Разработаны различные предикторы (и их комбинации – индексы). То есть задача feature engineering уже многократно решалась. Вопрос о преимуществах нелинейного подхода над линейным остается актуальным.

Важным преимуществом линейных методов является их применимость при отсутствии части информации. Этим преимуществом обладают и нейронные сети специальных типов, например, рекуррентные [Hochreiter, Schmidhuber, 1997], сети внимания и трансформеры [Vaswani et al., 2017].

Цели и задачи работы. Основной целью диссертационной работы является разработка основанного на применении нейросетевых методов нового автоматизированного комплекса постпроцессинга выходной продукции одной или нескольких численных прогностических моделей с учетом последних наблюдений (за период длительностью T) приземных метеорологических величин на синоптических станциях. Необходимо, чтобы разработанный комплекс:

- был применим в случаях частичного отсутствия прогностической информации и в случаях отсутствия (отбраковки алгоритмом контроля качества) части данных наблюдений за период T ;
- обеспечивал получение прогностических данных и в местах расположения синоптических станций, и в узлах модельной сетки;
- уточнял результаты численных прогнозов погоды;
- мог работать в оперативном режиме на доступных вычислительных системах.

Для достижения этой цели были сформулированы и решены с применением нейросетевых методов следующие задачи:

- систематическая коррекция (комплексификация) прогнозов приземных метеорологических параметров в местах расположения синоптических станций; поправка вычисляется как результат применения к известным погрешностям (за период длительностью T) прогнозов модели (моделей) нелинейного оператора, коэффициенты которого вычисляются нейронной сетью;

- определение поправок к прогнозам ЧМПП, учитывающий сдвинутые по начальному сроку и заблаговременности прогнозы;
- реализована квазилинейная неоднородная оптимальная интерполяция (КНОИ) по горизонтальным координатам для вычисления поправок к прогностическим полям приземных метеорологических параметров в точках модельной сетки; КНОИ использует нейронные сети для учёта неоднородностей полей поправок;
- оптимизация параметров нейронных сетей, использованных в предложенном постпроцессингом приземных прогностических полей одной и нескольких ЧМПП;
- сравнение различных конфигураций предлагаемого постпроцессинга;

Предложенный постпроцессинг протестирован в непрерывном режиме счета и на большом статистически независимом архиве. Получены сравнительные оценки качества прогнозов, составляемых путем применения предлагаемого постпроцессинга и других известных методов.

Личный вклад автора. Все представленные в диссертации результаты получены лично автором. Автор лично предложил и реализовал в программном виде предлагаемые методы и провел их отладку, обучение, валидацию, тестирование и организовал работу в автоматизированном режиме.

Научная новизна. В диссертационной работе получены следующие новые научные результаты:

- Использование нейронных сетей для вычисления коэффициентов систематической коррекции по сравнению с экспоненциальным сглаживанием уменьшает среднюю погрешность прогнозов на величину, эквивалентную уменьшению заблаговременности на 1 сутки (глава 2);
- Разработана коррекция с помощью нейронных сетей (КНС) для расчета нелинейных поправок к прогностическим полям. КНС учитывает сдвинутые по начальному сроку и заблаговременности прогнозы. Показано, что использование индивидуальных параметров для каждой синоптической станции неэффективно, если была проведена предварительная систематическая коррекция. Определены оптимальные гиперпараметры метода КНС;
- Предложена двумерная квазилинейная неоднородная анизотропная оптимальная интерполяция (КНОИ). КНОИ применяет метод оптимальной интерполяции [Гандин, 1963] после вычисляемого нейронной сетью вложения рассматриваемой двумерной области на поверхности Земли в пространство большей размерности. Применение КНОИ для интерполяции найденных ранее поправок в точках синоптических станций

показало уменьшение погрешностей поправленных прогностических полей в точках «пропущенных» станций по сравнению с линейной однородной оптимальной интерполяцией.

Практическая значимость работы. Предлагаемый автоматизированный комплекс постпроцессинга применяется в повседневной практике и результаты публикуются на интернет-сайтах (примеры продукции, использующей прогнозы, рассчитанные по предлагаемому постпроцессингом, представлены в приложении Б):

- методического кабинета ФГБУ «Гидрометцентр России» <http://method.meteorf.ru/ansambl/ansambl.html> для населенных пунктов России и Беларуси. Прогнозы публикуются дважды в сутки с заблаговременностью до 96 ч доступны в виде карт по каждому из регионов РФ, а для некоторых населенных пунктов – в виде метеограмм с заблаговременностью до 144 ч;
- проекта Всемирной Метеорологической Организации по прогнозированию суровых погодных условий в Центральной Азии <http://swfdp-ca.meteoinfo.ru/prognozy/mmforecasts> для населенных пунктов Центральной Азии в виде метеограмм;
- Численных прогнозов погоды для метеорологического обеспечения <http://u2019.meteoinfo.ru/services> на метеограммах прогнозов по модели COSMO-Ru в конфигурациях COSMO-Ru6-ENA и COSMO-RuBy, выпускаемых четыре раза в сутки, демонстрируются графики поправленных прогнозов температуры и точки росы на высоте 2 м;
- «О погоде для специалистов» ФГБУ «Гидрометцентр России» <https://special.meteoinfo.ru/> для населенных пунктов России в разделах «метеограммы» (дублируются метеограммы с сайта методического кабинета и с сайта численных прогнозов погоды для метеорологического обеспечения) и «прогнозы по пунктам».

