

## Применение методов машинного обучения для моделирования толщины снежного покрова

© 2017 г. Г.В. Айзель

Институт водных проблем РАН, Москва, Россия  
hydrogo@yandex.ru

## Use of machine learning techniques for modeling of snow depth

G.V. Ayzel

Institute of Water Problems, Russian Academy of Sciences, Moscow, Russia  
hydrogo@yandex.ru

Received March 12, 2016

Accepted September 20, 2016

**Keywords:** *boosting, machine learning, modeling, open data, snow depth.*

### Summary

Snow exerts significant regulating effect on the land hydrological cycle since it controls intensity of heat and water exchange between the soil-vegetative cover and the atmosphere. Estimating of a spring flood runoff or a rain-flood on mountainous rivers requires understanding of the snow cover dynamics on a watershed. In our work, solving a problem of the snow cover depth modeling is based on both available databases of hydro-meteorological observations and easily accessible scientific software that allows complete reproduction of investigation results and further development of this theme by scientific community. In this research we used the daily observational data on the snow cover and surface meteorological parameters, obtained at three stations situated in different geographical regions: Col de Porte (France), Sodankyla (Finland), and Snoquamie Pass (USA). Statistical modeling of the snow cover depth is based on a complex of freely distributed the present-day machine learning models: Decision Trees, Adaptive Boosting, Gradient Boosting. It is demonstrated that use of combination of modern machine learning methods with available meteorological data provides the good accuracy of the snow cover modeling. The best results of snow cover depth modeling for every investigated site were obtained by the ensemble method of gradient boosting above decision trees – this model reproduces well both, the periods of snow cover accumulation and its melting. The purposeful character of learning process for models of the gradient boosting type, their ensemble character, and use of combined redundancy of a test sample in learning procedure makes this type of models a good and sustainable research tool. The results obtained can be used for estimating the snow cover characteristics for river basins where hydro-meteorological information is absent or insufficient.

Поступила 12 марта 2016 г.

Принята к печати 20 сентября 2016 г.

**Ключевые слова:** *бустинг, машинное обучение, моделирование, открытые данные, толщина снежного покрова.*

На основе открытых данных гидрометеорологических наблюдений на трёх водно-балансовых станциях, расположенных в различных физико-географических условиях, исследована возможность применения современных методов машинного обучения для моделирования динамики снежного покрова. Эффективность использования ансамблевой модели градиентного бустинга над решающими деревьями выше, чем моделей одиночного решающего дерева или адаптивного бустинга для всех исследуемых объектов.

### Введение

Снежный покров – важнейший элемент функционирования природной среды, поэтому численное моделирование его динамики представляет собой важную научную задачу. Процессы снегонакопления и стаивания вызывают большой интерес не только в локальных исследованиях их нелинейного характера и геофизических особенностей, но и по причине огромной регулирующей роли снежного покрова в определении динамики процессов тепло- и влагообмена поверхности суши с атмосферой [1, 2].

Непосредственное и наиболее значимое влияние снежный покров оказывает на динамику весенних половодий [2, 3], а часто и паводков [4] на реках, на термические особенности и влагосодержание почвенного покрова (контролируя весеннюю продуктивность почв сельскохозяйственных земель), а также на экологическое состояние ландшафта территорий, расположенных в холодном климате. Снежный покров относится к производной сочетания локальных метеорологических условий, оказывает также обратное воздействие на местный климат, формируя его специфические особенности.

Исследование динамики снежного покрова не ограничивается рамками изолированной среды природных процессов, а распространяется и на междисциплинарную область исследований социогидрологии, включающую в себя весь спектр взаимодействия процессов гидрологического цикла суши, с одной стороны, и человеческого общества — с другой. Снежный покров, а также особенности его формирования и распределения относятся к важнейшим факторам безопасности общества, так как определяют расчётную степень допустимых нагрузок на строительные конструкции и сооружения [5], опасность и интенсивность половодий и паводков [2, 3], функционирование инфраструктуры городов [6] и др. Кроме того, характеристики снежного покрова обуславливают привлекательность и безопасность использования горных и равнинных лыжных курортов [1], что вносит существенный вклад в рекреационный потенциал этих территорий. С начала 1970-х годов в научной среде стало активно развиваться численное моделирование как область исследования динамики снежного покрова [1, 7]. В настоящее время можно выделить две большие группы моделей формирования снежного покрова: физически обоснованные и статистические.

