

ОЦЕНКА ВЫСОТНОГО ПРОФИЛЯ ИНТЕНСИВНОСТИ АТМОСФЕРНОЙ ОПТИЧЕСКОЙ ТУРБУЛЕНТНОСТИ С ИСПОЛЬЗОВАНИЕМ ГРАДИЕНТНОГО БУСТИНГА

ESTIMATION OF THE ALTITUDE PROFILE OF ATMOSPHERIC OPTICAL TURBULENCE INTENSITY USING GRADIENT BOOSTING

М.Б. Дрига 

*Институт солнечно-земной физики СО РАН,
Иркутск, Россия, driga@iszf.irk.ru*

А.Ю. Шиховцев 

*Институт солнечно-земной физики СО РАН,
Иркутск, Россия, Ashikhovtsev@iszf.irk.ru*

П.Г. Ковадло 

*Институт солнечно-земной физики СО РАН,
Иркутск, Россия, kovadlo2006@rambler.ru*

Е.А. Копылов 

*Институт астрономии РАН,
Москва, Россия, kopylov@inasan.ru*

С.А. Потанин 

*Институт астрономии РАН,
Москва, Россия, sr.potantin@gmail.com
Московский государственный университет
им. М.В. Ломоносова,
Москва, Россия
Государственный астрономический институт
им. П.К. Штернберга,
Москва, Россия*

M.B. Driga

*Institute of Solar-Terrestrial Physics SB RAS,
Irkutsk, Russia, driga@iszf.irk.ru*

A.Yu. Shikhovtsev

*Institute of Solar-Terrestrial Physics SB RAS,
Irkutsk, Russia, Ashikhovtsev@iszf.irk.ru*

P.G. Kovadlo

*Institute of Solar-Terrestrial Physics SB RAS,
Irkutsk, Russia, kovadlo2006@rambler.ru*

E.A. Kopylov

*Institute of Astronomy RAS,
Moscow, Russia, kopylov@inasan.ru*

S.A. Potanin

*Institute of Astronomy RAS,
Moscow, Russia, sr.potantin@gmail.com
Lomonosov Moscow State University,
Moscow, Russia
Sternberg Astronomical Institute,
Moscow, Russia*

Аннотация. Искажения волнового фронта, вызываемые атмосферной турбулентностью, значительно снижают качество астрономических наблюдений. Ключевой характеристикой интенсивности атмосферной турбулентности является структурная постоянная показателя преломления C_n^2 . Прямые измерения ее высотного профиля сложны и трудоемки, что стимулирует развитие методов прогнозирования. В данной работе мы представляем метод оценки высотного профиля C_n^2 на 12 уровнях (от 0.5 до 22.6 км) с помощью моделей машинного обучения. Сравнивалась точность предсказания моделей, при обучении которых использовались методы градиентного бустинга и случайного леса. Модели обучались на основе приземных измерений характеристик турбулентности, локальных метеорологических данных и вертикальных профилей метеорологических величин, извлекаемых из реанализа ERA-5. Сравнение показало, что по точности предсказания профиля C_n^2 метод градиентного бустинга превосходит метод случайного леса на большинстве высот, начиная с 0.71 км. Наилучшая точность градиентного бустинга по сравнению со случайным лесом (до 7.4 % по коэффициенту корреляции Пирсона) наблюдалась на высотах более 5 км. Анализ важности признаков для лучшей модели выявил, что наиболее значимыми являются такие параметры, как

Abstract. Wavefront distortions caused by atmospheric turbulence significantly reduce the quality of astronomical observations. A key characteristic of atmospheric turbulence intensity is the structural constant of the refractive index C_n^2 . Direct measurements of its altitude profile are complex and labor-intensive, which stimulates the development of forecasting methods. In this work, we present a method for estimating the altitude profile of C_n^2 at 12 levels (from 0.5 to 22.6 km) using machine learning. The gradient boosting model was trained based on ground measurements of turbulence characteristics, local meteorological data, and vertical profiles of meteorological variables extracted from the ERA-5 reanalysis. The performance of the resulting model was compared with that of a random forest model. The comparison showed that gradient boosting outperforms the random forest method at most heights, starting from 0.71 km. The greatest improvement in accuracy (up to 7.4 % according to Pearson's correlation coefficient) was achieved at heights above 5 km. Analysis of the importance of features for the best model revealed that the most significant parameters are temperature and wind speed at isobaric surfaces. The results demonstrate the effectiveness of gradient boosting for predicting the C_n^2 profile, which simplifies and speeds up the evaluation of astronomical sites where optical telescopes are located.