Центральной методической комиссией по гидрометеорологическим и гелиогеофизическим прогнозам (ЦМКП) от 29.11.2021 прогностическим подразделением Росгидромета Европейской части России рекомендовано использовать разработанные в диссертации «прогнозы температуры и точки росы на высоте 2 м по пунктам, уточненные на основе методики машинного обучения (авторы Ф.Л. Быков, А.Н. Багров) с привлечением прогнозов COSMO-Ru и визуализированные в виде метеограмм, в комплексе с основными модельными прогнозами в качестве вспомогательной информации».

Качество этих прогнозов оперативно оценивается, и их результаты оперативно публикуются на сайте методического кабинета Гидрометцентра России. Оценки качества

прогнозов максимальной дневной и минимальной ночной температур превосходят соответствующих оценок качества прогнозов синоптиков УГМС.

Получены отзывы, положительно отмечающие полезность и качество представляемых на сайте методического кабинета ФГБУ «Гидрометцентр России» прогнозов от синоптиков Приволжского УГМС, Саратовского ЦГМС, Читинского ГМЦ, Ульяновского ЦГМС, Дальневосточного УГМС, Мурманского УГМС, Владимирского ЦГМС (приложение В).

Методы исследования. Для решения сформулированных в диссертационной работе задач использованы теоретические результаты и методы линейной алгебры, математического анализа, функционального анализа, интерполяции, оптимизации, математической статистики и теории вероятностей, теории случайных полей, статистической обработки больших данных, нейронных сетей и машинного обучения, а также методы структурного и объектно-ориентированного программирования и различные оценки качества метеорологических прогнозов. Использованы архивы прогнозов различных ЧМПП в точках синоптических станций и архивов наблюдений на синоптических станциях.

Положения, выносимые на защиту

1. Новый алгоритм систематической коррекции прогнозов приземных метеорологических параметров для вычисления поправок путем применения оператора с коэффициентами, вычисляемыми нейронной сетью, к известным погрешностям численной модели.
2. Новый алгоритм комплексификации прогнозов нескольких численных моделей, основанный на методе нейронных сетей.
3. Новый алгоритм квазилинейной неоднородной оптимальной интерполяции (КНОИ) инкрементов приземных метеорологических параметров. Алгоритм КНОИ реализует метод оптимальной интерполяции с корреляционной функцией, зависящей от расстояния не в геометрическом пространстве, а в линейном пространстве большей размерности. Вложение в пространство большей размерности вычисляется нейронной сетью и учитывает предикторы неоднородности (в том числе поля первого приближения). Этот учет предикторов неоднородности позволяет объяснить большую часть дисперсии интерполируемого поля.

Обоснованность и достоверность результатов работы. Обоснованность научных положений и выводов, приведенных в диссертационной работе, подтверждается математическими доказательствами, и валидацией постпроцессинга на больших архивах прогностических данных (объемом порядка 10^6 - 10^8 пар из прогностических и фактических значений). Достоверность полученных выводов подтверждена тестированием прогнозов, вычисленных разработанным постпроцессингом, в оперативном автоматизированном режиме.

Использование результатов диссертации. Результаты исследования в форме автоматизированной технологии расчета прогнозов по разработанной методике предназначены для использования широким кругом заинтересованных лиц, в том числе в учреждениях, обеспечивающих выпуск синоптических прогнозов приземных метеорологических параметров с заблаговременностью до 144 ч. Продукция может быть использована как непосредственно в качестве выпускаемых прогнозов, так и для дальнейшего постпроцессинга.

Апробация работы. Основные положения и результаты диссертации докладывались и обсуждались на международных и российских научно-технических конференциях:

1. «М.А.Петросянц и отечественная метеорология» в 2009 и 2019 годах.
2. Научная сессия Совета РАН по нелинейной динамике в 2009, 2011, 2014, 2016, 2019 годах.
3. XXVIII International Conference on Mathematical Geophysics “Modelling Earth Dynamics: Complexity, Uncertainty and Validation” в 2010 году.
4. European Geophysical Union General Assembly в 2011 году.
5. XX Всероссийская конференция «Теоретические основы и конструирование численных алгоритмов решения задач математической физики» в 2014 году.
6. Всероссийская открытая конференция «Современные проблемы дистанционного зондирования земли из космоса» в 2016 и 2021 годах.
7. The China-Russia Conference on Numerical Algebra with Applications (CRCNAA) в 2017 году.
8. Вторая научно-практическая конференция «Современные информационные технологии в гидрометеорологии и смежных с ней областях» в 2017 году.
9. V Международная научная конференция «Региональные проблемы дистанционного зондирования Земли» в 2018 году.
10. Вторая Всероссийская научная конференция с международным участием «Применение средств дистанционного зондирования Земли в сельском хозяйстве» в 2018 году.
11. Семинар в главной геофизической обсерватории им. А.И.Воейкова в 2018 году.
12. Межвузовская научно-техническая конференция студентов, аспирантов и молодых специалистов им. Е.В. Арменского в 2019 и 2021 годах.
13. COSMO General Meeting в 2020 и 2021 году.
14. International Conference on Computer Simulation in Physics and beyond в 2020 году.
15. ICON/COSMO/CLM/ART User Seminar (ICCARUS) в 2020 и 2021 годах.
16. Семинар лаборатории вычислительного интеллекта Сколковского института науки и технологий в 2021 году.