*Физически обоснованные модели* учитывают огромный спектр особенностей трансформации водного и теплового режима снежного покрова: тепловлагообмен на границах «снежный покров — атмосфера» и «снежный покров — почвенно-растительный покров», процессы уплотнения и старения снега, образования ледяных корок, изменения структурных свойств и текстурных паттернов и т.д. [8, 9]. Развитию данного направления способствовали глобальные научные проекты SnowMIP и PILPS, посвящённые сравнению моделей формирования снежного покрова, в которых участвовали модели, реализованные разными научными группами из исследовательских институтов по всему миру [10, 11]. При решении проблемы априорного (или иного) задания пространства параметров физически обоснованные модели формирования снежного покрова могут с хорошей точностью воспроизводить динамику процессов снегонакопления и стаивания [3, 8, 12].

*Статистические методы моделирования* динамики снежного покрова не учитывают спектр физических процессов, происходящих в толще снега и на его верхней и нижней границах, а пытаются установить функциональное соответствие динами-

ки характеристик снежного покрова (толщины, содержания воды в снеге) от хода метеорологических элементов (температуры и влажности воздуха, количества осадков и т.д.). Несмотря на простоту реализации данных численных методов моделирования и их высокую устойчивость [13], при решении задач воспроизведения характеристик снежного покрова они не нашли широкого распространения. Можно выделить два класса работ в этой области. Первый класс охватывает работы, связанные с восстановлением пространственной структуры снежного покрова путём использования современных методов машинного обучения — решающих деревьев и искусственных нейронных сетей [14, 15], а также их комбинации с геостатистическими методами [16]. Второй класс связывает работы по использованию функционала современных статистических методов для качественного уточнения продуктов спутниковой радиометрии снежного покрова [17].

Цель данной работы — исследование эффективности применения современных методов статистического моделирования (машинного обучения) для воспроизведения динамики толщины снежного покрова на стационарах, расположенных в разных климатических условиях. Выбор в качестве основной моделируемой величины толщины снежного покрова определяется высокой доступностью и полнотой наблюдений за её динамикой на исследовательских стационарах и метеостанциях по всему миру. Выбор в качестве инструмента численного моделирования методов машинного обучения обусловлен существенным прогрессом данной области за последние 5–10 лет, что, в дополнение к низкой изученности представленной темы, даёт нам дополнительные основания для проведения исследований на новом современном уровне. Мы использовали данные открытых источников, свободно распространяемое программное обеспечение и реализацию алгоритмов машинного обучения [18], что свидетельствует о соответствии данной работы современным требованиям воспроизводимости научного исследования.

### Используемые данные

Исследования велись на основе открытых данных режимных наблюдений за метеорологическими элементами и снежным покровом на стационарах Коль де Порт (Франция), Соданкьюла

Таблица 1. Характеристики исследуемых стационаров

Параметры	Коль де Порт (Франция)	Соданкюла (Финляндия)	Снокуалми Пасс (США)
Широта, градусы	45,30 с.ш.	67,36 с.ш.	47,41 с.ш.
Долгота, градусы	5,77 в.д.	26,63 в.д.	121,41 з.д.
Высота, м	1325	180	921
Среднегодовая температура воздуха, °С	2,9	0,85	5,4
Годовая сумма осадков, мм	1180	555	2590
Максимальная толщина снежного покрова, м	2,1	1,1	4,8

(Финляндия) и Снокуалми Пасс (США). Все стационары находятся в разных природных условиях (табл. 1), что позволило провести более широкие обобщения полученных результатов и установить специфику применимости моделей разного типа. Для моделирования из всего массива наблюдений в качестве входных параметров (предикторов) выбраны только ряды наблюдений за приходящей коротко- и длинноволновой радиацией, температурой и влажностью воздуха, интенсивностью жидких и твёрдых осадков, а также скоростью ветра. В качестве моделируемой величины выбрана толщина снежного покрова. Дискретность измерений на выбранных станциях составляла один час. Архивы наблюдений охватывали следующие периоды: для стационара Коль де Порт – с 1993 по 2011 г. [19]; для стационара Соданкюла – с 2007 по 2014 г. [20]; для стационара Снокуалми Пасс – с 1989 по 2012 г. [21]. Для обеспечения однородности исследовательского подхода выполнены процедуры линейного восстановления пропусков и осреднения часовых данных наблюдений в суточные, выбран и общий для всех стационаров период наблюдений – с 2007 по 2011 г. (четыре полных сезона снегонакопления и стаивания).

