Всероссийская конференция «Современные проблемы дистанционного зондирования Земли из космоса»
ИКИ РАН, Москва, 9–13 ноября 2026 г.

Определение температурно-влажностного профиля облачной атмосферы по данным СВЧ радиометров

Егоров Д.П., Яфарова А.Р., Козлова А.А., Кутуза Б.Г.
Институт радиотехники и электроники им. В.А. Котельникова РАН, Москва, Россия

Мотивация

- Текущие вертикальные профили температуры и влажности нужны для локального прогноза погоды, раннего обнаружения опасных явлений (шквалы, ливни, заморозки), прецизионного земледелия.
- Контактные и космические средства не дают нужного сочетания детальности и оперативности:
  - радиозонды – точны, но запускаются 2–3 раза в сутки и не дают мгновенного вертикального профиля;
  - спутниковые СВЧ-радиометры – пятно разрешения 5×5…60×60 км.
- **СВЧ радиометры-спектрометры на наземных платформах и БПЛА малых высот** (например, СВЧ МИС) дают мгновенные локальные профили, высокое пространственно-временное разрешение.
- Перспективные режимы наблюдений – **многоуровневые** (по высоте полёта), **многоракурсные**, мультисенсорные и «роевые» схемы – формируют непрерывные потоки **больших данных** ⇒ требуются **улучшенные алгоритмы** восстановления: быстрые, точные, работоспособные в облаках, с оценкой неопределённости каждого измерения, пригодные к бортовому исполнению.

Синтез физического и статистического подходов. Два варианта: **(1)** яркостные температуры — в функции ошибки нейросети; **(2)** «нейросеть + вариационная ассимиляция» с «горячим стартом» от нейросети. Общий фундамент — быстрая дифференцируемая модель переноса излучения.

Обратная задача

$$y = F(x) + \varepsilon, \qquad x = [T(z),\ \ln \rho(z),\ W(z)]$$

• Вектор состояния x — высотные профили температуры, (логарифма) влажности и водности облаков. Задача нелинейна и **некорректна по Адамару**: оператор переноса излучения сглаживает профиль ⇒ решение не единственно и неустойчиво; число степеней свободы сигнала конечно ⇒ качество восстановления определяется априорной информацией.

	1DVAR — байесовская вариационная ассимиляция	Нейросеть — регрессия y → x
+	физическая согласованность решения с измеренным спектром	скорость: миллисекунды на одно измерение
+	апостериорная ковариация ошибки, χ^2-диагностика	извлекает закономерности из данных: реальная (не гауссова) климатология, облака
–	зависит от статичного климатического фона; локальные минимумы при сильной нелинейности (облака, осадки)	нет гарантии согласованности с конкретным измерением
–	вычислительно дорога: итерации с прямой моделью и якобианом	нет встроенной строгой теории ошибок

Рассмотренные варианты: (1) внедрить согласованность со спектром Tb в функцию ошибки нейросети;

(2) «нейросеть + вариационная ассимиляция»: НС формирует фон и ковариацию, вариационная стадия уточняет решение.

Облачность: эффект на спектр яркостной температуры

- Алгоритмы восстановления атмосферных профилей в научной литературе, как правило, рассматриваются и сравниваются только в постановке **безоблачной** атмосферы.
- Между тем в реальной атмосфере жидкокапельная облачность оказывает на спектр Tb **сильный** (десятки–сотни K в окнах 18–40 ГГц) и принципиально **нелинейный** эффект.

