

Развитие методов и технологий оперативного усвоения данных метеорологических наблюдений в Гидрометцентре России

М. Д. Цырульников*, Д. Р. Гайфулин*, П. И. Свиренко*,
А. Е. Сотский*, С. А. Гаврилова*, А. Б. Успенский**

Дается краткое описание функционирующей системы оперативного усвоения данных метеорологических наблюдений Гидрометцентра России и приводятся результаты работ по ее развитию. Основное направление развития — создание оригинальной ансамблево-вариационной системы усвоения данных с привлечением методов нейросетевого моделирования. Оригинальность заключается в новой схеме многомасштабного сверточного анализа. Приводятся результаты тестирования новой методики усвоения данных на двумерной задаче. В численных экспериментах сверточный анализ показал более высокую точность, чем традиционный ансамблево-вариационный подход. Описывается новая многомасштабная методика и приводятся результаты ее тестирования. Второе направление развития — повышение эффективности усвоения данных спутниковых наблюдений. Приводятся результаты восстановления поля сплоченности морского льда по данным микроволновых радиометров AMSR2 и MTBЗА-ГЯ с использованием методов машинного обучения. Описывается методика и приводятся результаты усвоения данных спутниковых наблюдений, поступающих с существенной задержкой.

Ключевые слова: усвоение данных, нейросетевое моделирование, спутниковые наблюдения, точность прогноза, многомасштабный анализ.

DOI: 10.52002/0130-2906-2024-7-108-121

1. Введение

Для старта численной модели прогноза погоды необходимы начальные данные. Их производят системы усвоения данных, формируя оценки текущих метеорологических и других полей по настоящим и прошлым наблюдениям. Системы усвоения данных работают циклически: на каждом цикле усваиваются текущие наблюдения на фоне краткосрочного прогноза, который несет информацию о прошлых наблюдениях. Ввиду хаотичности атмосферы, приводящей к росту ошибок в начальных данных, точность прогноза существенно зависит от точности начальных полей. Это диктует необходимость оптимизации существующих и создания новых, более совершенных методов и технологий усвоения данных наблюдений.

* Гидрометеорологический научно-исследовательский центр Российской Федерации; e-mail: mik.tsyrulnikov@gmail.com (Цырульников Михаил Давыдович).

**Научно-исследовательский центр космической гидрометеорологии “Планета”.

В ведущих метеорологических центрах применяются следующие методы усвоения данных. Наиболее успешным методом по-прежнему является так называемое четырехмерное усвоение данных (4D-Var) — несмотря на то что эта технология была разработана четверть века назад [16]. В современном варианте 4D-Var комбинируется с ансамблевым подходом, в результате чего критически важная матрица ковариаций ошибок первого приближения (краткосрочного прогноза) зависит от текущей метеорологической ситуации и локальной плотности усваиваемых наблюдений. Этот вариант получил название “гибридный 4D-Var”. В Европейском центре среднесрочных прогнозов погоды он реализован в виде “ансамбля усвоений данных” (Ensemble of Data Assimilations, EDA, [9]). Однако технологии на основе 4D-Var весьма дороги в разработке и поддержке ввиду необходимости иметь так называемую сопряженную модель. Поэтому получили распространение относительно более дешевые технологии на основе ансамблево-вариационного подхода (EnVar). Им не нужна сопряженная модель, однако они требуют поддержки двух систем — вариационной и ансамблевого фильтра Калмана [10, 21].

В Гидрометцентре России в течение ряда лет функционирует оперативная система глобального усвоения данных на основе так называемого трехмерного усвоения данных (3D-Var). Ее модернизация будет производиться с использованием нового подхода, который мы называем “многомасштабным сверточным анализом”. Этот подход основан на ансамблевом принципе формирования статистики поля ошибок первого приближения и на вариационном методе решения системы уравнений оптимального анализа, но он не требует поддержки двух систем — вариационной и ансамблевой (в этом смысле он следует методу EDA и отличается от EnVar). В то же время он не требует сопряженной модели (так же, как EnVar). В данной статье мы обрисуем состояние разработки новой системы усвоения на основе многомасштабного сверточного анализа.

Помимо работ по созданию системы усвоения данных следующего поколения, также разрабатываются методы и технологии более эффективного усвоения данных спутниковых метеорологических наблюдений, в том числе производимых на российских полярно-орбитальных спутниках серии “Метеор-М”. В данной статье представлены результаты недавних работ по восстановлению поля сплоченности морского льда по данным микроволновых спутниковых наблюдений, а также по созданию технологии усвоения данных спутниковых наблюдений, поступающих с большой задержкой.

2. Оперативная система усвоения данных

Оперативная технология глобального усвоения данных основана на оригинальном вариационном анализе, описанном в работах [1, 7, 8]. Оригинальность методики усвоения основана на модели пространственной авторегрессии и скользящего среднего, с помощью которой задаются ковариации ошибок первого приближения и которая позволила построить весьма экономичную вычислительную схему решения уравнений анализа. Технология функционирует в циклическом режиме с моделью ПЛАВ [4], а также в статическом режиме, в котором в качестве первого приближения используется 6-часовой прогноз НСЕР. В циклическом режиме формиру-

ются поля анализа на модельной сетке на 51 уровне с горизонтальным разрешением 20 км, в статическом режиме — на сетках 0,5 и 0,25 (с 37 и 40 уровнями по вертикали соответственно). Трехмерные поля анализа температуры, компонентов горизонтального ветра и влажности, а также приземные поля давления, температуры, ветра и влажности вычисляются каждые 6 ч, время готовности — через 1 ч 45 мин после срока анализа.