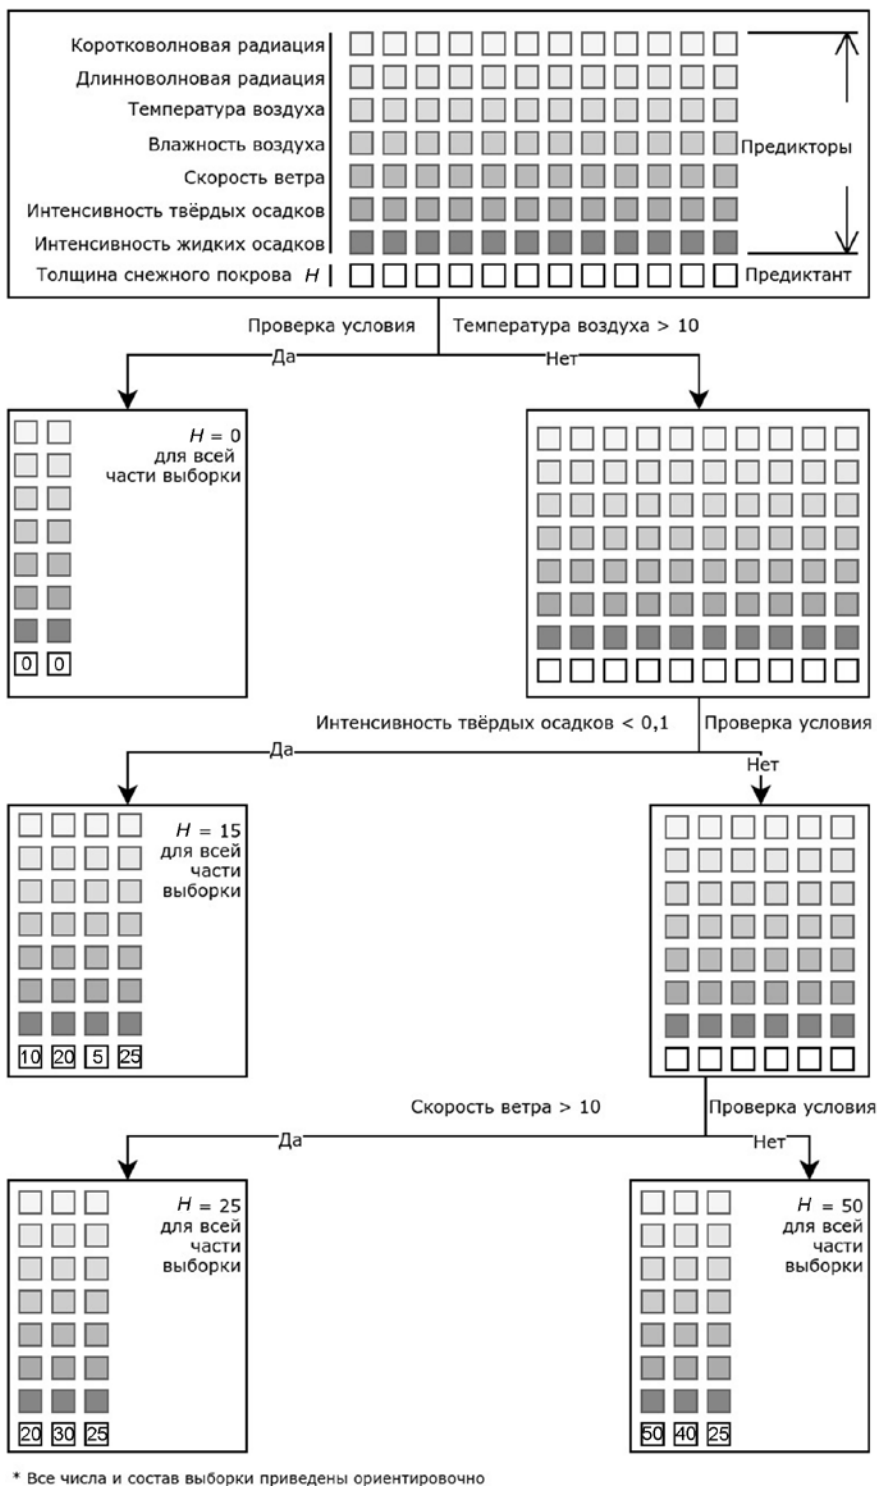
### Методы исследования

В качестве основного метода машинного обучения выбрана простейшая модель одиночного решающего дерева (рис. 1). Логика данной модели заключается в бинарном разбиении пространства признаков используемой выборки (в нашем случае – метеорологические наблюдения) на малые подвыборки до того момента (критерий останова), когда внутри этих подвыборок можно определить однозначное соответствие усечённого пространства признаков константному значению целевой переменной (в нашем случае – толщина снежного

покрова). Для построения модели программно реализован алгоритм CART, предложенный в работе [22], с дополнениями, касающимися усечения итоговых деревьев и упрощения критериев разбиения подвыборок, обобщёнными в работе [23].