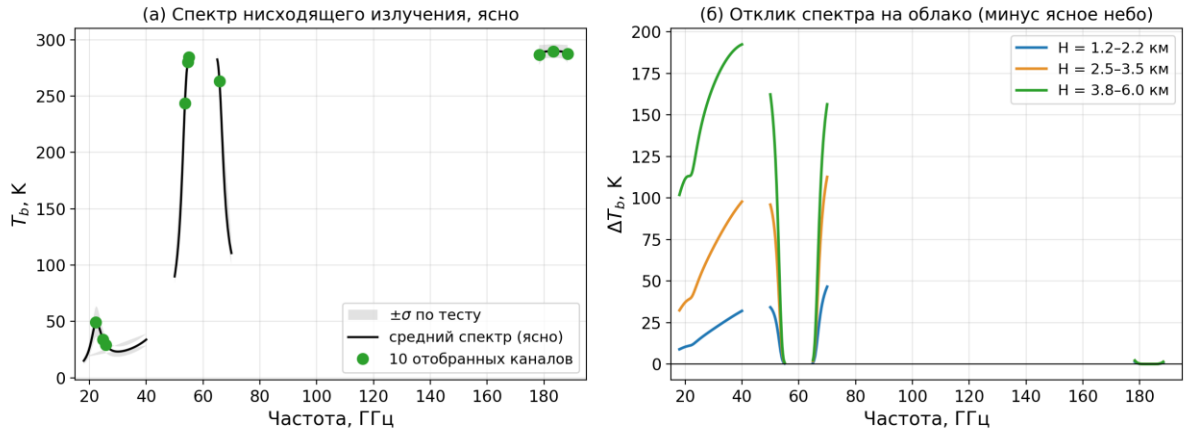

(а) спектр Tb ясной атмосферы (среднее ± σ по тесту); (б) средний отклик спектра на облачную воду по бинам мощности облака H.

⇒ Далее — сразу **облачная постановка**: профиль водности W(z) включён в вектор состояния, прямая модель учитывает поглощение в облаке.

Постановка вычислительного эксперимента

- **Ансамбль состояний:** 50 000 летних профилей радиозондов (архивы UWYO и NOAA IGRA, средние широты); train/val/test = 40 000/5 000/5 000.
- **Измерения:** 214 каналов – 18–40 ГГц (линия H_2O 22.2 ГГц), 50–55 и 65–70 ГГц (крыло O_2), 183.3±5 ГГц, шаг 0.2 ГГц – плюс наземные псевдо-наблюдения T_0, ρ_0.
- **Модель ошибок наблюдений** S_e: NEDT 0.3 K (независ.) + калибровка 0.5 K (общая, ранг-1) + ошибка прямой модели 0.45 K (коррелир. по каналам); $\sigma(T_0)$ = 1 K, $\sigma(\rho_0)$ = 10 %.
- **«Истинные» спектры:** пакет atmrad (ITU-R P.676-12 – метод суммирования спектральных линий).
- **Рабочая прямая модель во всех методах** – разработанная **быстрая дифференцируемая** суррогатная модель с аналитическим якобианом: средняя RMS по каналам **0.7 K** относительно эталона (~35 мкс/профиль на GPU).

- **Облачная серия:** каждый профиль → 5 вариантов (слабые возмущения T и ρ + модельное облако) → **250 000 состояний**; первый вариант – ясный.
- Облако по **модели Мазина**: низ 1.1 км, мощность H = 0–5 км.
- Истинные спектры – с поглощением в облаке (ITU-R P.840-8); профиль водности **W(z) входит в вектор состояния**, прямая модель учитывает его поглощение ⇒ **совместное восстановление трёх профилей: T, ρ, W.**

$$w(z) = \xi^{\mu_0}(1-\xi)^{\psi_0}\frac{W(H)}{H}\frac{\Gamma(2+\mu_0+\psi_0)}{\Gamma(1+\mu_0)\Gamma(1+\psi_0)}, \quad W(H) = 0.133\,H^{2.302}$$