Усваиваются данные следующих видов наблюдений: радиозондовых (температура, компоненты горизонтального ветра, влажность), наблюдений на приземных метеостанциях (давление, температура, горизонтальный ветер, влажность), а также на кораблях и буях (давление, температура и горизонтальный ветер), самолетных наблюдений (температура, горизонтальный ветер), спутниковых микроволновых наблюдений в каналах атмосферного зондирования (AMSU-A, MHS и MTBZA-ГЯ), спутниковых гиперспектральных инфракрасных наблюдений (IASI, ИКФС-2), спутниковых радиозатмененных наблюдений показателя преломления воздуха (производимых в ROM SAF Eumetsat по данным измерений GRAS), скаттерометрических спутниковых наблюдений за приводным ветром (производимых по данным ASCAT в Королевском метеорологическом институте Нидерландов) и спутниковых наблюдений за ветром по движению облаков и полям влажности (Geo, Leo и LeoGeo, производимых по данным геостационарных и полярно-орбитальных спутников в Кооперативном институте спутниковых метеорологических исследований, CIMMS, США).

3. Разработка сверточного ансамблево-вариационного анализа

В основу нового сверточного ансамблево-вариационного анализа положена модель трехмерного случайного поля ошибок первого приближения [20]. Модель формулируется непосредственно для случайного поля ошибок первого приближения, что обеспечивает положительную определенность соответствующей ковариационной матрицы — свойство, необходимое для работоспособности алгоритма анализа. Модель формулируется для полей с непрерывными пространственными координатами, с тем чтобы облегчить дальнейшее задание модели с произвольным конечным пространственным разрешением. В одноэлементной постановке задачи постулируется, что поле ошибок первого приближения (x) (где x — вектор пространственных координат) удовлетворяет общей модели линейного процесса:

$$(x) = w(x, y) (y) dy. \quad (1)$$

Здесь y — точка в области анализа, $w(x, y)$ — неоднородное сверточное ядро (весовая функция), (y) — пространственный белый шум. Формулировка многоэлементной модели будет осуществлена в дальнейшем с помощью линейных преобразований нескольких одноэлементных моделей.

Уравнение (1) описывает неоднородную пространственную свертку, однако в таком виде существует множество сверточных ядер, дающих одну и ту же неоднородную (т. е. пространственно нестационарную) ковариационную функцию $B(x, x)$, где x и x — пространственные точки. Поэтому чтобы модель была идентифицируема, вводится ряд ограничений на сверточное ядро $w(x, y)$. Эти ограничения также служат

средством регуляризации модели, ограничивая ее эффективное число степеней свободы, стабилизируя процесс ее оценивания по ансамблю первых приближений (ансамблю реализаций случайного поля) и предотвращая так называемый оверфиттинг в условиях реалистичного (т. е. неизбежно малого) объема ансамбля.

Во-первых, постулируется, что ядро $w(x, y)$ локально изотропно:

$$w(x, y) = u(x, |x - y|) \quad (2)$$

для некоторой функции $u(x, |x - y|)$ — расстояние между точками x и y . Во-вторых, мы требуем, чтобы функция $u(x, |x - y|)$ была положительно определена как функция для любого x . Это ограничение продиктовано требованием локальности сверточного ядра $u(x, |x - y|)$, а также его единственности. Далее, накладывается ограничение гладкости $u(x, |x - y|)$ как функции x , что означает, что локальная структура случайного поля медленно изменяется в пространстве по сравнению с изменением сверточного ядра как функции расстояния $|x - y|$. И наконец, вводится понятие локального спектра $f_n(x)$ (где n — пространственное волновое число) как преобразования Фурье — Лежандра (в сферической геометрии) функции $u(x, |x - y|)$ по ее аргументу x с требованием гладкости этого локального спектра. Гладкий спектр обеспечивает быстрое убывание пространственных корреляций с расстоянием и, таким образом, снимает потребность в эмпирических приемах типа локализации ковариаций.

Более подробное изложение предлагаемой методики можно найти в работе [20], где также описывается алгоритм оценивания модели по ансамблю полей первого приближения. Вкратце методика оценивания локального спектра в каждой точке сетки анализа состоит из следующих шагов. Во-первых, вычисляются поля ансамблевых возмущений (отклонений от ансамблевого среднего) $\hat{v}_j^{(m)}$, где $m = 1, \dots, M$ — номер ансамблевой реализации, M — объем ансамбля, x — точка сетки анализа. Во-вторых, поля ансамблевых возмущений подвергаются пространственной полосовой фильтрации в нескольких (числом J) полосах. В результате получаются поля профильтрованных ансамблевых возмущений $\hat{v}_j^{(m)}(x)$, где $j = 1, \dots, J$ — номер спектральной полосы. В-третьих, вычисляется выборочная дисперсия профильтрованных полей $\hat{v}_j(x)$ в каждой точке сетки анализа x . Наконец, решается обратная задача восстановления локального спектра $f_n(x)$ по набору полосовых дисперсий $\hat{v}_j(x)$ в каждой точке сетки анализа независимо. Наиболее эффективным способом решения этой обратной задачи оказалось применение нейросети. Оптимальная конфигурация нейросети имела два полно связных скрытых слоя по 120 нейронов в каждом и функцию активации, известную как Relu [20].

Полученные оценки локальных спектров пересчитываются в сверточное ядро u , которое затем используется для вычисления квадратного корня W из матрицы ковариаций B , опущенного на сетку анализа случайного поля :

$$B = WW^T, \quad (3)$$

T означает транспонирование. При этом постулируется, что случайное поле имеет ограниченную спектральную полосу с максимальным волновым числом, равным $/h$, где h — шаг сетки анализа. Это позволяет опускать поле W на сетку анализа без потерь и искажений.

Наличие факторизации (3) позволяет построить предобусловливатель при решении системы уравнений анализа. Помимо предобусловливателя, другим фактором, ведущим к вычислительно эффективному алгоритму анализа, является независимое (т. е. распараллеливаемое) применение нейросети для восстановления локального спектра в каждой точке сетки анализа. Технологически важным фактором является вариационный характер алгоритма, что дает возможность применения в новом анализе элементов уже имеющегося вариационного солвера.