К достоинствам модели одиночного решающего дерева относятся: интерпретируемость, быстрота обучения и высокая толерантность к неполным данным. В качестве недостатков обычно выделяют: высокую способность к переобучению, неустойчивость при доминировании одного решающего класса, сложность поиска точной структуры дерева [23]. Общее место для большинства исследователей в области машинного обучения и искусственного интеллекта – подтверждённая годами работы с реальными данными эвристика о высокой обобщающей способности ансамблевых методов моделирования, основанных на применении различных реализаций одиночных решающих деревьев [23–25]. В нашей работе применены две стандартные реализации бустинга (алгоритма последовательного ансамблевого построения моделей машинного обучения [25]) – адаптивный и градиентный.

Использовалась классическая реализация *адаптивного бустинга*, предложенная в пионерной работе [24]. Отличительная особенность данного алгоритма – использование в качестве членов ансамбля слабых моделей (в нашем случае – решающих деревьев с максимальной глубиной разбиения выборки не более четырёх уровней). Логика данного алгоритма заключается в обновлении весов членов обучающей выборки на каждой следующей итерации в соответствии с ошибкой модели, полученной на предыдущей итерации [24]. Обновление происходит таким образом, что члены обучающей выборки с наибольшей ошибкой получают наибольшие веса. Это позволяет следующей модели в ансамбле «сместить своё внимание» на неудачные экземпляры.



**Рис. 1.** Принципиальная блок-схема простой модели одиночного решающего дерева  
**Fig. 1.** Common scheme of ordinary decision tree model

Использование адаптивного бустинга в реальных задачах классификации образов позволило считать его «безусловно лучшим алгоритмом для классификации» [23] на конец 1990-х годов.

*Градиентный бустинг* над решающими деревьями относится к жадному алгоритму, который на каждом этапе построения принимает локально оптимальные решения, полагая, что ансамблевый

набор таких решений приведёт в итоге к глобальному оптимальному решению [25, 26]. Логика данного алгоритма заключается в построении на каждой следующей итерации модели, в качестве целевого вектора которой выступают не сами значения моделируемой величины, а ошибки модели на предыдущей итерации. Представляя собой логичное продолжение работ по развитию ансамблевых алгоритмов статистического моделирования, основанных на использовании решающих деревьев в качестве элементарных членов ансамбля, градиентный бустинг стал одним из сильнейших алгоритмов на современном этапе развития методов машинного обучения [25].

При построении моделей машинного обучения применены стандартные реализации алгоритмов бэггинга (bagging), бутстрепа (bootstrap), усечения деревьев (pruning) и кросс-валидации методом выброшенной точки (leave-one-out cross-validation), направленные на повышение устойчивости предлагаемых решений [23, 25, 27]. Все представленные алгоритмы реализовались с помощью свободно распространяемой библиотеки машинного обучения Scikit-learn [18] для языка программирования Python. Для оценки эффективности воспроизведения динамики снежного покрова используемыми моделями машинного обучения по сравнению с данными натурных наблюдений применены метрики коэффициента детерминации  $R^2$  и средней абсолютной ошибки  $MAE$ :

$$R^2 = 1 - \frac{\sum_i (x_i - y_i)^2}{\sum_i (x_i - \bar{x})^2};$$

$$MAE = \frac{\sum_i |x_i - y_i|}{n},$$

где  $x_i$  – измеренное значение толщины снежного покрова в момент времени  $i$ ;  $y_i$  – то же, рассчитанное (смоделированное);  $\bar{x}$  – среднее значение измеренной толщины снежного покрова;  $n$  – длина ряда наблюдений.