w — облачная водность, г/м³; W — водозапас столба облака, кг/м²

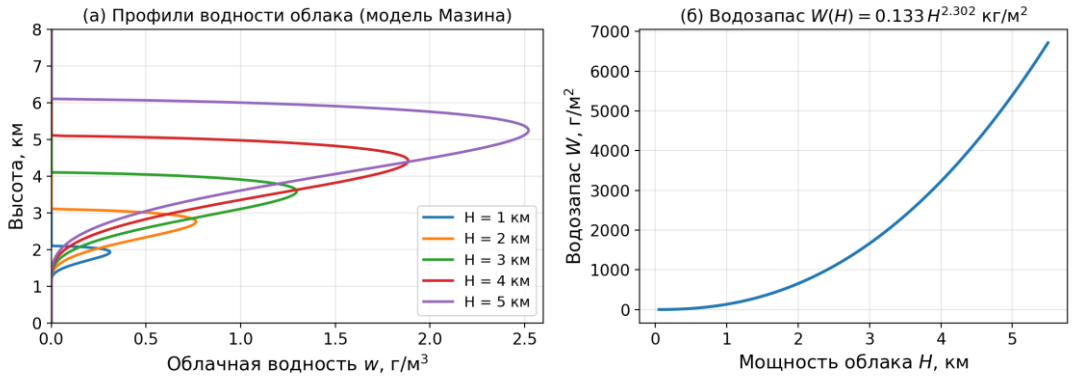

Вариант 1 — яркостные температуры в функции ошибки нейросети

• Нейросетевая парадигма сохраняется полностью (ансамбль из 3 MLP, слои 1024–1024–512–512, GELU; скорость – микросекунды на измерение), но в функцию ошибки внедряется **согласованность с измеренным спектром Tb**.

• **MSE** – базовая среднеквадратичная ошибка по профилю; **MSE+Tb** – плюс физически информированный штраф по спектрам:

$$\mathcal{L} = \mathcal{L}_{\mathrm{MSE}} + \beta\, s_0 \frac{1}{N} \sum_{f=1}^{N} w_f \left[\mathbf{K}(x_{\mathrm{true}})\,(\hat{x} - x_{\mathrm{true}})\right]_f^2, \quad w_f = 1/\mathrm{Var}_f T_b$$

– штраф за профили, близкие к истине, но дающие физически нереализуемый спектр (якобиан – в точке истинного профиля батча);

– в облачной серии якобиан включает поглощение облака истинного профиля (k_w(f, T)·w, ITU-R P.840-8).

• **NLL** – гетероскедастическая сеть предсказывает среднее и дисперсию каждого коэффициента в базисе климатических EOF:

$$\mathcal{L} = \frac{1}{2} \sum_{k=1}^{K} \left[\ln \sigma_k^2 + \frac{(a_k - \mu_k)^2}{\sigma_k^2}\right]$$

– дисперсии покомпонентно калибруются на валидации → **покейсовая неопределённость** прогноза;

– **NLL+Tb** – комбинация NLL со спектральным штрафом: рабочая конфигурация в обоих вариантах синтеза.

Итог: точность и быстродействие нейросети сохраняются, а её вывод становится более согласованным с измеренными спектрами яркостной температуры.

Вариант 2 — «нейросеть + вариационная ассимиляция»

$$J(x) = \frac{1}{2}(x - x_b)^T \mathbf{B}^{-1}(x - x_b) + \frac{1}{2}(y - F(x))^T \mathbf{S}_e^{-1}(y - F(x)) \longrightarrow \min_x$$

$$x_{k+1} = x_k + \left(\mathbf{B}^{-1} + \mathbf{K}_k^T \mathbf{S}_e^{-1} \mathbf{K}_k + \lambda_k \operatorname{diag}(\cdot)\right)^{-1} \left[\mathbf{K}_k^T \mathbf{S}_e^{-1}(y - F(x_k)) - \mathbf{B}^{-1}(x_k - x_b)\right]$$

- Фон и ковариация – **от нейросети** (вариант 1, NLL+Tb): нулевое приближение x_b = x_NN(y) и **ковариация его ошибки** B_NN(y).
- **«Горячий старт»** – сразу в окрестности глобального минимума: меньше итераций ЛМ, сходимость 100 %.
- Вариационная стадия возвращает: **согласованность** со спектром, апостериорную **Ŝ(y)**, **χ²-контроль** (слайд 9).
- B_NN двух видов: общая – усадка эмпирической ковариации остатков (λ = 0.35); покейсовая – из предсказанных σ²(y) по формуле Вудбери ↓