Новая методика ансамблевого анализа была протестирована в численных экспериментах в двумерном (на сфере) одноэлементном варианте с “синтетическими” полями ошибок первого приближения. Подробное описание постановки экспериментов можно найти в работе [20]. Здесь приводятся их результаты в терминах среднеквадратичных ошибок следующих анализов: 1) True-B — оптимальный анализ, имеющий доступ к истинной матрице ковариаций ошибок первого приближения B_{true} ; 2) Mean-B — вариационный анализ со средней по многим реализациям (“климатологической”) матрицей B_{mean} ; 3) EnKF-B — анализ стохастического ансамблевого фильтра Калмана с локализованной выборочной матрицей ковариаций B_{EnKF} ; 4) Hybrid-B — традиционный гибридный ансамблево-вариационный анализ с матрицей ковариаций $B_{\text{hybrid}} = (1 - w_e)B_{\text{mean}} + w_e B_{\text{EnKF}}$, где вес ансамблевых ковариаций w_e был выбран по результатам экспериментов равным 0,5; 5) LSEF-B по NN — новый предлагаемый анализ без использования нейросети; 6) LSEF-B NN — новый анализ с использованием нейросети для восстановления локальных спектров.

Как видно на рис. 1, новый анализ превосходит протестированные анализы, основанные на традиционных подходах. Особенно велико преимущество при малых объемах ансамбля. Также необходимо отметить значительный положительный эффект от применения нейросети в алгоритме анализа.

Кроме проведения вышеописанных экспериментов, также протестирована новая методика в циклической системе усвоения данных с прогностической моделью, заданной на окружности [19]. Результаты, приведенные в работе [20], показали преимущество новой методики анализа и в этой постановке.

При реализации предложенной методики усвоения в реальной циклической системе усвоения данных планируется регуляризовать алгоритм вычисления локальных спектров путем организации так называемо-

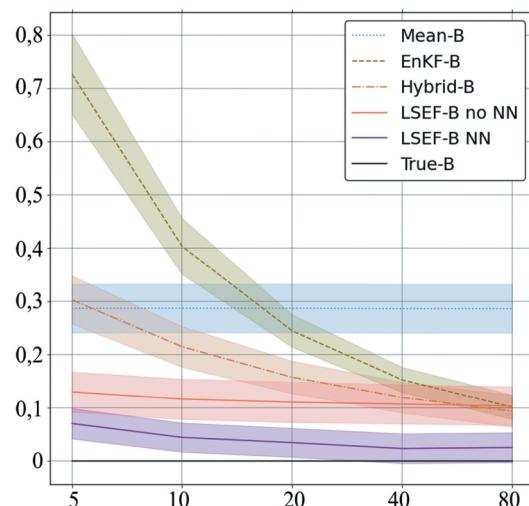


Рис. 1. Среднеквадратичные ошибки шести анализов, указанных в легенде (расшифровка обозначений приведена в тексте). Затенением показаны 90%-ные доверительные интервалы. По оси абсцисс — объем ансамбля.

го вторичного фильтра, в котором будут использованы локальные спектры, вычисленные на предыдущем цикле, в качестве первого приближения при их вычислении по ансамблю прогнозов на текущем цикле — аналогично тому, как вторичный фильтр применен в работе [18] для циклического оценивания ковариационных матриц полей ошибок первого приближения.

4. Разработка многомасштабного сверточного анализа

Описанный в предыдущем разделе подход к моделированию статистики ошибок первого приближения с использованием сверточной модели случайного поля в численных экспериментах показал себя эффективным и устойчивым методом ансамблево-вариационного усвоения данных. Однако в задачах высокой размерности, которые возникают при усвоении данных о процессах в атмосфере и океане, этот метод требует модификации для достижения вычислительной эффективности. Предлагается обобщение, ведущее к многомасштабному сверточному анализу. На данном этапе разработана и протестирована методика многомасштабного сверточного анализа в одномерном случае. Она кратко изложена ниже.

При разработке методики предполагалось, что в ближайшие 10 лет горизонтальное разрешение глобальных атмосферных моделей достигнет 3—5 км, так что понадобится “целевое” разрешение сетки анализа примерно 10 км (сетка анализа всегда выбирается в 2—4 раза более редкой, чем сетка прогностической модели, поскольку реальное разрешение моделей прогноза погоды в 3—4 раза ниже их номинального разрешения [17, 22]).

Моделируется случайное поле ошибок первого приближения (x) в виде суммы N взаимно независимых случайных полей $_s(x)$:

$$(x) = \sum_{s=1}^N _s(x). \quad (4)$$

Каждое поле $_s(x)$, соответствующее масштабу (или скейлу) s , моделируется сверточной моделью (см. уравнения (1) и (2)). Принципиальным моментом является то, что каждое поле $_s(x)$ имеет ограниченную спектральную полосу с полушириной $2^{s-N}/h$, где, напомним, h — шаг сетки анализа. То есть спектральная полоса максимально широка для последнего скейла и сужается вдвое при переходе от скейла s к скейлу $s - 1$. Соответственно, поле на последнем скейле $_N(x)$ представляется как сеточная функция непосредственно на сетке анализа, а поля на более низких скейлах представляются на более редких сетках. Сетка разрежается вдвое при переходе от скейла s к скейлу $s - 1$, так что шаг сетки на скейле равен $h_s = 2^{N-s}h$. Если $N = 10$, то в одномерной задаче число точек сетки, на которой представлено поле (x) (т. е. сетка на первом скейле), меньше числа точек сетки анализа в $2^9 = 512$ раз, а в двумерной задаче — в $2^{18} \approx 10^6$ раз. В трехмерной задаче уменьшение числа точек сетки анализа на первом скейле будет еще кратно ниже. Такое радикальное разрежение сетки анализа позволяет строить вычислительно реализуемый алгоритм для практических задач очень высокой размерности.