температура и скорость ветра на изобарических поверхностях. Полученные результаты демонстрируют эффективность метода градиентного бустинга для предсказания профиля C_n^2 , что упрощает и ускоряет оценку астрономических площадок, на которых размещаются оптические телескопы.

Ключевые слова: атмосферная оптическая турбулентность, структурная постоянная показателя преломления, машинное обучение, градиентный бустинг, случайный лес, астрономические площадки.

ВВЕДЕНИЕ

При прохождении сквозь турбулентную атмосферу нашей планеты волновой фронт излучения в оптическом диапазоне искажается, именно поэтому изображения удаленных астрономических объектов, фокусируемых на светочувствительную матрицу, могут размываться [Cuadros et al., 2025]. По сути, размывание свидетельствует о потере части информации о наблюдаемом объекте. Конечно, системы детектирования и коррекции способны определять и исправлять деформированную атмосферой форму волнового фронта [Jellen et al., 2023; Pierzyna et al., 2025; Bakı, Basu, 2024]. Однако качество детектирования и коррекции будет напрямую зависеть от профиля интенсивности атмосферной оптической турбулентности (АОТ) по лучу зрения «наблюдательный оптический инструмент — астрономический объект» [Natekin, Knoll, 2013; Cai et al., 2020].

Важнейшей практической задачей является выбор астрономической площадки с целью размещения какого-либо наблюдательного оптического инструмента, для чего необходимо знание об интенсивности АОТ на различных высотах [Roddier, 1981]. Одной из количественных характеристик интенсивности АОТ является структурная постоянная показателя преломления C_n^2 [Shikhovtsev et al., 2023].

При решении задачи прогнозирования профиля атмосферной оптической турбулентности важную роль играет выбор алгоритма машинного обучения. По принципу построения модели методы машинного обучения подразделяют на геометрические (например, метод опорных векторов), вероятностные (наивный байесовский классификатор), логические (деревья решений) и ансамблевые. Используемый в данной работе градиентный бустинг относится к классу ансамблевых алгоритмов. Его ключевая идея заключается в последовательном построении композиции из слабых базовых моделей (как правило, деревьев решений), где каждая следующая модель обучается на ошибках предыдущей, минимизируя некоторую функцию потерь. Такой подход позволяет эффективно моделировать сложные нелинейные зависимости между входными метеорологическими параметрами и высотным распределением C_n^2 .

Целями данной работы являлись адаптация и обучение известных моделей машинного обучения, которые определяли бы высотный профиль C_n^2 по приземным измерениям C_n^2 и набору метеорологиче-

Keywords: atmospheric optical turbulence, refractive index structure constant, machine learning, gradient boosting, random forest, astronomical sites.

ских величин на высоте 0 км, а также по данным реанализа ERA-5. Мы предполагаем, что полученная в результате модель машинного обучения позволит строить высотные профили C_n^2 , минуя его непосредственные измерения. В частности, модель может быть использована для восстановления профилей турбулентности и оценки углового разрешения телескопов в пределах некоторого региона вокруг опорной обсерватории. Это позволит ускорить и упростить выбор астрономической площадки для оптических наблюдений.

1. ДАННЫЕ

Для обучения модели требовалось определиться с выходными и входными данными. В качестве выходных данных использовались рутинные оптические измерения, выполненные с помощью малого наземного телескопа Кавказской горной обсерватории (КГО) который использует комбинированную методику Multi-Aperture Scintillation Sensor-Differential Image Motion Monitor (MASS-DIMM) [Kornilov et al., 2007], объединяющую многоапертурный анализ мерцаний (MASS) и мониторинг дифференциального дрожания изображения (DIMM).