## Результаты

Моделирование динамики толщины снежного покрова для всех исследуемых стационаров в отдельности (см. табл. 1) проводилось для всего исследуемого периода (четыре сезона снегонакопления – с 2007 по 2011 г.). Так как в работе использовалось недостаточное количество дан-

Таблица 2. Результаты моделирования

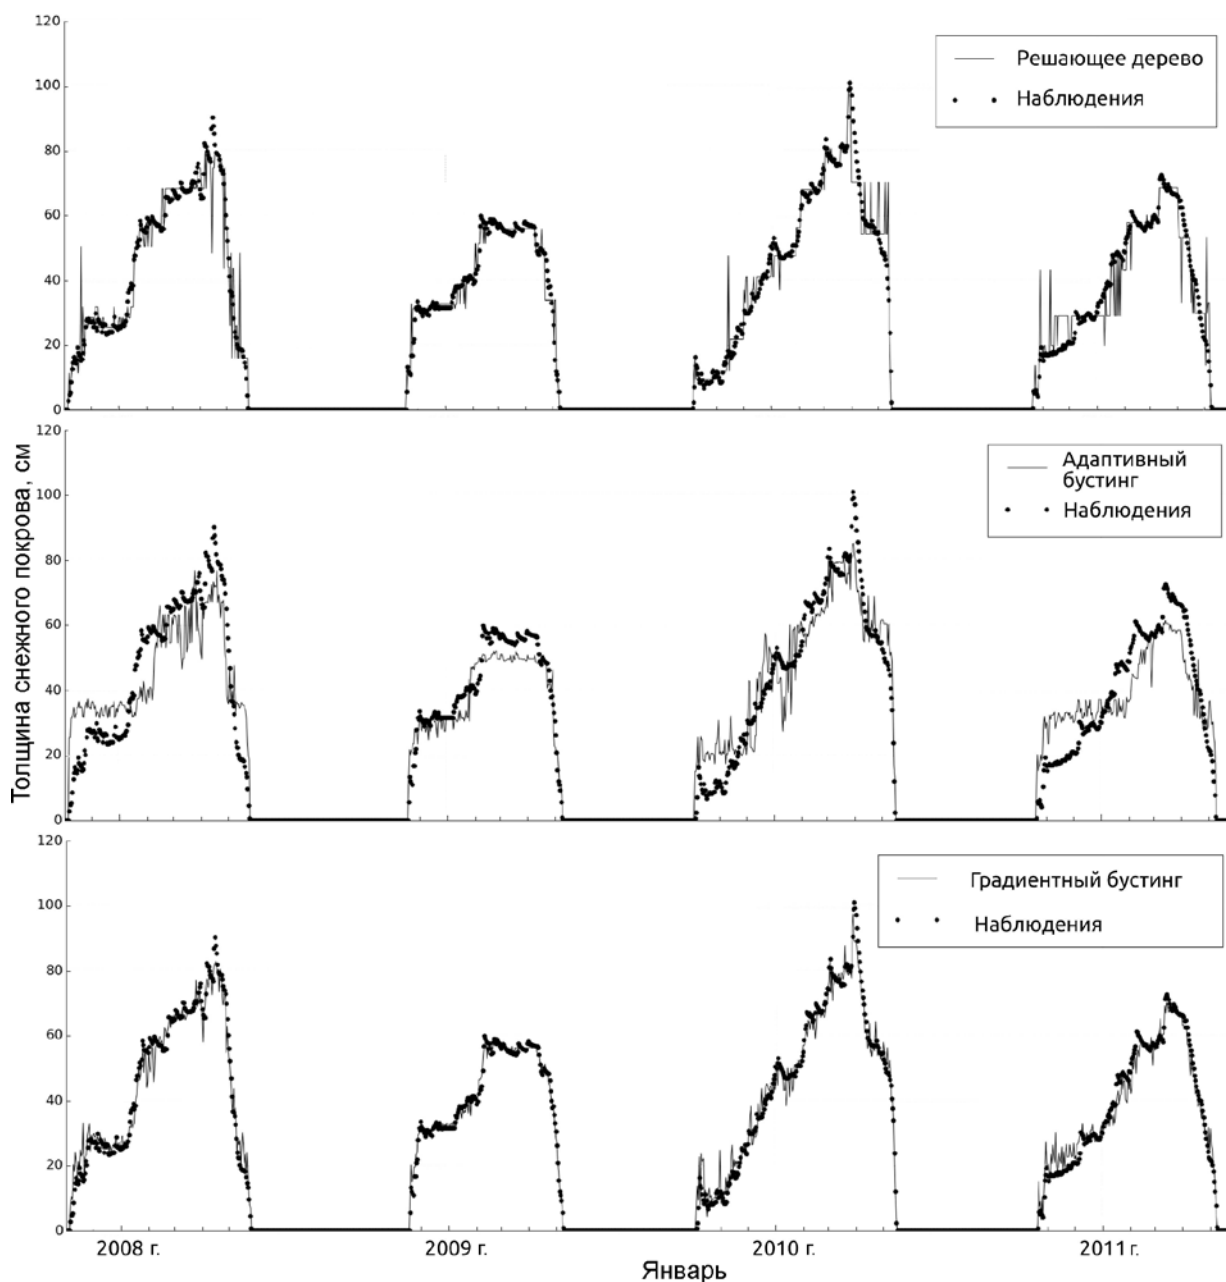
Стационар	Критерии эффективности	
	$R^2$	$MAE$ , см
Коль де Порт (Франция)	0,82 <sup>1*</sup> /0,62 <sup>2*</sup> /0,94 <sup>3*</sup>	8,1/16,0/5,6
Соданкьюла (Финляндия)	0,91/0,79/0,97	3,5/8,3/2,7
Снокуалми Пасс (США)	0,83/0,79/0,96	20,7/30,9/11,5