Проблема одномасштабного вычислительного алгоритма, кратко описанного выше в разделе 3, в том, что далекие корреляции поля ошибок первого приближения (x) приводят к существенной заполненности матрицы W . В результате вычислительный алгоритм оказывается слишком мед-

ленным. Идея его ускорения, реализованная в многомасштабном (многосеточном) анализе, состоит в том, чтобы далекие корреляции воспроизводились полями $s(x)$ на первых скейлах. Эти скейлы представлены на редких сетках, поэтому соответствующие матрицы W_s будут вычислительно “легкими”. Последние же скейлы, представленные полями на густых сетках, отвечают за короткие корреляции — так что заполненность соответствующих матриц W_s будет малой. В результате вычислительная нагрузка при работе со всеми матрицами W_s оказывается низкой, что и ведет к вычислительно быстрому алгоритму.

Для реализации этого алгоритма моделируется поле $s(x)$ (на каждом масштабе s) таким образом, чтобы оно имело очень короткий радиус корреляции в терминах шагов соответствующей сетки. В одномерном случае (на единичной окружности) шаблон сверточного оператора на всех скейлах, кроме самого первого, состоит всего из пяти точек сетки. В двумерном случае это соответствует ненулевым значениям сверточного ядра в круге радиуса $2h_s$, где h_s — шаг используемой квазиравномерной сетки на сфере на масштабе s . В результате носитель дискретного сверточного оператора на сфере будет состоять примерно всего лишь из 4–13 точек.

Реализованный алгоритм состоит в последовательной подгонке, начиная с последнего скейла, дискретных сверточных моделей. Конкретно на скейле $s = N, N - 1, \dots$ ищется модель вида

$$(s) = \sum_{p=1}^P u_p^{(s)} j_p^{(s)}, \quad (5)$$

где j обозначает индекс точки сетки; $u_p^{(s)}$ — коэффициенты дискретного сверточного оператора (неотрицательные вещественные числа, такие что $u_p^{(s)} \geq 0$), $P = 2$ — порядок дискретной свертки, а $j_p^{(s)}$ — дискретный белый шум на единичной окружности (независимые нормально распределенные случайные величины с математическим ожиданием 0 и дисперсией 1).

Коэффициенты сверточного фильтра $u_p^{(s)}$ выбираются исходя из целевого (локального) спектра f_n (где, напомним, n — волновое число) случайного поля x). Целевой спектр в реальности будет оцениваться по ансамблевой статистике, а в данном случае тестирования алгоритма считается заданным параметрической моделью

$$f_n = \frac{1}{1 + (n/\sigma)^2}, \quad (6)$$

где σ — параметр, отвечающий за масштаб длины случайного поля, а n — параметр формы спектра (и формы пространственной ковариационной функции $B(x)$ поля x).

Начиная с последнего скейла $s = N$, где целевой спектр $f_n^{(s)}$ полагается равным f_n , коэффициенты $u_p^{(s)}$ вычисляются исходя из требования, чтобы модельный спектр $\hat{f}_n^{(s)}$, отвечающий модели (5), и его производная (конечная разность) совпадали с целевым спектром $f_n^{(s)}$ и его производной на обоих концах правой половины скейла. Если модельный спектр не превышает целевой спектр, то $\hat{f}_n^{(s)}$ вычитается из $f_n^{(s)}$ и разность

$$f_n^{(s-1)} - f_n^{(s)} - \hat{f}_n^{(s)}$$

обрабатывается как новый целевой спектр f_n на следующем по убыванию скейле $s = 1$. Процесс продолжается, пока не достигнут первый скейл $s = 1$ или после вычитания $f_n^{(s)}$ остаточный спектр $f_n^{(s-1)}$ становится существенно отрицательным. В последнем случае сам факт того, что на скейле s целевой спектр $f_n^{(s)}$ оказался более мелким, чем модельный спектр $\hat{f}_n^{(s)}$, означает, что пространственный масштаб целевого спектра на скейле s маленький и, значит, целевой спектр может быть непосредственно смоделирован сверточной моделью, в которой сверточное ядро вычислено как обрезанное обратное преобразование Фурье $f_n^{(s)}$.

Пример качества подгонки спектра вышеописанной многомасштабной моделью приведен на рис. 2, где можно видеть процесс последовательного приближения целевого спектра масштабами, начиная с 5-го. Окончательная аппроксимация — кривая 6 — очень близка к целевому спектру.

Таким образом, предложенная многомасштабная модель случайного поля была успешно идентифицирована в одномерном случае для модельного целевого спектра, это демонстрирует работоспособность предложенной концепции. Дальнейшая работа будет включать переход к двумерному и трехмерному полям и к многоэлементной задаче.

5. Восстановление поля сплоченности морского льда по микроволновым спутниковым наблюдениям

Данные о ледовой обстановке играют существенную роль в прогнозе погоды, так как наличие или отсутствие льда изменяет радиационные свойства подстилающей поверхности и влияет на поверхностные потоки тепла, влаги и импульса. Это диктует необходимость возможно более точного задания поля морского льда при численном моделировании атмосферных процессов.