Измерения значений C_n^2 проводились с 15 ноября 2007 г. по 16 июня 2013 г. для следующих высот: 0, 0.5, 0.71, 1, 1.41, 2, 2.82, 4, 5.66, 8, 11.3, 16, 22.6 км. Заметим, что измерения C_n^2 на высоте 0 км можно проводить с помощью не только методики MASS-DIMM, но также и наземной ультразвуковой метеостанции. Такая доступность наблюдательных данных позволила нам использовать ряд значений C_n^2 на высоте 0 км в качестве входных переменных.

В качестве входных данных также использовались измерения метеорологических характеристик в приземном слое атмосферы, которые велись синхронно с оптическими наблюдениями в КГО. Для обучения модели использовались следующие временные ряды данных:

- T_{outside} — температура воздуха снаружи купола телескопа (MASS-DIMM);
- T_{inside} — температура воздуха внутри купола телескопа (MASS-DIMM);
- V_{wind} — скорость приземного ветра;
- D_{wind} — направление приземного ветра;
- H — влажность воздуха.

К входным относятся и данные реанализа последнего поколения ERA-5, которые являются ре-

зультатом ассимиляции данных измерений метеорологических станций, станций радиозондирования, спутниковых данных и других инструментов, регистрирующих атмосферные характеристики. Для обучения модели использовались следующие характеристики ERA-5:

- blh — высота пограничного слоя;
 - $ewss$ и $nsst$ — турбулентные приповерхностные напряжения восточного и северного направлений;
 - $lgws$ и $ngws$ — приповерхностные напряжения, создающиеся под действием гравитационных волн в восточном и северном направлениях соответственно;
 - $mgws$ — средняя скорость порывов ветра.
- Для изобарических поверхностей 750, 500, 250 гПа:
- u — компоненты скорости ветра по оси восток–запад;
 - v — компоненты скорости ветра по оси север–юг;
 - w — вертикальная скорость ветра;
 - T — температура воздуха;
 - vo — завихренность воздушных течений.

Выбор входных и выходных данных для моделей машинного обучения определялся физической обоснованностью, доступностью измерений и требованиями к пространственно-временному разрешению. В качестве выходных переменных выступают значения C_n^2 на 12 фиксированных высотах в диапазоне от 0.5 до 22.6 км. Такое количество уровней обусловлено методикой измерений MASS-DIMM, которая обеспечивает восстановление интегральных характеристик турбулентности именно в этих слоях, и соответствует типичному вертикальному разрешению, используемому в задачах астроклимата. Ограничений на количество выходных переменных не накладывалось, однако их набор был строго определен доступными экспериментальными данными.

Входные признаки подразделяются на три группы: приземные метеорологические величины, данные наземных измерений C_n^2 (на высоте 0 км) и вертикальные профили метеопараметров из реанализа ERA-5. Принцип отбора этих переменных основывался на результатах предшествующих исследований, указывающих на их значимую корреляцию с интенсивностью оптической турбулентности. Количество входных признаков (порядка двух десятков) является компромиссом между полнотой описания атмосферных процессов и риском переобучения модели. При формировании обучающей выборки была необходима синхронизация разновременных данных: измерения MASS-DIMM и наземной метеостанции проводились с минутным шагом, тогда как реанализ ERA-5 доступен ежечасно. Поэтому все ряды данных были приведены к часовому усреднению, что позволило унифицировать временные метки.

При формировании признаков для моделей машинного обучения используется десятичный логарифм произведения $C_n^2 \Delta z$ (имеющего размерность $\text{м}^{1/3}$), а на графиках для удобства представления данных применяется логарифмическая шкала по оси высоты Z (в км). Поскольку математически коррект-

ный логарифм определен только для безразмерного аргумента, в данной работе для краткости под выражениями $\lg C_n^2 \Delta z$ и $\lg z$ подразумевается логарифм от отношения соответствующей величины к ее единице измерения:

$$\lg\left(\left(C_n^2 \Delta z\right) / \left(1 \text{ м}^{1/3}\right)\right) \text{ и } \lg(z / 1 \text{ км}).$$

Такой подход обеспечивает корректность вычислений и позволяет использовать логарифмический масштаб для наглядного представления данных, сохраняя при этом физическую размерность исходных величин.