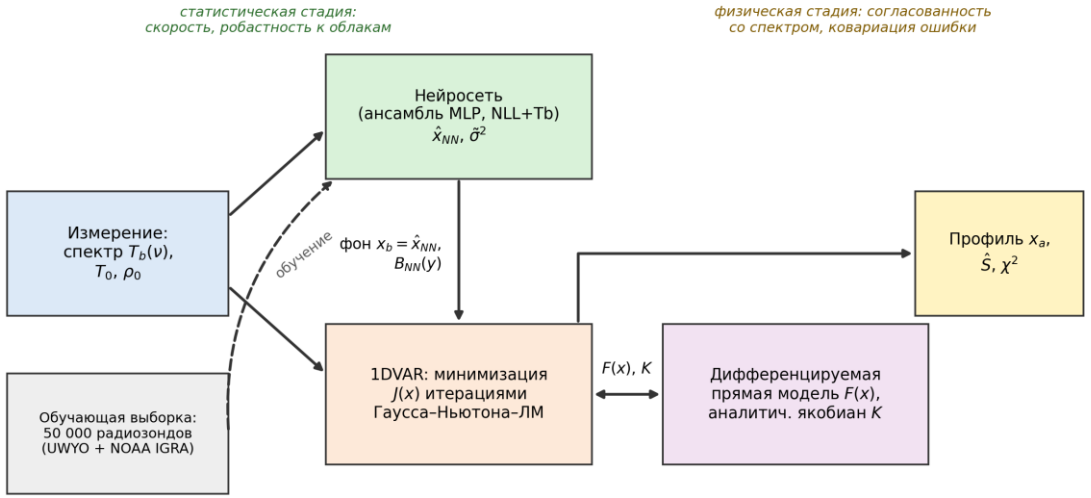

$$\mathbf{B}_{NN}^{-1} = \mathbf{D}_s^{-1}\left[\varepsilon^{-2}\mathbf{I} + \mathbf{V}\operatorname{diag}(\tilde{\sigma}^{-2} - \varepsilon^{-2})\mathbf{V}^T\right]\mathbf{D}_s^{-1} \quad \text{(Вудбери)}$$

Результаты: точность совместного восстановления T, ρ и W

Метод	T, 0.2–1	T, 1–4	T, 4–8	T, весь	ρ, 0.2–1	ρ, 1–4	ρ, 4–8	ρ, весь	WΣ, весь
Климатология	5.88	4.99	5.04	5.11	2.756	1.690	0.508	1.185	2.51
1DVAR-cloud (клим. фон)	1.47	1.96	3.01	2.45	1.091	0.796	0.277	0.556	0.05
NN (NLL+Tb)	1.03	1.22	1.65	1.42	0.971	0.728	0.255	0.507	0.06
Гибрид-cloud (NN→1DVAR)	1.13	1.29	1.64	1.46	0.974	0.724	0.254	0.505	0.06

RMSE по слоям (T в K, ρ в г/м³) и по водозапасу столба облака WΣ (кг/м², облачные кейсы); полный спектр.