17. Научно-практическая конференция по проблемам гидрометеорологических прогнозов, экологии, климата Сибири (к 50-летию образования СибНИГМИ) в 2021 году.

Публикации. Основные результаты по теме диссертации изложены в 18 научных работах, 7 из которых изданы в периодических научных журналах, рекомендованном ВАК, из которых 6 – в индексируемых в базе данных Scopus; 1 — в материалах конференций; 6 — в сборниках тезисов конференций.

Структура и объем диссертационной работы. Диссертация состоит из введения, 5 глав и заключения, списка литературы из 257 наименований и 3 приложений. Диссертация изложена на 245 страницах, содержит 61 рисунок, 27 таблиц.

Краткое содержание работы

Первая часть главы 1 содержит обзор технологий градиентного машинного обучения методом обратного распространения ошибки и искусственных нейронных сетей. Рассмотрены некоторые часто используемые типы слоёв нейронных сетей и процесс оптимизации параметров нейронных сетей.

При оптимизации модели $\vec{F}(\vec{X}_{input,j}, \vec{\theta})$ *методом машинного обучения с учителем* все параметры $\vec{\theta}$ модели F оптимизируются напрямую на архиве из $j=1, \dots, M$ реализаций *входных аргументов* $\vec{X}_{input,j}$ и *целевых значений* $\vec{X}_{fact,j}$:

$$L(\vec{\theta}) = \frac{1}{M} \sum_{j=1}^M e(\vec{X}_{fact,j}, \vec{F}(\vec{X}_{input,j}, \vec{\theta})) \rightarrow \min_{\vec{\theta}},$$

где e – заранее выбранный критерий качества (*функция потерь, штрафная функция*).

При *градиентном машинном обучении* для минимизации функционала $L(\vec{\theta})$ используется метод градиентного спуска. Нейронные сети эффективно обучать методом градиентного спуска, поскольку для вычисления градиента $\nabla_{\vec{\theta}} L$ требуется примерно столько же арифметических операций, сколько тратится на прямое вычисление $\vec{F}(\vec{X}_{input,j}, \vec{\theta})$.

Помимо параметров метод машинного обучения имеет также гиперпараметры – параметры метода МО, которые невозможно оптимизировать методом обратного распространения ошибки, поскольку эти параметры напрямую не участвуют в вычислении прогноза $\vec{F}(\vec{X}_{input,j}, \vec{\theta})$. Примеры гиперпараметров: размерности латентных (скрытых) пространств и параметры алгоритма градиентного спуска.

Во второй части главы 1 кратко описаны используемые наборы данных: данные наблюдений на синоптических станциях и прогностические данные по различным отечественным и зарубежным ЧМПП.

В третьей части главы 1 обсуждаются предпосылки использования именно нейронных сетей в задачах прогноза погоды и перспективы их применений. Приведен обзор результатов других авторов, применявших нейронные сети в моделировании атмосферных процессов.

В четвертой части главы 1 описаны технические и технологические подробности реализации постпроцессинга и структура разработанных программ и скриптов. При использовании модулей V220F суперкомпьютера T-Platforms V6000, оснащенных GPU-ускорителями Nvidia V100 PCI-E, ускорение по сравнению с вычислениями на процессорах общего назначения составило от 1.6 раза (для модели МО из главы 3) до 115 раз (для интерполяции из главы 4). Практическое применение интерполяции из главы 4 в оперативном режиме реализовано на GPU суперкомпьютера T-Platforms V6000.

Глава 2 посвящена квазилинейной систематической коррекции (КСК) и квазилинейной комплексификации прогнозов (ККП) приземных метеорологических параметров [Розинкина, Ривин, Быков и др., 2021].

Систематическая коррекция [Wilks, 2006] (**первая часть главы 2**) подправляет текущий прогноз, оценивая смещение ЧМПП по известным погрешностям прогнозов рассматриваемой ЧМПП в точке рассматриваемой синоптической станции. Комплексификация (**вторая часть главы 2**) использует аналогичный архив прогнозов, но уже по нескольким моделям ЧМПП и оценивает не только смещения, но и стандартные отклонения погрешностей рассматриваемых ЧМПП.

Обозначим $X_0(t, \tau)$ – прогноз параметра X от начального срока t с заблаговременностью τ . Как правило, рассматривают систематическую коррекцию, являющуюся линейным оператором от известных погрешностей прогнозов рассматриваемой ЧМПП, то есть откорректированный прогноз $X_C(t, \tau)$ вычисляется по формуле:

$$X_C(t, \tau) = X_0(t, \tau) + \frac{\sum_{\delta t = \lfloor \tau \rfloor}^{\lfloor \tau \rfloor + T} w(\delta t, t, \tau) \Delta X(t - \delta t, \tau)}{\sum_{\delta t = \lfloor \tau \rfloor}^{\lfloor \tau \rfloor + T} w(\delta t, t, \tau)}, \quad (1)$$

где $\lfloor \tau \rfloor$ – округление заблаговременности вверх до целого количества суток; $\Delta X(t, \tau) = X_{fact}(t + \tau) - X_0(t, \tau)$ – погрешность прогноза $X_0(t, \tau)$; X_{fact} – фактически

измеренное на рассматриваемой синоптической станции значение параметра X ; T – длительность периода оценки, которая по результатам экспериментов была выбрана равна 35 дням; w – весовая функция, которую оптимизируем с целью минимизации функционала $L(\bar{\theta})$ для прогноза $X_C(t, \tau)$.