2. МЕТОДЫ

В данной работе проведен сравнительный анализ двух методов машинного обучения — градиентного бустинга и случайного леса, который был реализован в работе [Шиховцев и др., 2025a], — в приложении к задаче предсказания высотного профиля АОТ. Как и для случайного леса, для градиентного бустинга нами варьировались значения двух основных гиперпараметров: количества базовых моделей (от 100 до 1000 с шагом 100) и максимальной глубины базовой модели (от 1 до 11 с шагом 1). Заметим, что полученная модель представляет собой объединение двенадцати моделей машинного обучения, т. е. для каждой высоты предназначена своя модель связи C_n^2 с метеорологическими характеристиками. При комбинациях различных значений этих двух гиперпараметров для каждой из двенадцати высот модели градиентного бустинга делали предсказания значений C_n^2 для 20 % от всего объема имевшегося у нас набора данных, который представлял собой тестовую выборку.

Затем для одной комбинации гиперпараметров формировались двенадцать новых рядов данных с предсказанными значениями C_n^2 .

Чтобы оценить качество работы модели градиентного бустинга для определенной комбинации значений варьируемых гиперпараметров, мы использовали следующий подход. Для каждой высоты мы определяли коэффициент корреляции Пирсона между рядами измеренных и предсказанных значений C_n^2 по следующей формуле:

$$r_{mp} = \frac{\sum_{i=1}^n (m_i - \bar{m})(p_i - \bar{p})}{\sqrt{\sum_{i=1}^n (m_i - \bar{m})^2 \sum_{i=1}^n (p_i - \bar{p})^2}}, \quad (1)$$

где m_i и p_i — отдельные измеренные (measured) и предсказанные (predicted) значения C_n^2 соответственно; $\bar{m}$ и $\bar{p}$ — средние арифметические значения соответствующих рядов данных.

После того как коэффициент корреляции Пирсона был определен для всех двенадцати пар рядов данных, определялось его среднее значение. Затем количество базовых моделей, максимальная глубина базовой модели и среднее значение коэффициента корреляции

Коэффициенты корреляции Пирсона (r), средние абсолютная (MAE) и квадратичная (MSE) ошибки для рядов значений, полученных методами градиентного бустинга (GB) и случайного леса (RF)

Высота слоя, км	r_{GB}	r_{RF}	MAE_{GB}	MAE_{RF}	MSE_{GB}	MSE_{RF}
0.5	0.77***	0.78***	0.33	0.33	0.19	0.19
0.71	0.73***	0.73***	0.43	0.43	0.31	0.31
1.0	0.74***	0.71***	0.41	0.43	0.28	0.31
1.41	0.79***	0.76***	0.41	0.45	0.29	0.33
2.0	0.78***	0.76***	0.34	0.36	0.20	0.22
2.82	0.78***	0.76***	0.27	0.29	0.13	0.14
4.0	0.81***	0.78***	0.25	0.27	0.11	0.12
5.66	0.80***	0.76***	0.23	0.26	0.09	0.11
8.0	0.71***	0.68***	0.21	0.24	0.08	0.09
11.3	0.73***	0.68***	0.16	0.19	0.05	0.06
16.0	0.71***	0.67***	0.16	0.18	0.04	0.05
22.6	0.84***	0.79***	0.13	0.15	0.03	0.04

Примечание: *** — уровень значимости p-value < 0.001.




Рис. 1. Тепловая карта со средними значениями коэффициента корреляции Пирсона при различных комбинациях количества базовых моделей и максимальной глубины базовых моделей. Цветовая шкала показывает значения среднего коэффициента корреляции. Звездочкой отмечена оптимальная модель градиентного бустинга

ляции записывались в [таблицу](#) и на основе этих данных строилась так называемая тепловая карта, представленная на [рис. 1](#).

Лучшей комбинацией значений гиперпараметров признавалась такая, при которой наблюдалось наибольшее среднее значение коэффициента корреляции Пирсона между измеренными значениями и полученными с помощью модели градиентного бустинга.