<sup>1\*</sup>Решающее дерево; <sup>2\*</sup>адаптивный бустинг; <sup>3\*</sup>градиентный бустинг.

ных для исследования устойчивости модели на продолжительном независимом периоде наблюдений, мы применили подход кросс-валидации методом выброшенной точки, при котором в обучающую выборку входят все доступные значения целевой переменной, кроме одного, для которого проводятся независимые расчёты адаптированной к выборке моделью. Такой подход позволяет вычислить модельные значения целевой переменной (в нашем случае толщины снежного покрова) независимо для каждого объекта выборки, что удовлетворяет принципу полного использования данных наблюдений и позволяет снизить вероятность переобучения применяемых статистических моделей [23, 27]. Предложенный подход успешно апробирован в работе [13], где показал результаты, сравнимые с перекрёстной групповой кросс-валидацией.

Обобщённые результаты эффективности моделирования толщины снежного покрова с помощью используемых в работе методов приведены в табл. 2. Для каждого из стационаров в отдельности за весь исследуемый период с использованием всех трёх моделей машинного обучения рассчитывалась динамика толщины снежного покрова (стационар Соданкьюла – рис. 2, Коль де Порт – рис. 3, Снокуалми Пасс – рис. 4). Далее определяли критерии соответствия модельных значений толщины снежного покрова данным натурных наблюдений – коэффициент детерминации  $R^2$  и среднюю величину абсолютного отклонения  $MAE$ , позволяющие количественно оценить обобщающую способность используемых моделей.

Эффективность применения модели градиентного бустинга над решающими деревьями оказалась выше, чем моделей одиночного решающего дерева и адаптивного бустинга, по обоим