Предположим, что оптимальная весовая функция w положительна. Предлагаемая в диссертации КСК использует нейронную сеть для вычисления функции $\omega = \ln w$. При таком подходе обеспечиваются:

- применимость формулы (1) в случае отсутствия части прогностических данных или данных наблюдений;
- частичная интерпретируемость коррекции;
- если нейронная сеть принимает на вход известные погрешности прогнозов ΔX , то коррекция (1) становится квазилинейной.

При оптимизации комплексификации прогнозов нескольких ЧМПП ранее, как правило, предполагали, что

- погрешности прогнозов распределены согласно заранее заданному статистическому закону;
- комплексификация является линейным оператором от прогнозов рассматриваемых ЧМПП.

Если же расширить круг поисков оптимального алгоритма и существенно ослабить или отказаться от этих двух предположений, то качество полученных комплексифицированных прогнозов может возрасти. В главе 2 полностью откажемся от первого предположения, а второе предположение заменим на предположение о представимости оператора комплексификации в некоторой заранее заданной квазилинейной форме: при вычислении весов w используются известные погрешности комплексифицируемых ЧМПП.

На рисунке 1 сравнивается средняя абсолютная ошибка прогнозов модели COSMO-Ru в конфигурации COSMO-Ru6-ENA за декабрь 2020 г. по территории России (1686 станций) от начального срока 00:00 ВСВ, поправленных систематической коррекцией с различными весовыми функциями:

1. с постоянной весовой функцией $w \equiv 1$ (синие линии);
2. экспоненциальной коррекции (ЭК, зеленые линии) $w = \exp(-\lambda \cdot \delta t)$, где $\lambda = \text{const}$;

3. линейной оптимизированной систематической коррекцией (ОСК, фиолетовые линии) $w = \exp(-\lambda \cdot \delta t) / \left(1 + \beta (T(t, \tau) - T(t - \delta t, \tau))^2\right)$, где λ, β – константы, которые были оптимизированы;
4. квазилинейной систематической коррекцией (КСК, черные линии).

Из рисунка 1 и параграфов 2.1.5 и 2.2.4 диссертации следует, что использование нейронной сети для вычисления коэффициентов систематической коррекции улучшает качество прогнозов КСК по сравнению с ЭК на величину, соответствующую уменьшению заблаговременности на 1 сутки.




Рисунок 1 – Средняя абсолютная ошибка прогноза (ось ординат) в зависимости от заблаговременности прогноза (ось абсцисс) различным образом поправленных прогнозов COSMO-Ru6-ENA за декабрь 2020 г. по территории России (1686 станций): с постоянной весовой функцией $w \equiv 1$ и с весовыми функциями ЭК, ОСК, КСК различных метеорологических параметров:

- а) температуры воздуха на высоте 2м; б) точки росы на высоте 2м;
- в) давления на уровне моря; г) скорости ветра на высоте 10 м.

КСК и ККП были применены для коррекции прогнозов приземных метеорологических параметров в точках синоптических станций: температуры воздуха, точки росы, давления, приведенного к уровню моря, скорости и направления ветра, порывов ветра с заблаговременностью до 144 ч. КСК была настроена для коррекции прогнозов модели COSMO-Ru в конфигурациях COSMO-Ru13-ENA, COSMO-Ru6-ENA, COSMO-RuBy и COSMO-Ru1-Msk. ККП использует одновременно прогнозы 7 различных численных моделей прогноза погоды (ЧМПП) COSMO-Ru6-ENA, ECMWF, ICON-De, JMA, GFS, PLAV, UKMO.

Глава 3 посвящена дополнительной коррекции по методу нейронных сетей (КНС) [Быков, 2020], [Розинкина, Ривин, Быков и др., 2021]. Рассмотрены три варианта коррекции:

- к прогнозам по модели COSMO-Ru;
- к прогнозам модели COSMO-Ru, подвергнутым процедуре квазилинейной систематической коррекции (первая часть главы 2);
- к прогнозам ККП (вторая часть главы 2).

В первой части главы 3 определен список используемых предикторов, в том числе значения прогностических полей, включая предыдущие прогнозы на тот же срок (большей заблаговременности, чем корректируемый прогноз), а задача оптимизации формулируется математически.

Во второй части главы 3 проведена оптимизация параметров и гиперпараметров нейронных сетей, подобраны оптимальные архитектуры и количество нейронов нейронных сетей.

В третьей части главы 3 рассмотрена возможность использования индивидуальных параметров для каждой синоптической станции в количестве E штук. Результаты сравнения результатов коррекции при E от 0 (индивидуальные параметры не используются) до 4 приведены в таблице 1. Видно, что использование индивидуальных параметров имеет смысл только в случае, когда коррекции подвергаются оригинальные прогнозы COSMO-Ru6-ENA, а при предварительном применении КСК использование индивидуальных параметров не эффективно.