3. РЕЗУЛЬТАТЫ

Наилучшей была признана модель градиентного бустинга со следующими значениями гиперпараметров:

- количество базовых моделей — 800;
- максимальная глубина базовых моделей — 8.

Для визуализации разброса предсказаний величины C_n^2 приведено распределение предсказанных значений в зависимости от измеренных ([рис. 2](#)).

Распределение показывает квазилинейную зависимость с некоторым разбросом, сходную с полученной нами ранее для метода случайного леса [Шиховцев др., 20256], что может говорить о близкой точности предсказаний этими моделями.

Для количественной оценки точности предсказаний наилучших моделей градиентного бустинга и случайного леса на различных высотах было решено выбрать следующие метрики:

- коэффициент корреляции Пирсона r ;
- средняя абсолютная ошибка

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|,$$

где y_i — фактическое значение; $\hat{y}_i$ — предсказанное значение; n — количество наблюдений;

- средняя квадратичная ошибка

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2.$$




Рис. 2. Предсказанные методом градиентного бустинга и измеренные значения C_n^2 для турбулентных слоев на разных высотах; Δz — толщина атмосферного слоя

Ориентируясь на значения коэффициентов корреляции Пирсона из таблицы, можно видеть, что точность предсказания на высоте 0.5 км модели градиентного бустинга хуже, чем модели случайного леса. Однако уже с высоты 0.71 км точность предсказания градиентного бустинга по сравнению со случайным лесом увеличивается.

На рис. 3, а показано распределение коэффициентов корреляции Пирсона для градиентного бустинга и случайного леса по высотам. На рис. 3, б представлено высотное распределение относительного отклонения

$$\delta_r = (r_{GB} - r_{RF}) / r_{RF} \cdot 100 \text{ \%}.$$

Из рис. 3, б видно, что, если исходить из коэффициента корреляции Пирсона, точность предсказания градиентного бустинга по сравнению с точностью предсказания случайного леса:

- на высоте 0.5 км хуже на 1.3 %;
- на высоте 0.71 км такая же;
- на высоте 1 км лучше на 4.2 %;
- на высоте 1.41 км лучше на 3.9 %;
- на высоте 2 км лучше на 2.6 %;
- на высоте 2.82 км лучше на 2.6 %;
- на высоте 4 км лучше на 3.8 %;
- на высоте 5.66 км лучше на 5.3 %;
- на высоте 8 км лучше на 4.4 %;
- на высоте 11.3 км лучше на 7.4 %;
- на высоте 16 км лучше на 6.0 %;
- на высоте 22.6 км лучше на 6.3 %.

Под термином «распределение важности признаков» (feature importance) в данной работе понимается количественная оценка вклада каждого входного параметра в предсказательную способность модели машинного обучения. Для алгоритмов на основе деревьев решений, к которым относится градиентный бустинг, важность признака обычно вычисляется

как суммарное уменьшение неопределенности (дисперсии) целевой переменной во всех узлах дерева, где используется данный признак, усредненное по всем деревьям ансамбля. Чем выше значение важности, тем сильнее влияет соответствующая метеорологическая величина на формирование турбулентности на данной высоте. Таким образом, представленные на рис. 4–6 распределения позволяют не только интерпретировать построенные модели, но и выделить физически значимые механизмы, связывающие состояние атмосферы с интенсивностью оптических искажений.

Из таблицы, а также из рис. 3, а и б следует, что на высоте 0.5 км градиентный бустинг работает хуже случайного леса на 1.3 %. Зная это, ориентируемся на распределение важности признаков случайного леса. Согласно ему наибольший вклад в формирование турбулентности вблизи поверхности земли (на высоте 0.5 км) вносят следующие параметры:

- $vo(750 \text{ гПа}), \text{ с}^{-1}$ — около 25 %;
- $\lg C_n^2 \Delta z (0 \text{ км}), \text{ м}^{1/3}$ — около 17 %;
- $u(500 \text{ гПа}), \text{ м/с}$ — около 10 %.