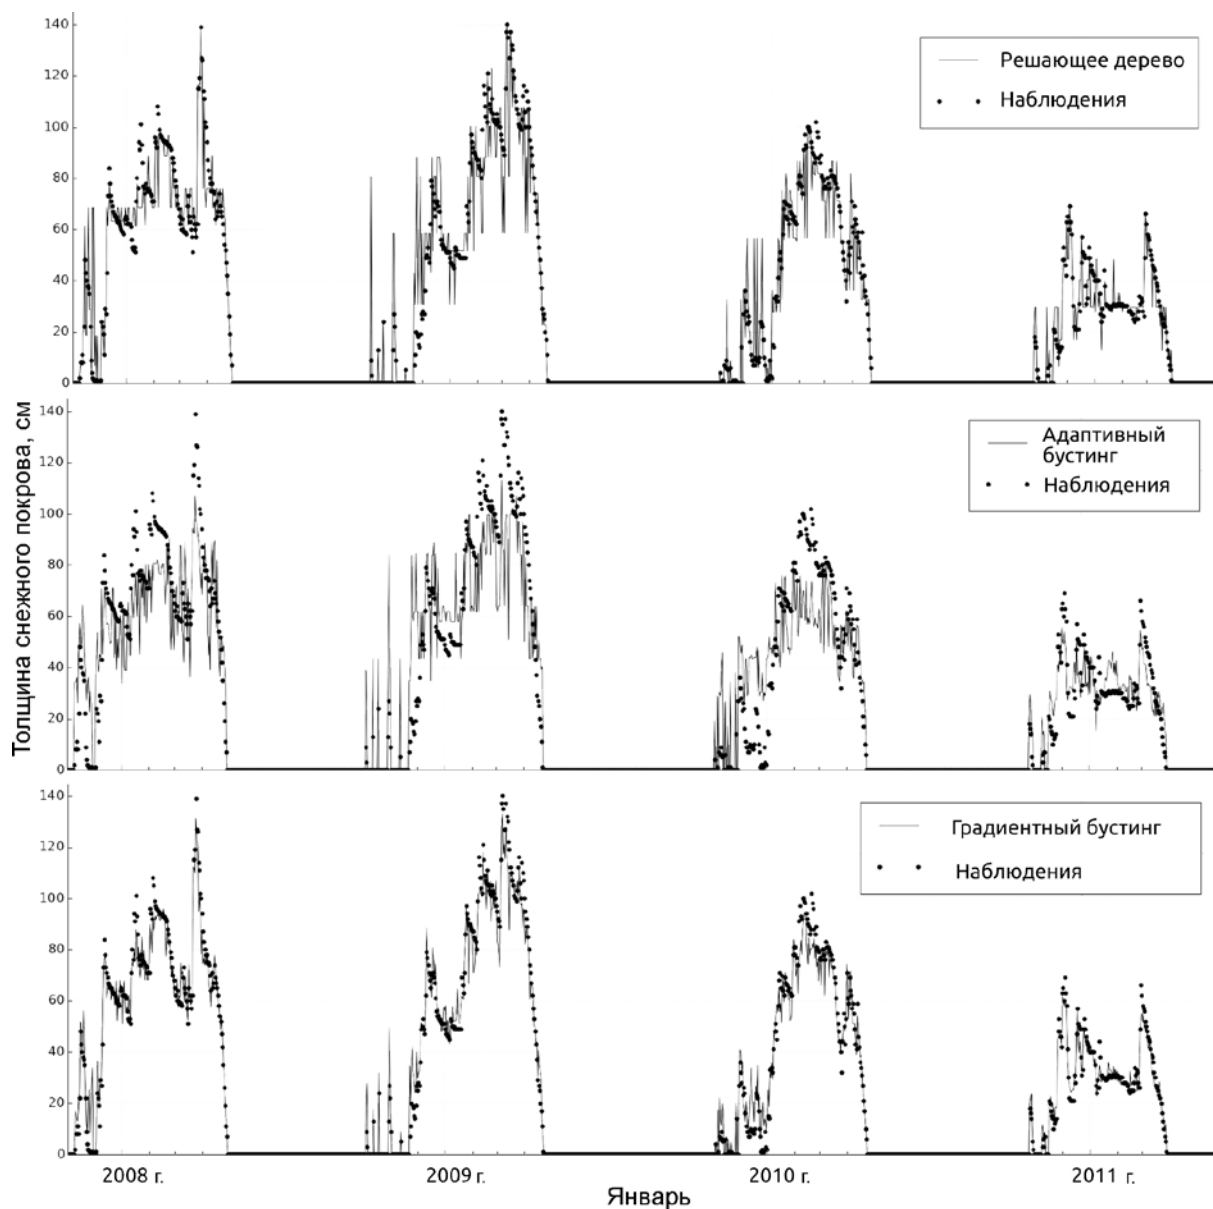


**Рис. 2.** Толщина снежного покрова на стационаре Соданкюла по данным наблюдений и рассчитанная с помощью моделей машинного обучения

**Fig. 2.** Observational and calculated with machine learning models snow depth data on the Sodankyla station

статистическим критериям, что можно объяснить направленным характером обучения модели градиентного бустинга, а также эффективностью использования процедур бэггинга, бустрепа и усечения при обучении модели. Эти данные подтверждают обобщённые в работах [23, 25] результаты о лидирующих показателях семейства моделей градиентного бустинга среди современных методов машинного обучения.

Модель одиночного решающего дерева превосходит по производительности модель адаптивного бустинга, что связано, в первую очередь, с использованием в качестве элементарных моделей ансамбля решающих деревьев малой глубины, очевидно, не способных хорошо обобщить сложную динамику процесса снегонакопления — максимальная толщина снежного покрова для всех стационаров существенно занижается (см.