Таким образом, при предварительном использовании КСК или ККП достаточно иметь архив наблюдений за последние $T = 35$ дней, используемый для применения КСК или ККП. Для оптимизации же предложенного в главе 3 коррекции КНС нет необходимости иметь многолетний архив наблюдений на всех синоптических станциях, для которых прогноз будет составляться в оперативном режиме.

Таблица 1 – Величина, на которую уменьшилась среднеквадратическая погрешность ΔRMS на валидационном архиве прогнозов COSMO-Ru6-ENA по территории России (1686 станций) за 2020 г. при коррекции прогнозов для различных метеорологических параметров при использовании различного количества E индивидуальных параметров для каждой синоптической станции

COSMO-Ru6-ENA						COSMO-Ru6-ENA+KCK				
E	0	1	2	3	4	0	1	2	3	4
$T, ^\circ\text{C}$	0.290	0.315	0.345	0.349	0.364	0.128	0.139	0.142	0.144	0.147
$Td, ^\circ\text{C}$	0.379	0.410	0.438	0.443	0.457	0.120	0.124	0.122	0.125	0.127
$P_0, \text{гПа}$	0.291	0.329	0.334	0.325	0.354	0.012	0.015	0.012	0.012	0.013
$ \vec{U} , \text{м/с}$	0.291	0.374	0.388	0.386	0.390	0.038	0.038	0.039	0.038	0.038

В отличие от остальных глав, предложенная в главе 3 коррекция КНС является «черным ящиком», а поэтому в **четвертой части 3 главы** рассмотрен вопрос оценки *важности* (importance) различных используемых предикторов при вычислении поправок. Под важностью подразумевается наша оценка: насколько ухудшится качество прогноза при отбрасывании данного предиктора. Поскольку нейронная сеть является нелинейной функцией, вопрос оценки важности тех или иных используемых предикторов, используя лишь параметры уже обученной нейронной сети (без дополнительного обучения), является нетривиальным.

Классические решения этой задачи, например, метод class activation map [Zhou, Khosla et al., 2016], были разработаны для обработки изображений и предполагают, что значения всех предикторов (яркости различных пикселей изображения) распределены согласно одному и тому же вероятностному закону. Это предположение неверно для различных метеорологических полей (например, вероятностные распределения значений скорости ветра и температуры воздуха принципиально различны). Для оценки важности различных предикторов использован метод перестановок (permutation importance), примененный ранее в [Rasp, Lerch, 2018] для задачи оценки важности при коррекции ансамблевых прогнозов приземных метеорологических параметров.

Глава 4 посвящена предлагаемой квазилинейной неоднородной оптимальной интерполяции (КНОИ, кратко описана в [Вуков, 2021]) и её применениям для интерполяции поправок к прогнозам приземных метеорологических параметров по горизонтальным координатам.

В первой части главы 4 рассмотрено классическое решение задачи интерполяции метеорологических полей – метод оптимальной интерполяции [Гандин, 1963], реализованный диссертантом в рамках работы [Быков, Василенко и др., 2017].

Оптимальная интерполяция использует оценку корреляционной функции (КФ) $K(\vec{x}, \vec{y})$ интерполируемого поля поправок $\Delta X(\vec{x})$. Для применимости оптимальной интерполяции нужно обеспечить строгую положительную определенность $K(\vec{x}, \vec{y})$. Проверить положительную определенность КФ однородного поля можно согласно теореме Бохнера – Хинчина [Bochner, 1934], [Хинчин, 1938]. Для приземных метеорологических полей предположения об однородности поля являются весьма грубым, особенно в областях больших градиентов (вблизи атмосферных фронтов [Быков, Гордин, 2012], морского побережья, в горах, в мегаполисе [Varentsov, Samsonov, Demuzere, 2020]).

Следствие из теоремы Мерсера [Mercer, 1909] гарантирует для положительно-определенного симметричного оператора на связно компакте в $\Omega \subset \mathbb{R}^n$ существование **выравнивающего отображения** (другие названия: feature mapping, деформация) в некоторое гильбертово пространство (известное как **гильбертово пространство, воспроизводящее ядро**, reproducing kernel Hilbert space [Aronszajn, 1950]). КФ скалярного поля $\Delta X(\vec{x})$, $\vec{x} \in \Omega \subset \mathbb{R}^n$ удовлетворяет теореме Мерсера, и выравнивающее отображение $g(\vec{x})$ переводит поле $\Delta X(\vec{x})$ в однородное и изотропное:

$$K(\vec{x}, \vec{y}) = K(|g(\vec{x}) - g(\vec{y})|).$$

Выравнивающее отображение (деформация) аппроксимировалось с помощью кубических сплайнов [Sampson, 1992], [Anderes, Stein, 2008] и с помощью методов машинного обучения [Zammit-Mangion, Tin et al., 2019], [Xue, Wu, Sun, 2019]. Во всех этих работах авторы строили выравнивающее отображение, максимизируя логарифм правдоподобия рассматриваемой ковариационной модели. При такой оптимизации рассматривают лишь пары значений рассматриваемого поля в двух различных точках и предполагают, что значения интерполируемого случайного поля распределены согласно вероятностному распределению из заранее выбранного семейства. Однако этот выбор используемого семейства может повлиять на качество интерполяции.