Важнейшей характеристикой морского льда является его сплоченность (концентрация), понимаемая как отношение площади ячейки модельной сетки, занятой льдом, к ее общей площади. Ввиду малого количества контактных наблюдений в полярных областях, для восстановления поля сплоченности морского льда используются спутниковые измерения уходящей радиации в разных диапазонах длин волн. В данной работе используются данные спутниковых микроволновых измерений в низкочастотных (6—24 ГГц), так называемых сканерных каналах, измеряющих излучение системы Земля — атмосфера в окне прозрачности атмосферы. По сравнению с измерениями спектрометров видимого и инфракрасного диапазонов спек-

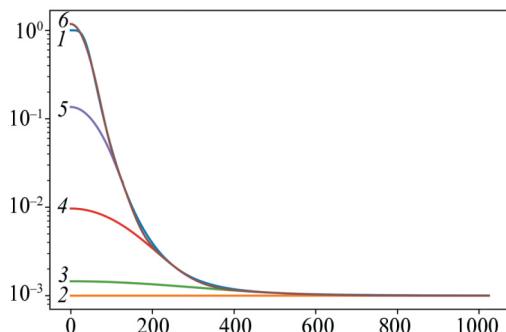


Рис. 2. Целевой спектр (1) и накопленные спектры полей на масштабах: 2 (2), 4 и 5 (3), 3—5 (4), 2—5 (5), 1—5 (6). По оси абсцисс — волновое число.

тра, преимуществами микроволновых сканерных измерений является “всепогодность” (малое влияние облачности) и независимость от освещенности Солнцем, недостатком — сравнительно низкое пространственное разрешение. Отметим, что такими же преимуществами обладает спутниковая радиолокационная съемка, но для нее проблема — обеспечение глобального покрытия.

Физическую основу детектирования ледяного покрова морей составляют различные электромагнитные свойства морского льда и воды, что приводит, в частности, к отличию коэффициентов излучения морского льда и морской воды, а также к разным величинам спектральных и поляризационных соотношений между измерениями над льдом и над открытой водой. Так, в указанном диапазоне длин волн излучательная способность значительно больше у льда по сравнению с водой, а степень поляризации значительно больше у воды. В работе [2] представлен обзор физико-эмпирических алгоритмов построения оценок сплоченности морского льда по данным спутниковых микроволновых радиометров, а в работе [3] дано описание предложенного нами алгоритма оценивания сплоченности морского льда по данным спутникового микроволнового радиометра МТВЗА-ГЯ.

Для решения задачи восстановления поля сплоченности морского льда по данным микроволновых спутниковых наблюдений был выбран универсальный эмпирический подход на основе нейросетевого моделирования [12]. На входе нейросети — данные измерений (антенна температура) во всех частотных каналах в окне прозрачности атмосферы в интервале ± 12 ч. На выходе — число от 0 до 1, содержащее оценку сплоченности морского льда в данном пикселе. Для обучения и валидации был использован 6-часовой прогноз NCEP (принимаемый за истину) [13]. Стоит отметить, что использование в нейросети в качестве предикторов значений антенной температуры вместо общепринятого использования яркостной температуры позволяет избежать влияния погрешностей, вносимых процедурой внешней калибровки каналов МТВЗА-ГЯ (необходима в дополнение к бортовой радиометрической калибровке для перехода от антенной к яркостной температуре [5]). Как показано в работе [6], при стабильном функционировании аппаратуры МТВЗА-ГЯ на спутнике “Метеор-М” № 2-2 и применении эмпирического подхода к интерпретации спутниковых данных необходимость внешней калибровки отпадает.

Нейросеть построена на базе библиотеки для глубокого обучения Keras на платформе TensorFlow [14]. Программный код написан на языке программирования Python. Архитектура и гиперпараметры нейросети были подобраны эмпирически. В модели используется два скрытых слоя из 512 нейронов каждый, в качестве функции активации используются Relu для первого слоя и Selu для второго. Для регуляризации сети использован метод dropout, при котором случайным образом исключается некоторая доля (0,15 в нашем случае) нейронов во время обучения. Поскольку выход сети должен иметь величину от 0 до 1, на последнем слое используется функция активации hard sigmoid. В качестве функции потерь использовалась квадратичная норма отклонения от “истины”, метод оптимизации — Adam [12].

Для восстановления поля сплоченности морского льда использовались данные радиометра AMSR2 [15], установленного на японском спутнике

GCOM-W, и радиометра МТВЗА-ГЯ [5, 11], установленного на российском спутнике “Метеор-М” № 2-2. Использовались каналы МТВЗА-ГЯ, отвечающие частотам 10,65, 18,7 и 23,8 ГГц (всего шесть каналов, учитывая, что каждой частоте соответствуют два канала с разной поляризацией) и каналы 6,9, 7,3, 10,7, 18,7 ГГц для AMSR2 (всего восемь каналов также с учетом разной поляризации). Разрешающая способность (линейный размер поля зрения прибора, излучение которого существенно влияет на измеренную яркостную температуру) данных радиометров на частоте 10,65 ГГц составляет примерно 32 км для AMSR2 и 133 км для МТВЗА-ГЯ. Для исключения влияния суши не учитывались наблюдения, имеющие более 1% суши в поле зрения прибора.

Анализ поля сплоченности проводился один раз в сутки. Из-за высокой густоты данных наблюдений МТВЗА-ГЯ (соседние пиксели отстоят друг от друга примерно на 15 км) применяется процедура прореживания: выбирается каждое третье наблюдение в каждой третьей строке. Для каждой точки полярных областей регулярной широтно-долготной сетки учитывались все спутниковые наблюдения в радиусе R (равном 30 км в случае AMSR2 и 80 км в случае МТВЗА-ГЯ), и подавались на вход нейросети средние значения с весами, пропорциональными $\exp(-r_i/R)$, где r_i — расстояние i -го наблюдения до центра ячейки сетки анализа. Если ни одного наблюдения не было найдено, радиус поиска увеличивался. В дальнейшем для восстановления поля льда в ячейках сетки, не покрытых наблюдениями, планируется привлекать поле сплоченности, восстановленное на предыдущих циклах усвоения данных, а также обучать нейросеть восстанавливать поле льда с известной долей суши в поле зрения прибора.