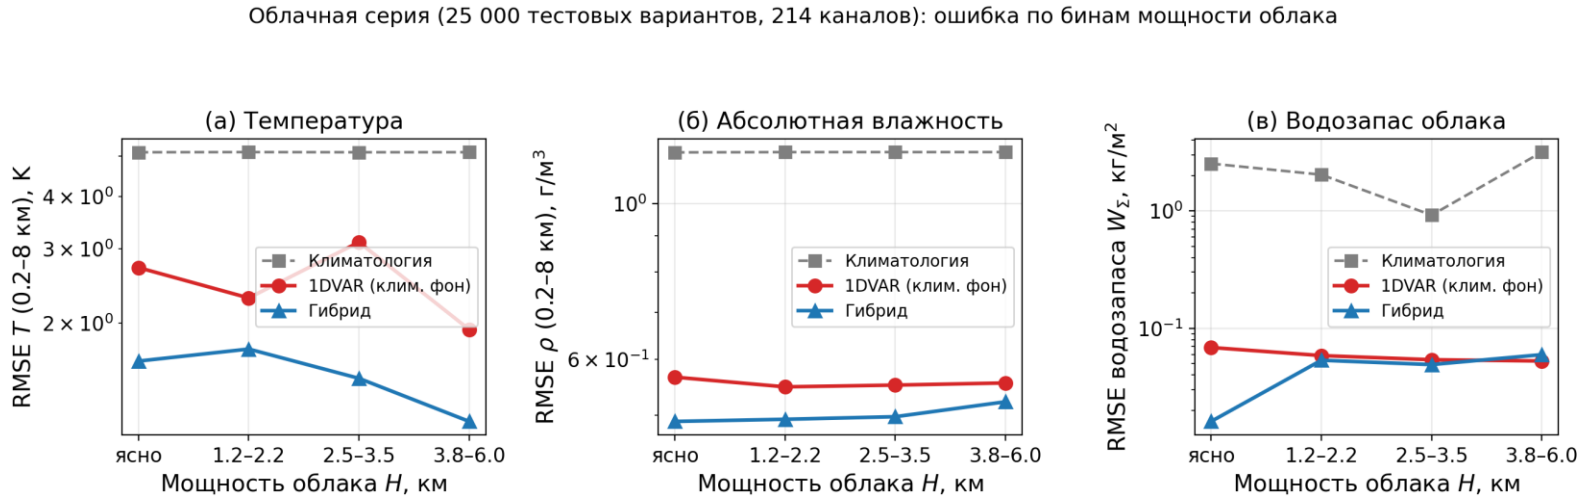

Вывод 1: NN (NLL+Tb) – самый точный метод по T – 1.42 K. **Вывод 2:** горячий старт от NN повышает точность традиционного 1DVAR почти до нейросетевой (2.45 → 1.46 K по T) – по всем трём профилям и при любой облачности.

Результаты: точность совместного восстановления T, ρ и W

Метод	T, 0.2–1	T, 1–4	T, 4–8	T, весь	ρ, 0.2–1	ρ, 1–4	ρ, 4–8	ρ, весь	WΣ, весь
Климатология	5.88	4.99	5.04	5.11	2.756	1.690	0.508	1.185	2.51
1DVAR-cloud (клим. фон)	1.31	1.83	2.67	2.22	1.194	0.891	0.297	0.613	0.16
NN (NLL+Tb)	1.17	1.48	2.16	1.80	1.091	0.823	0.283	0.570	0.11
Гибрид-cloud (NN→1DVAR)	1.18	1.50	2.17	1.82	1.106	0.822	0.279	0.569	0.11

RMSE по слоям (T в K, ρ в г/м³) и по водозапасу столба облака WΣ (кг/м², облачные кейсы); 10 DFS-отобранных каналов.