Используемые на практике реализации метода оптимальной интерполяции метеорологических полей часто используют существенные предположения, влияющие на качество интерполяции:

- а) однородность и изотропность интерполируемого поля по горизонтальным координатам;

- б) распределение значений интерполируемого поля согласно определенному вероятностному распределению, например гауссовскому;
- в) отсутствие крупномасштабных трендов;
- г) линейность оператора интерполяции.

Диссертанту неизвестно о работах с использованием выравнивающего отображения в оперативных системах усвоения метеорологических данных. По-видимому, в настоящее время только в ансамблевых системах усвоения данных неоднородность метеорологических полей по горизонтальным координатам оценивается с учётом синоптической ситуации. Обзор различных методов усвоения данных в геофизике сделан в [Carrassi, Vocquet et al., 2018].

Во второй части главы 4 описана предлагаемая КНОИ, в которой эти три предположения заменены на более слабые. Предположение а) заменено на предположение о том, что неоднородности интерполируемого поля могут быть описаны некоторыми заранее заданными (быть может, меняющимися во времени) предикторами неоднородности. Предположения б) и в) не используются. Предположение г) заменено на предположение о представимости оптимального оператора интерполяции в некоторой конечно-параметрической квазилинейной форме. Такое обобщение должно существенно улучшить качество интерполяции метеорологических полей, не являющихся однородными, однако причины неоднородности которых известны. А также полей, значения которых распределены согласно негауссовскому вероятностному закону.

В диссертации предлагается методика оценки условного выравнивающего отображения. Эта методика общая для различных реализаций интерполируемого поля, но учитывающая **предикторы неоднородности** – поля, описывающие причины неоднородностей полей метеорологических параметров. Причинами неоднородности и анизотропности метеорологических полей являются: неоднородность граничных условий (подстилающей поверхности Земли, космического излучения); внутренняя неоднородность, связанная с областями больших градиентов метеорологических параметров – атмосферными фронтами [Быков, Гордин, 2012]. В данной работе использовались предикторы неоднородности: поля первого приближения рассматриваемых метеорологических параметров; расположение Солнца на небе; высота поверхности Земли над уровнем моря.

При построении условного выравнивающего отображения сложно обеспечить его инъективность. Одно из возможных решений: рассматривать выравнивающее отображение $g: \vec{x} \rightarrow (\vec{x}, f(\vec{x}))$, то есть являющееся графиком некоторой функции $f(\vec{x})$ [Bornn, Shaddick, Zidek, 2012]. В параграфе 4.1.4 предложено приближать эту функцию $f(\vec{x})$ посредством нейронной сети, принимающей на вход предикторы неоднородности поля поправок $\Delta X(\vec{x})$.

Чтобы отказаться от предположения о распределении значений интерполируемого поля согласно определенному статистическому закону, предлагается осуществлять минимизацию погрешности интерполяции в точку «пропущенной» станции напрямую, используя метод обратного распространения ошибки [Галушкин, 1974]. Метод обратного распространения ошибки позволяет отказаться от предположения об отсутствии крупномасштабных трендов в интерполируемом поле.

Предположение линейности оператора интерполяции можно ослабить, используя известные значения метеорологического поля в точках синоптических станций при вычислении выравнивающего отображения. Это приводит к рассмотрению квазилинейного оператора интерполяции.




Рисунок 2 – Сравнение средней абсолютной погрешности прогнозов температуры воздуха на высоте 2 м (ось ординат) в зависимости от заблаговременности (ось абсцисс) по модели COSMO-Ru в конфигурации COSMO-Ru6-ENA за июль 2020 г. по Азиатской части России (774 станции), и проинтерполированных в точку «пропущенной» станции согласно КНОИ (красные линии) и согласно ОИ (зеленые линии).

Параметры предлагаемой КНОИ оптимизированы (параграф 4.2.3) для интерполяции поправок к приземным прогностическим полям модели COSMO-Ru (температуры воздуха и точки росы на высоте 2 м, скорости ветра и скорости порывов ветра на высоте 10 м, давления, приведенного к уровню моря), вычисленным КСК (глава 2). А также для интерполяции квазилинейного комплексного прогноза (ККП) с первым приближением по модели COSMO-Ru в конфигурации COSMO-Ru6-ENA.

На рисунке 2 показаны результаты сравнения средней абсолютной погрешности прогнозов температуры воздуха на высоте 2 м по модели COSMO-Ru в конфигурации COSMO-Ru6-ENA за июль 2020 г. по Азиатской части России, и откорректированным прогнозам, полученных интерполяцией поправок в точку «пропущенной» синоптической

станции согласно КНОИ и по методу однородной и изотропной оптимальной интерполяцией (ОИ).

Сравнительная проверка (параграф 4.2.4) предлагаемой КНОИ и ОИ, показала, что предположение однородности и изотропности адекватно для поля давления, приведенного к уровню моря, а для остальных рассмотренных приземных метеорологических полей – только на равнинных территориях в зимний период.

Глава 5 посвящена сравнительным оценкам прогнозов от начального срока 00:00 ВСВ, рассчитанных по предлагаемым постпроцессингом в оперативном режиме в период с 1 октября 2020 г. по 31 марта 2021 г. Аналогичные сравнения за период с 1 мая по 30 сентября приведены в приложении А. Проведено сравнение качества полученных прогнозов приземных метеорологических параметров (температуры воздуха и точки росы на высоте 2 м, скорости ветра и скорости порывов ветра на высоте 10 м, давления, приведенного к уровню моря) с исходными прогнозами ЧМПП с заблаговременностью до 144 ч.