Нейросеть сначала обучалась трансформировать полученные осредненные данные наблюдений в сплоченность льда, а затем использовалась как эмпирическая модель для решения этой обратной задачи. Рассматривались только точки широтно-долготной сетки, расположенные к северу от 40° с. ш. или к югу от 40° ю. ш., поскольку между этими двумя параллелями морской лед не встречается. Размер как обучающей, так и тестовой выборки составлял порядка 350 тысяч.

Типичные результаты представлены на рис. 3 для арктической области за 15 апреля 2022 г., срок 12 ч ВСВ. Можно видеть, что нейросеть достаточно хорошо восстанавливает поле сплоченности морского льда по данным наблюдений каждого из двух спутниковых радиометров. Восстановление по данным AMSR2 дает несколько более высокое разрешение и большую точность по сравнению с восстановлением по данным МТВЗА-ГЯ. Среднеквадратичные ошибки равны 0,074 для AMSR2 и 0,083 для МТВЗА-ГЯ. Смещения были пренебрежимо малы. Аналогичные результаты были получены для антарктической области.

В дальнейшем планируется оценить работоспособность схемы восстановления сплоченности морского льда в разные сезоны, а также исследовать чувствительность прогнозов погоды к конфигурации и параметрам схемы и по результатам этого исследования решить, требуются ли усовершенствования вышеописанной схемы в сторону учета пространственной и временной связности поля для повышения точности восстановления, в особенности в прибрежной зоне и в переходные сезоны.

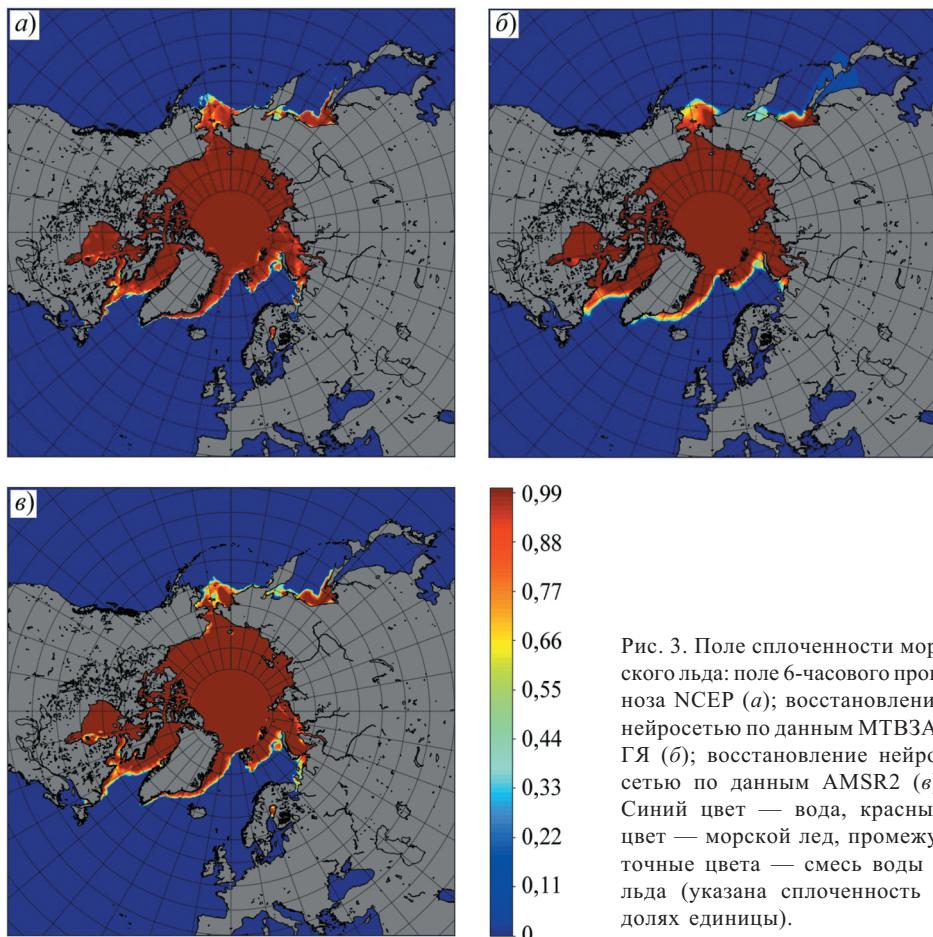


Рис. 3. Поле сплоченности морского льда: поле 6-часового прогноза NCEP (а); восстановление нейросетью по данным МТВЗА-ГЯ (б); восстановление нейросетью по данным AMSR2 (в). Синий цвет — вода, красный цвет — морской лед, промежуточные цвета — смесь воды и льда (указана сплоченность в долях единицы).

6. Усвоение данных наблюдений, поступающих с существенной задержкой

Стандартным подходом при оперативном усвоении запаздывающих наблюдений является так называемый “поздний анализ”, в котором усваиваются данные наблюдений, не пришедшие к моменту начала работы оперативного анализа. Поздний анализ повторяет оперативный анализ, но считается на несколько часов позже. Поля позднего анализа служат в качестве начальных данных для краткосрочного прогноза, вычисляющего первое приближение для следующего цикла усвоения. Таким образом, цикл усвоения состоит из позднего анализа и краткосрочного прогноза. Оперативный (ранний) анализ находится вне цикла и просто использует вычисленный в цикле усвоения краткосрочный прогноз в качестве своего первого приближения. Таким образом, первое приближение у раннего и позднего анализов одинаковое, но количество усваиваемых наблюдений различно (больше — у позднего анализа).