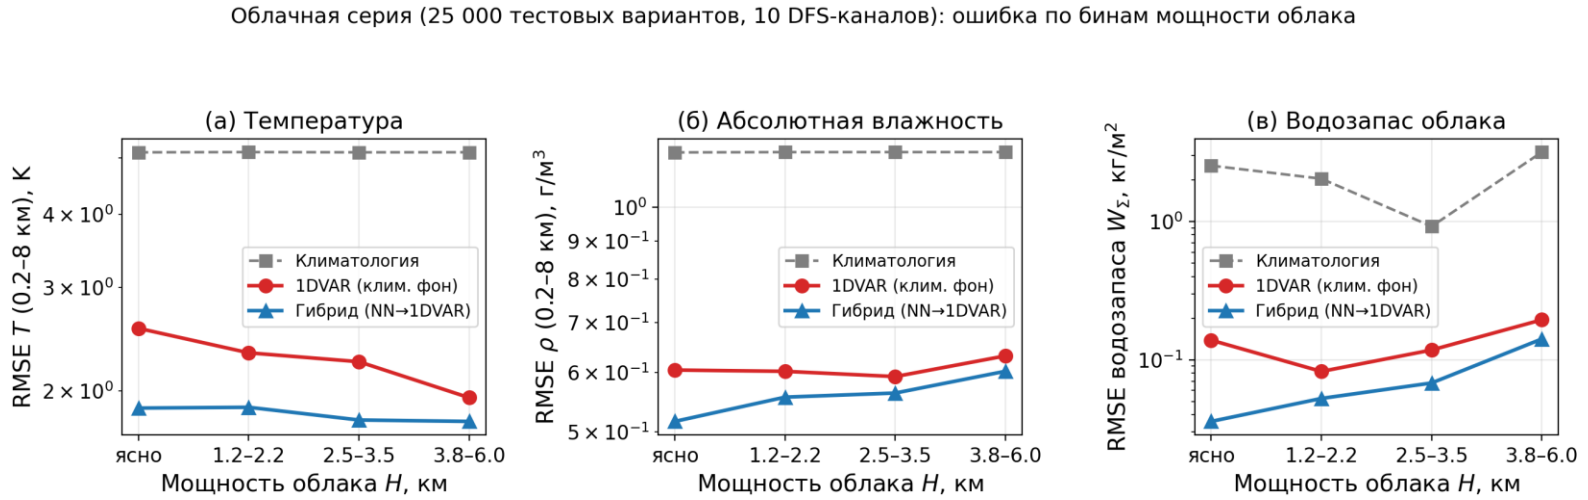

Вывод 1: NN (NLL+Tb) – самый точный метод по T – 1.80 K. Вывод 2: горячий старт от NN повышает точность традиционного 1DVAR почти до нейросетевой (2.22 → 1.82 K по T) – по всем трём профилям и при любой облачности.

Результаты: согласованность со спектрами Tb и неопределённость

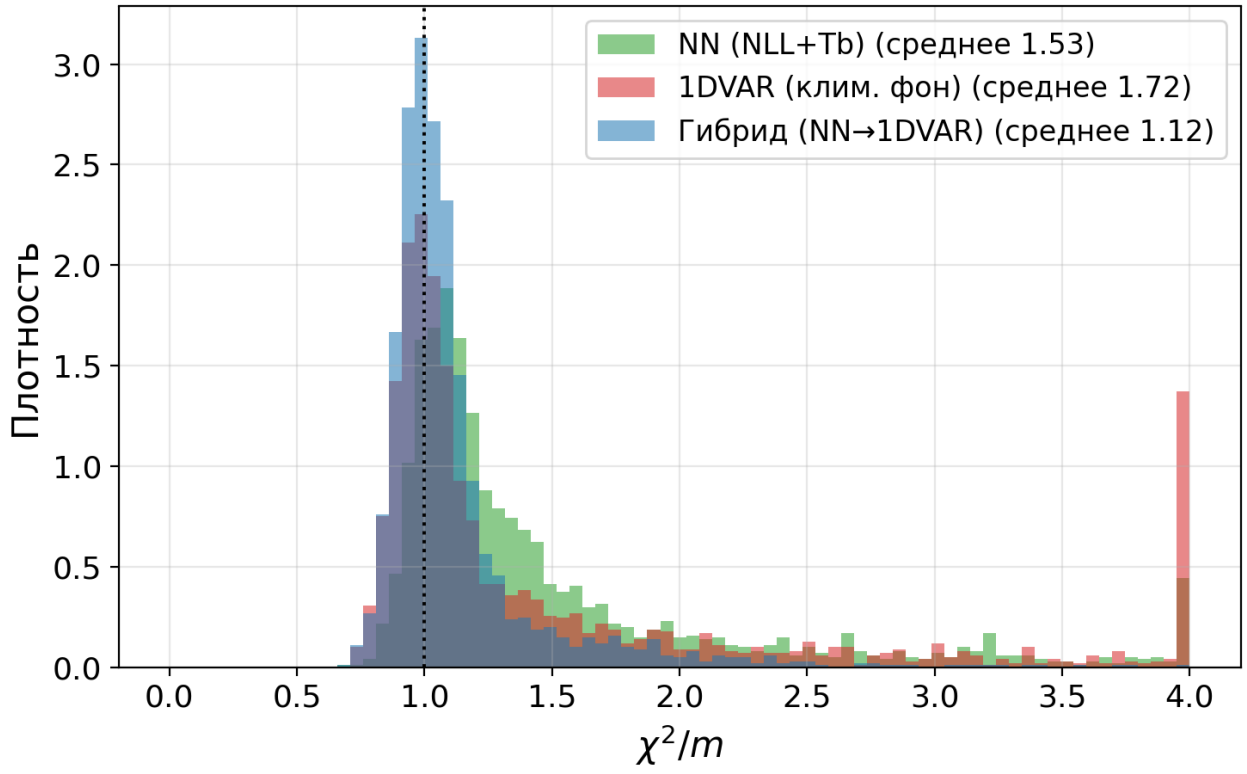

Распределение χ^2/m – невязки измеренного и моделируемого спектров, нормированной на ковариацию ошибок S_e; m = 216 (214 каналов + 2 наземных псевдо-наблюдения).