Проведенные численные эксперименты показали, что качество комплексного прогноза (рассчитанного ККП+КНС) за холодный период года в среднем эквивалентно качеству поправленных КСК+КНС прогнозов модели COSMO-Ru в конфигурации COSMO-Ru6ENA с заблаговременностью, меньшей на 1-1.5 суток, которое близко или чуть лучше, чем качество прогнозов лучшей из доступных ЧМПП.

Комплексный прогноз минимальной ночной и максимальной дневной температур сравнивался с соответствующими прогнозами по методу РЭП и с прогнозами синоптиков УГМС на трое суток. Качество комплексного прогноза близко к качеству прогнозов УГМС с заблаговременностью, меньшей на 1-2 суток и близко по качеству к прогнозу РЭП с заблаговременностью, меньшей на 1 сутки.

Сравнение средней абсолютной ошибки прогнозов минимальной ночной и максимальной дневной температур воздуха на высоте 2 м комплексного прогноза с прогнозами, размещаемых на сайтах meteoinfo.ru, gismeteo.ru, yandex.ru, foreca.com, rp5.ru, meteovesti.ru, weather.com показано на рисунке 3 (предоставлен Н.А. Светловой). Видно, что качество прогнозов по территории России на сайте комплексного прогноза занимает первое место при заблаговременности прогноза до 3 суток, а при заблаговременности 4-5 суток делит первое и второе место с сайтом weather.com.

а

Сравнительная оценка прогнозов температуры воздуха,
опубликованных на различных ИНТЕРНЕТ-сайтах
по Европейской территории России (33 города*)
Период осреднения: 01.10.2020 - 31.03.2021



б

Сравнительная оценка прогнозов температуры воздуха,
опубликованных на различных ИНТЕРНЕТ-сайтах
по Азиатской территории России (20 городов**)
Период осреднения: 01.10.2020 - 31.03.2021




Рисунок 3 – Результаты сравнения средней абсолютной ошибки комплексного прогноза минимальной ночной и максимальной дневной температур воздуха с прогнозами, представленных на интернет-сайтах за период с 1 октября 2020 г. по 31 марта 2021 г.:
а) по 33 городам в Европейской части России; б) по 20 городам в Азиатской части России.

В **заключении** обсуждаются полученные результаты, способы использования продукции, рассчитываемой по предлагаемым постпроцессингом, возможные применения разработанного постпроцессинга для выпуска других видов продукции, а также возможные пути развития и усовершенствования предложенного постпроцессинга.

В **приложении А** приведены оценки, аналогичные оценкам из главы 5, но для начального срока 12:00 ВСВ и для летнего периода (с 1 мая по 30 сентября 2021 г).

В **приложении Б** приведены примеры продукции, использующей прогнозы, рассчитанные по предлагаемыми в диссертации постпроцессингом.

В **приложении В** приведены отзывы синоптиков региональных УГМС и ЦГМС о продукции, рассчитываемой предлагаемым постпроцессингом и предоставляемой на сайте методического кабинета ФГБУ «Гидрометцентр России».

Результаты работы. Все заявленные цели были достигнуты. Разработана система постпроцессинга, которая:

- уточняет результаты численных прогнозов погоды одной или нескольких численных моделей прогноза;
- применима в случаях частичного отсутствия прогностической информации и (или) отсутствия (отбраковки) данных наблюдений за период $T=35$ дней;
- подготавливает прогнозы и в точках синоптических станций, и в виде полей на модельной сетке;
- применяется в оперативном режиме на доступных вычислительных системах (подготовка полей на сетках высокого разрешения осуществляется на GPU суперкомпьютера T-Platforms V6000).

Список работ, опубликованных по теме диссертации

Статьи в научных журналах, рекомендованных ВАК:

1. Быков Ф.Л. Гордин В.А. *Трехмерный объективный анализ структуры атмосферных фронтов*. // Известия РАН. Физика атмосферы и океана, 2012, № 48(2), с. 172—188.
Bykov Ph.L. Gordin V.A. *Objective Analysis of the Structure of Three-Dimensional Atmospheric Fronts* // Izvestia: Atmospheric and Oceanic Physics, 2012, № 48(2), p. 152-168.
2. Багров А.Н., Быков Ф.Л., Гордин В.А. *Комплексный прогноз приземных метеозлементов* // Метеорология и гидрология, 2014, № 5, с. 5—16.
Bagrov A.N. Bykov Ph.L. Gordin V.A. *Complex forecast of surface meteorological parameters* // Russian Meteorology and Hydrology, 2014, №39(5), p. 283—291.
<https://doi.org/10.3103/S106837391405001X>
3. Быков Ф.Л. Василенко Е.В. Гордин В.А. Тарасова Л.Л. *Статистическая структура поля влажности верхнего слоя почвы по данным наземных и спутниковых наблюдений*.

// Метеорология и гидрология, 2017, №6, с. 68—84.

Bykov Ph.L., Vasilenko E.V. Gordin V.A. Tarasova L.L. *The Statistical Structure of the Field of Surface Soil Layer Moisture from Ground-based and Satellite Observations* // Russian Meteorology and Hydrology, 2017, №42(6), p. 403—414.