Возникла ситуация, при которой запаздывание прихода данных наблюдений МТВЗА-ГЯ со спутника “Метеор-М” № 2-2 оказалось в некоторых

случаях значительно больше, чем интервал между временем отсечения (время окончания отбора наблюдений) позднего анализа и расчетным временем анализа (7 ч). Во избежание потери этих данных наблюдений была реализована технология с ретроградными циклами усвоения. На каждом цикле повторялся не только последний анализ (поздний анализ повторяет ранний анализ, но с увеличенным числом наблюдений), но и несколько предыдущих циклов усвоения. При 6-часовом цикле технология усвоения данных наблюдений, поступающих с большой задержкой, предусматривает на каждом цикле усвоения пересчет от одного до четырех циклов усвоения. Таким образом, усваиваются данные наблюдений с задержкой поступления вплоть до суток.

Чтобы понять смысл такой методики усвоения, представим, что все наблюдения приходят с задержкой (от 10 до 24 ч). Тогда в традиционной технологии с ранним и поздним анализом ни одного наблюдения в 6-часовое “окно усвоения” в оперативном режиме попадать не будет (так как “окно” отбора текущих наблюдений начинается на 3 ч раньше расчетного времени анализа плюс 7 ч проходит до начала счета позднего анализа) и прогноз, стартующий с начальных данных, формируемый такой системой усвоения, потеряет всякую ценность через несколько дней. В описанной выше технологии в срок усвоения T будут усвоены все данные наблюдений со временем измерения вплоть до $T - \Delta T$, и только в интервале времени от $T - \Delta T$ до T (т. е. в течение последних 6—24 ч перед прогнозом) усвоения данных не будет. То есть фактическая заблаговременность прогноза просто увеличится примерно на ΔT . Учитывая высокое качество современных прогностических моделей, потерю точности прогноза за счет увеличения заблаговременности на 6 ч можно считать допустимой. Увеличение фактической заблаговременности на 24 ч существенно ухудшит прогноз, но это лучше, чем ничего.

Чтобы протестировать, насколько хуже становится прогноз в зависимости от времени запаздывания данных наблюдений, были проведены следующие эксперименты. Было смоделировано 10 сценариев поступления данных наблюдений: во-первых, пять сценариев, при которых все спутниковые наблюдения поступают (1) без задержки, (2) с задержкой 6 ч, (3) с задержкой 12 ч, (4) с задержкой 18 ч и (5) с задержкой 24 ч; и во-вторых, пять сценариев, при которых только данные радиационных спутниковых наблюдений (наблюдения уходящего излучения системы Земля — атмосфера) поступают с теми же задержками от 0 до 24 ч. Циклическое усвоение данных было проведено с 1 по 10 августа 2023 г. Среднеквадратичные ошибки суточного прогноза вычислялись путем сравнения с оперативным анализом Гидрометцентра России и осреднялись по внетропической зоне (выше 20° Северного полушария и по датам от 6 августа, срок 0 ч ВСВ, до 10 августа, срок 12 ч ВСВ). Прогнозы рассчитывались каждые 12 ч.

Результаты прогнозов геопотенциала поверхности 500 гПа представлены на рис. 4, где задержка поступления 30 ч означает, что усвоение данных производилось в отсутствие вышеописанной схемы усвоения запаздывающих данных наблюдений и, таким образом, эти наблюдения не влияли на процесс усвоения данных.

Анализ рис. 4 позволяет сделать следующие выводы. Первое: протестированная система усвоения с ретроградными циклами очень эффективна в случае, если запаздывают все спутниковые наблюдения. Действительно,

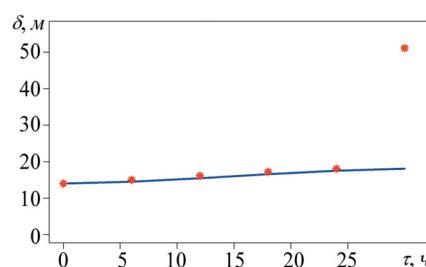


Рис. 4. Среднеквадратичная ошибка суточного прогноза геопотенциала поверхности 500 гПа в зависимости от времени запаздывания данных наблюдений: линия — запаздывают только данные спутниковых радиационных наблюдений, звездочки — запаздывают все данные спутниковых наблюдений (запаздывание более 24 ч означает, что запаздывающие данные наблюдений не усваивались).

примерно 30% (15%) при задержке всех спутниковых наблюдений на 24 ч (12 ч) и 25% (10%) при задержке только радиационных спутниковых наблюдений на 24 ч (12 ч). Таким образом, разработанные методика и численная схема позволяют эффективно извлекать информацию из данных наблюдений, поступающих с большой задержкой.

7. Заключение

Описаны состояние оперативной глобальной системы усвоения данных Гидрометцентра России и основные направления ее развития. Эти направления включают разработку новой, оригинальной системы ансамблево-вариационного усвоения данных на основе оригинальной методики много- масштабного сверточного анализа, а также оптимизацию и создание новых алгоритмов усвоения данных спутниковых наблюдений, включая наблюдения, производимые на российских полярно-орбитальных спутниках серии “Метеор-М”. Также среди приоритетов — включение методов нейросетевого моделирования в алгоритмы усвоения данных наблюдений.

Приведены положительные результаты тестирования сверточного анализа в постановке с известной “истиной”. Показана возможность построения новой вычислительно эффективной многомасштабной схемы сверточного анализа. Даны результаты восстановления поля морского льда по микроволновым спутниковым наблюдениям с помощью нейросетевой модели. Показана эффективность усвоения данных наблюдений, поступающих со значительной задержкой в системе с ретроградными циклами усвоения.

Авторы выражают признательность Д. М. Ермакову (ИКИ РАН), представившему набор данных измерений МТВЗА-ГЯ за апрель 2022 г. с уточненной географической привязкой.