$$\hat{\mathbf{S}}(y) = \left(\mathbf{B}^{-1} + \mathbf{K}^T\mathbf{S}_e^{-1}\mathbf{K}\right)^{-1}, \quad K = K(\hat{x}(y))$$

$$\chi^2/m = \frac{1}{m}\left(y - F(\hat{x})\right)^T\mathbf{S}_e^{-1}\left(y - F(\hat{x})\right)$$

- Норма для вариационной схемы: $\chi^2/m \approx 1 - DFS/m$ (DFS ≈ 5 – степени свободы сигнала); для NN χ^2 – апостериорная диагностика.
- **Вывод 1:** согласованность NN не хуже 1DVAR – среднее χ^2/m = 1.53 против 1.72, хвост короче (p90: 2.63 против 3.15) – при в 1.7 раза меньшей ошибке и на 4 порядка большей скорости.
- **Вывод 2:** гибрид – наилучшая согласованность: среднее 1.12, медиана 1.03, p90 = 1.46; апостериорная $\hat{S}(y)$ калибрована: z-RMS = 0.87 (T), 1.09 (ln ρ), 0.29 (w).

Быстродействие: значение для бортовой обработки

Метод (214 каналов)	Время на одно измерение	Режим применения
NN (ансамбль 3 MLP, NLL+Tb)	3 мкс (GPU), 0.13 мс (CPU)	реальное время, обработка на борту
1DVAR-cloud (клим. фон)	13.1 мс (GPU)	интерактивный
Гибрид-cloud (NN→1DVAR)	13.5 мс (GPU)	интерактивный

Облачная серия: состояние из трёх профилей; вариационные схемы – до 25 итераций Гаусса–Ньютона–ЛМ.

- NN-фон сокращает число итераций ЛМ, сходимость 100 % ⇒ гибрид не дороже климатического 1DVAR.
- NN обрабатывает **тысячи профилей в секунду** – достаточно для бортовой обработки потока измерений с БПЛА в реальном времени.
- Быстрая дифференцируемая модель прямой задачи с аналитическим якобианом (RMS 0.7 K, ~35 мкс/профиль).

Заключение

Цель *– алгоритмы восстановления высотных атмосферных профилей для новых платформ и режимов наблюдений (БПЛА-радиометры, многоуровневые и многоракурсные схемы, большие потоки данных), сочетающие сильные стороны физической и статистической парадигм ⇒ конвертируют возможности оборудования в реальные точность, детальность и надёжность мониторинга.*

- Рассмотрены **два варианта такого синтеза** на общем фундаменте – разработанной **быстрой дифференцируемой прямой модели**.

- **Вариант 1 – яркостные температуры в функции ошибки нейросети (Physics Informed NN):** точность и быстродействие нейросетевого алгоритма сохраняются (RMSE T = 1.42 K, микросекунды на измерение), а вывод более согласован с измеренными спектрами Tb – не хуже традиционной схемы ($\chi^2/m = 1.53$ против 1.72 у 1DVAR) при в 1.7 раза меньшей ошибке.

- **Вариант 2 – «горячий старт» вариационной ассимиляции от нейросети:** точность традиционного 1DVAR повышается почти до нейросетевой (2.45 → 1.46 K по T, преимущество по всем трём профилям при любой облачности); достоинства вариационной схемы сохраняются: согласованность ($\chi^2/m = 1.12$, медиана 1.03), калиброванная апостериорная $\hat{S}(y)$ и χ^2-контроль каждого измерения.

- **Постановка – облачная:** профиль водности W(z) облака включён в вектор состояния; все методы совместно восстанавливают три профиля (T, ρ, W).

- **Дальше:** многоракурсные и многоуровневые (томографические) схемы с БПЛА, осадки, переход к реальным измерениям.

Спасибо за внимание!

Егоров Д.П., Яфарова А.Р., Козлова А.А., Кутуза Б.Г.

Институт радиотехники и электроники им. В.А. Котельникова РАН