На высоте 5.66 км градиентный бустинг лучше воспроизводит вариации C_n^2 , чем случайный лес: δ_r достигает 5.3 %. Учитывая это, можно рекомендовать использовать метод градиентного бустинга для описания атмосферной турбулентности на этих высотах. При этом наибольший вклад в формирование турбулентности на высоте 5.66 км вносят следующие параметры (рис. 4):

- $v(500 \text{ гПа}), \text{ м/с}$ — около 16 %;
- $T(500 \text{ гПа}), \text{ }^\circ\text{C}$ — около 14 %;
- $T(200 \text{ гПа}), \text{ }^\circ\text{C}$ — около 7 %.

Для высоты 11.3 км (рис. 5) градиентный бустинг позволяет оценивать вариации интенсивности АОТ точнее, чем случайный лес, на 7.4 %. Для этих высот значимость переменной $T(500 \text{ гПа})$ несколько падает (она составляет 11 %). К ключевым атмосферным величинам также относятся:

- $T(750 \text{ гПа}), \text{ }^\circ\text{C}$ — около 10 %;
- $u(200 \text{ гПа}), \text{ м/с}$ — около 9 %.

ЗАКЛЮЧЕНИЕ

В ходе данной работы были успешно разработаны 12 независимых моделей машинного обучения для оценки интенсивности атмосферной оптической турбулентности, характеризуемой структурной постоянной C_n^2 , в диапазоне высот от 0.5 до 22.6 км. Созданные модели позволяют с приемлемой точностью реконструировать весь высотный профиль C_n^2 , используя в качестве входных данных лишь приземные измерения турбулентности и стандартные метеорологические параметры. Практическая ценность данного подхода состоит в возможности отказа от трудоемких прямых измерений профиля C_n^2 с помощью специального оборудования (например, MASS/DIMM или SCIDAR) на этапе предварительного анализа астрономических площадок. Это открывает путь к более эффективному исследованию




Рис. 3. Распределение коэффициентов корреляции Пирсона между измеренными и прогнозируемыми значениями C_n^2 для методов градиентного бустинга (r_{GB}) и случайного леса (r_{RF}) на различных высотах (а); распределение относительного изменения δ_r [%] r_{GB} по сравнению с r_{RF} для различных высот (б)




Рис. 4. Важность признаков на высоте 5.66 км при использовании метода градиентного бустинга




Рис. 5. Важность признаков на высоте 11.3 км при использовании метода градиентного бустинга




Рис. 6. Измеренные (сплошные зеленые линии) и предсказанные с применением градиентного бустинга (штриховые синие линии) высотные профили интенсивности атмосферной оптической турбулентности для 00:00:00 UTC 22.08.2008 (а), 24.10.2009 (б) и 02.06.2012 (в); z — высота над подстилающей поверхностью

потенциальных мест для размещения оптических наблюдательных инструментов.

Показано, что, начиная с высоты 0.71 км, метод градиентного бустинга демонстрирует систематически более высокую точность предсказания по сравнению с методом случайного леса с максимальным превышением (до 7.4 %) в средних и верхних слоях атмосферы. Такое превосходство, вероятно, объясняется ключевой особенностью градиентного бустинга — последовательной оптимизацией, при которой каждая следующая модель — слабый ученик — целенаправленно исправляет ошибки предыдущих. Это позволяет алгоритму более эффективно выявлять сложные нелинейные физические связи между приземными параметрами, данными реанализа и турбулентностью на больших высотах. Однако градиентный бустинг проявляет повышенную чувствительность к шуму и всплескам в данных, что, вероятно, обусловило его несколько худшую точность предсказания в нижнем приземном слое (0.5 км), где локальные эффекты более выражены.

Для сравнения на рис. 6 представлены примеры измеренных и предсказанных с применением градиентного бустинга высотных профилей интенсивности АОТ.

Исследование выполнено за счет гранта Российского научного фонда № 24-72-10043, [<https://rscf.ru/project/24-72-10043/>]. Результаты получены с использованием ЭВМ, расположенных на территории Уникальной научной установки «Большой солнечный вакуумный телескоп» ИСЗФ СО РАН [<https://ckp-rf.ru/catalog/usu/200615/>].