<https://doi.org/10.3103/S1068373917060061>

4. Багров А.Н., Быков Ф.Л., Гордин В.А. *Схема оперативного краткосрочного комплексного прогноза ветра* // Метеорология и гидрология, 2018, №7, с.19-26.

Bagrov A.N. Bykov Ph.L. Gordin V.A. *Operative Scheme for the Short-range Complex Forecasting of Wind* // Russian Meteorology and Hydrology, 2018, №42(7), p. 436-443.

<https://doi.org/10.3103/S1068373918070026>

5. Багров А.Н. Быков Ф.Л. Гордин В.А. *Схема оперативного краткосрочного комплексного прогноза приземной температуры воздуха и влажности* // Метеорология и гидрология, 2018, №8, с.5-18.

Bagrov A.N. Bykov Ph.L. Gordin V.A. *Operative Scheme for the Short-range Complex Forecasting of Surface Air Temperature and Humidity* // Russian Meteorology and Hydrology, 2018, №43(8), p. 495-505. <https://doi.org/10.3103/S1068373918080010>

6. Быков Ф.Л. *Статистическая коррекция прогнозов погоды по модели COSMO с помощью нейронных сетей* // Метеорология и гидрология, 2020, №3, с. 5-20.

Bykov, F.L. *Statistical Correction of the COSMO Model Weather Forecasts Based on Neural Networks* // Russian Meteorology and Hydrology, 2020, №45, p. 141–152.

<https://doi.org/10.3103/S1068373920030012>

7. Розинкина И.А., Ривин Г.С., Бурак Р.Н., Астахова Е.Д., Алферов Ю.В., Блинов Д.В., Быков Ф.Л., Васькова Д.В., Волкова В.А., Воробьева Е.В., Зайко П.О., Жабина И.И., Недачина А.Ю., Прохареня М.И., Елисеев Г.В. *Формирование продукции систем негидростатического моделирования атмосферы COSMO-RuBy (Гидрометцентр России) и WRF-ARW (Белгидромет) для краткосрочного прогноза погоды* // Гидрометеорологические исследования и прогнозы, 2021, № 382, с. 6-29.

Статьи в изданиях, не входящих в перечень ВАК:

8. Алдухов О.А. Быков Ф.Л. Гордин В.А. *Крупномасштабные трехмерные корреляционные функции для атмосферы Земли* // Ярославский педагогический вестник, 2011, № 4, с. 36-43.

9. Bykov F.L. Gordin V.A. *Forecasting Moscow Ambulance Trips* // Higher School of Economics Research Paper, Series: Science, Technology and Innovation. № WP BRP 36/STI/2015. <http://www.hse.ru/data/2015/03/27/1096061578/36STI2015.pdf>

10. Быков Ф.Л. Василенко Е.В. Гордин В.А. Тарасова Л.Л. *Анализ влажности почвы по данным наземной сети и дистанционного спутникового зондирования* // Сборник тезисов докладов четырнадцатой всероссийской открытой конференции "Современные проблемы дистанционного зондирования Земли из космоса", Москва, 2016, с. 334.
11. Быков Ф.Л. Гордин В.А. *Краткосрочный прогноз часового потребления электроэнергии с учетом погоды для субъектов РФ* // Известия РАН: Энергетика, 2017, № 5, с. 47—56.
12. Быков Ф.Л. Василенко Е.В. Гордин В.А. Тарасова Л.Л. *Совместный оперативный анализ стационарных и спутниковых данных о влагозапасе почвы* // Материалы II Всероссийской научной конференции с международным участием «Применение средств дистанционного зондирования Земли в сельском хозяйстве», Санкт-Петербург, 2018, с. 279-284. <https://doi.org/10.25695/agrophysica.2018.2.18810>
13. Гордин В.А. Багров А.Н. Быков Ф.Л. *Оперативная схема краткосрочного прогноза погоды и ей приложения* // Международная конференция и школа молодых ученых по измерениям, моделированию и информационным системам для изучения окружающей среды: ENVIROMIS-2018, Томск, с. 93-94.
14. Быков Ф.Л. *Краткосрочный прогноз потребления электроэнергии с учетом температуры воздуха и кластеризацией потребителей* // Межвузовская научно-техническая конференция студентов, аспирантов и молодых специалистов им. Е.В. Арменского, Москва, 2019, с. 12-13.
15. Bykov Ph.L. *Neural networks based statistical correction of COSMO-Ru model surface weather forecasts* // ICCARUS 2020 Book of Abstracts, Offenbach, Germany, 2020, p. 47-48. https://doi.org/10.5676/DWD_pub/nwv/iccarus_2020
16. Багров А.Н. Быков Ф.Л. Гордин В.А. *Схема комплексного прогноза погоды по территории стран СНГ на срок до 6 суток* // Сборник тезисов Международной научно-практической конференции, посвященной 90-летию Российского государственного гидрометеорологического университета, 2020, с. 122-123.
17. Bykov Ph.L. *Optimal interpolation of inhomogeneous fields using neural networks* // Research activities in Earth system modelling (Blue Book), 2021, p. 1-03.
18. Bykov Ph.L. *Correction the COSMO-Ru fields in the boundary layer and troposphere using the convolutional neural network* // ICCARUS 2022 Book of Abstracts, Offenbach, Germany, 2022, p. 65. https://doi.org/10.5676/DWD_pub/nwv/iccarus_2022