ошибка прогноза при его старте с анализа, произведенного системой усвоения запаздывающих данных наблюдений (красные звездочки, соответствующие задержкам от 6 до 24 ч), намного ниже ошибки прогноза, полученного без усвоения запаздывающих данных (красная звездочка, соответствующая задержке 30 ч). Второе: протестированная система достаточно эффективна и в случае запаздывания только радиационных спутниковых наблюдений (хотя и в гораздо меньшей степени, чем в случае запаздывания всех спутниковых наблюдений). Третье: потеря точности прогноза из-за усвоения запаздывающих данных наблюдений растет приблизительно линейно с ростом задержки поступления и достигает

Литература

1. Гайфулин Д. Р., Цырульников М. Д., Успенский А. Б. и др. Использование информации спутникового микроволнового радиометра МТВЗА-ГЯ в системе усвоения данных Гидрометцентра России. — Метеорология и гидрология, 2017, № 9, с. 36—47.
2. Заболотских Е. В. Обзор методов восстановления параметров ледяного покрова по данным спутниковых микроволновых радиометров. — Известия РАН. Физика атмосферы и океана, 2019, т. 55, № 1, с. 128—151; doi: 10.31857/S0002-3515551128-151.
3. Заболотских Е. В., Балашова Е. А., Азаров С. М. Восстановление сплоченности морского льда по данным измерений МТВЗА-ГЯ. — Современные проблемы дистанционного зондирования Земли из космоса, 2022, т. 19, № 1, с. 27—38.
4. Толстых М. А., Фадеев Р. Ю., Шляева А. В. и др. Система моделирования атмосферы для бесшовного прогноза. — Триада-ЛТД, 2017, 166 с.
5. Успенский А. Б., Асмус В. В., Крамчанинова Е. К. и др. Абсолютная калибровка каналов атмосферного зондирования спутникового микроволнового радиометра МТВЗА-ГЯ. — Исследования Земли из космоса, 2016, № 5, с. 57—70.
6. Филяй А. А., Андреев А. И., Успенский А. Б. Использование искусственных нейронных сетей для восстановления температурно-влажностного состояния атмосферы по данным спутникового микроволнового радиометра МТВЗА-ГЯ КА Метеор-М № 2-2. — Исследования Земли из космоса, 2021, № 6, с. 83—95.
7. Цырульников М. Д., Гайфулин Д. Р., Свиренко П. И. и др. Усвоение данных спутниковых метеорологических наблюдений в Гидрометцентре России. — Метеорология и гидрология, 2021, № 12, с. 25—38.
8. Цырульников М. Д., Свиренко П. И., Гайфулин Д. Р. и др. Развитие системы оперативного усвоения данных метеорологических наблюдений в Гидрометцентре России. — Гидрометеорологические исследования и прогнозы, 2019, № 4, с. 112—126.
9. Bonavita M., Holm E., Isaksen L., et al. The evolution of the ECMWF hybrid data assimilation system. — Quart. J. Roy. Meteorol. Soc., 2016, vol. 142, No. 694, pp. 287—303.
10. Buehner M., Morneau J., and Charette C. Four-dimensional ensemble-variational data assimilation for global deterministic weather prediction. — Nonlinear Processes in Geophys., 2013, vol. 20, No. 5, pp. 669—682.
11. Gayfulin D., Tsyrulnikov M., and Uspensky A. Assessment and adaptive correction of observations in atmospheric sounding channels of the satellite microwave radiometer MTVZA-GY. — Pure and Appl. Geophys., 2018, vol. 175, pp. 3653—3670.
12. Goodfellow I., Bengio Y., and Courville A. Deep Learning. — MIT Press, 2016.
13. Grumbine R. W. and Xingren Wu. Sea ice in the NCEP forecast system. — Cold Region Science and Marine Technology, 2014, 13 p.
14. Gulli A., Kapoor A., and Pal S. Deep Learning with TensorFlow 2 and Keras: Regression, ConvNets, GANs, RNNs, NLP, and More with TensorFlow 2 and the Keras API. — Packt Publishing Ltd, 2019.
15. Okuyama A. and Imaoka K. Inter-calibration of advanced microwave scanning radiometer-2 (AMSR2) brightness temperature. — IEEE Trans. Geosci. and Remote Sens., 2015, vol. 53, No. 8, pp. 4568—4577.
16. Rabier F., Jarvinen H., Klinker E., et al. The ECMWF operational implementation of four-dimensional variational assimilation. I: Experimental results with simplified physics. — Quart. J. Roy. Meteorol. Soc., 2000, vol. 126, No. 564, pp. 1143—1170.
17. Skamarock W. C., Park S.-H., Klemp J. B., et al. Atmospheric kinetic energy spectra from global high-resolution nonhydrostatic simulations. — J. Atmos. Sci., 2014, vol. 71, pp. 4369—4381.
18. Tsyrulnikov M. and Rakitko A. A hierarchical Bayes ensemble Kalman filter. — Physica D (Nonlinear Phenomena), 2017, vol. 338, pp. 1—16.
19. Tsyrulnikov M. and Rakitko A. Impact of non-stationarity on hybrid ensemble filters: A study with a doubly stochastic advection-diffusion-decay model. — Quart. J. Roy. Meteorol. Soc., 2019, vol. 145, No. 722, pp. 2255—2271.
20. Tsyrulnikov M. and Sotskiy A. Regularization of the ensemble Kalman filter using a non-parametric, non-stationary spatial model. — ArXiv preprint, 2023, arXiv:2306.14318; <https://doi.org/10.48550/arXiv.2306.14318>.
21. Wang X., Parrish D., Kleist D., et al. GSI 3DVar-based ensemble-variational hybrid data assimilation for NCEP Global Forecast System: Single-resolution experiments. — Mon. Wea. Rev., 2013, vol. 141, No. 11, pp. 4098—4117.
22. Wedi N. P. Increasing horizontal resolution in numerical weather prediction and climate simulations: Illusion or panacea? — Phil. Trans. Roy. Soc., 2014, A.37220130289; doi: <http://doi.org/10.1098/rsta.2013.0289>.