Выражаем признательность и благодарность Сафонову Б.С. за обсуждение данных, полученных в КГО.

СПИСОК ЛИТЕРАТУРЫ

- Шиховцев А.Ю., Дрига М.Б., Киселев А.В. и др. Нейросетевые модели для оценки атмосферного углового разрешения телескопов наземного базирования / *Всерос. конф. с междунар. участием «Магнетизм и активность Солнца – 2025»: тез. докл.* Научный, Крым, 2025а, с. 1.
- Шиховцев А.Ю., Киселев А.В., Ковадло П.Г. Физически-информируемые нейронные сети для оценки интенсивности атмосферной оптической турбулентности. *Известия вузов. Физика.* 2025б, т. 68, № 5, с. 66–73. <https://doi.org/10.17223/00213411/68/5/8>.
- Baki H., Basu S. Estimating high-resolution profiles of wind speeds from a global reanalysis dataset using TabNet. *Environmental Data Science.* 2024, vol. 3, e32. <https://doi.org/10.1017/eds.2024.41>.
- Cai J., Xu K., Zhu Y., et al. Prediction and analysis of net ecosystem carbon exchange based on gradient boosting regression and random forest. *Applied Energy.* 2020, vol. 262, 114566. <https://doi.org/10.1016/j.apenergy.2020.114566>.
- Cuadros E.T., Almeida A.P., Carlesso R., et al. Assessment of daytime sky quality and atmospheric refractive index (C_n^2) analysis at Pico dos Dias Observatory. *Astrophys. J. Suppl. Ser.* 2025, vol. 281, 24. <https://doi.org/10.3847/1538-4365/ae0a2a>.
- Jellen C., Nelson C., Burkhardt J., et al. Hybrid optical turbulence models using machine-learning and local measurements. *Applied Optics.* 2023, vol. 62, no. 18, pp. 4880–4890. <https://doi.org/10.1364/AO.487280>.
- Kornilov V., Tokovinin A., Shatsky N., et al. Combined MASS-DIMM instrument for atmospheric turbulence studies. *Mon. Not. Roy. Astron. Soc.* 2007, vol. 382, pp. 1268–1278. <https://doi.org/10.1111/j.1365-2966.2007.12467.x>.
- Natekin A., Knoll A. Gradient boosting machines, a tutorial. *Front. Neurobot.* 2013, vol. 7, 21. <https://doi.org/10.3389/fnbot.2013.00021>.
- Pierzyna M., Basu S., Saathof R. OTclIM: Generating a near-surface climatology of optical turbulence strength (C_n^2) us-

- ing gradient boosting. *Artificial Intelligence for the Earth Systems*. 2025, vol. 4, no. 2, e240076.
<https://doi.org/10.1175/AIES-D-24-0076.1>.
- Roddier F.V The effects of atmospheric turbulence in optical astronomy. *Progress in Optics* / Ed. E. Wolf. Amsterdam: Elsevier, 1981, vol. 19, pp. 281–376.
[https://doi.org/10.1016/S0079-6638\(08\)70204-X](https://doi.org/10.1016/S0079-6638(08)70204-X).
- Shikhovtsev A.Yu., Kovadlo P.G., Kiselev A.V., et al. Application of neural networks to estimation and prediction of seeing at the Large Solar Telescope site. *Publ. Astron. Soc. Pacific*. 2023, vol. 135, no. 1043, 014503.
<https://doi.org/10.1088/1538-3873/acb384>.
- URL: <https://rscf.ru/project/24-72-10043/> (дата обращения 22 июня 2026 г.).
- URL: <https://ckp-rf.ru/catalog/usu/200615/> (дата обращения 22 июня 2026 г.).

Как цитировать эту статью:

Дрига М.Б., Шиховцев А.Ю., Ковадло П.Г. и др. Оценка высотного профиля интенсивности атмосферной оптической турбулентности с использованием градиентного бустинга. *Солнечно-земная физика*. 2026, т. 12, № 3, с. 114–121. <https://doi.org/10.12737/szf-123202612>.