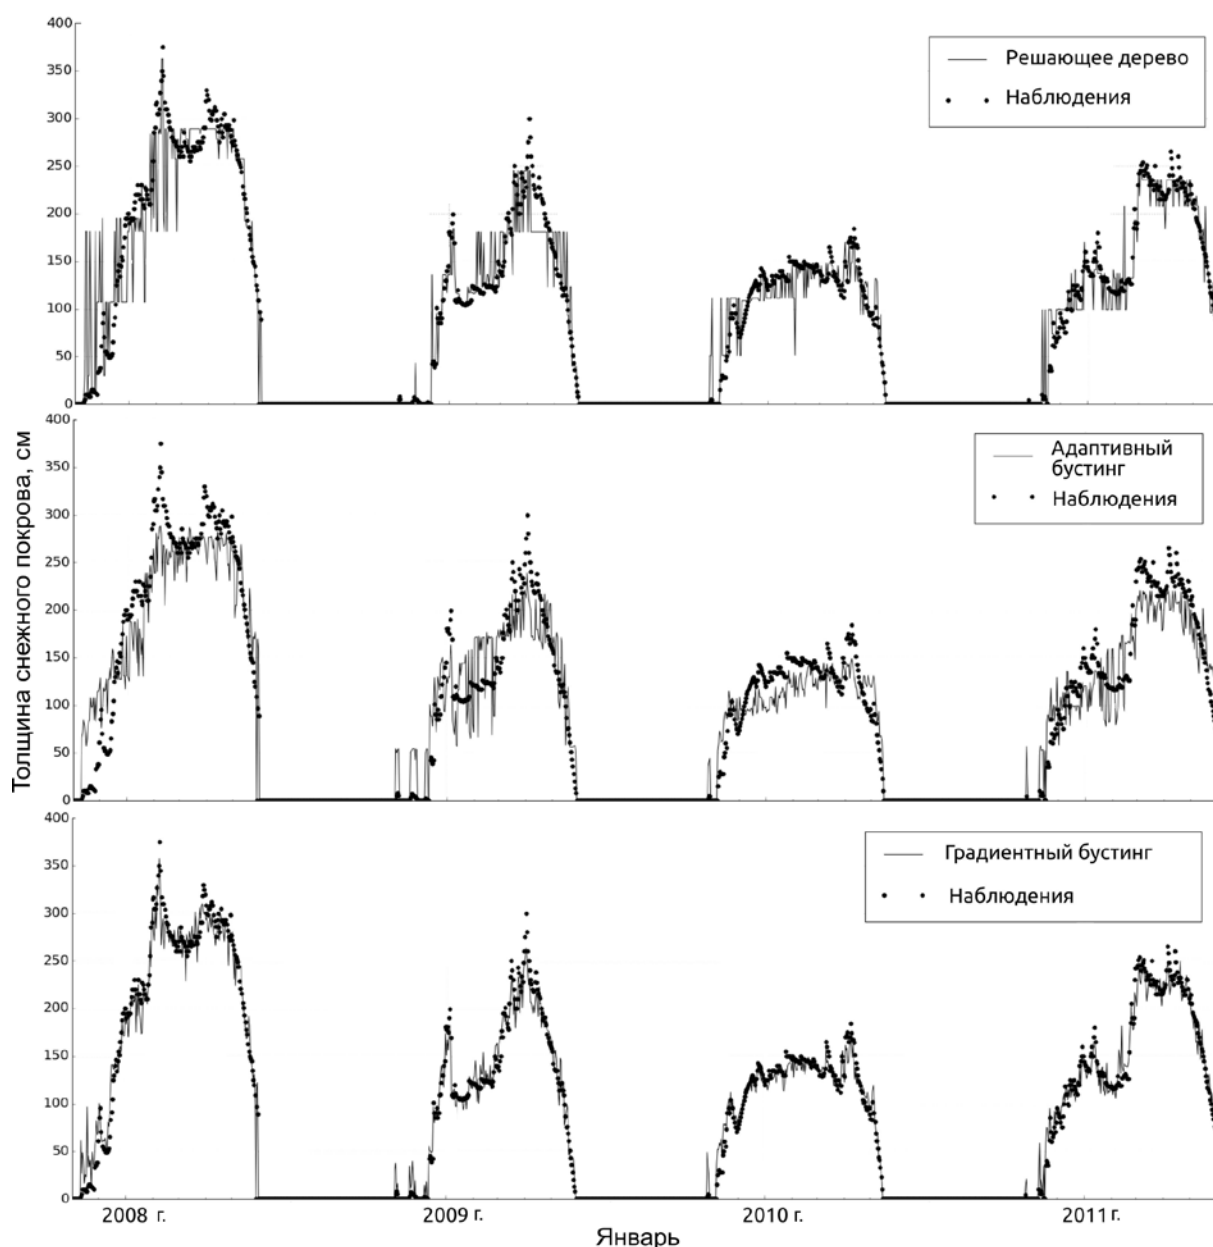
**Рис. 3.** Толщина снежного покрова на стационаре Коль де Порт по данным наблюдений и рассчитанная с помощью моделей машинного обучения

**Fig. 3.** Observational and calculated with machine learning models snow depth data on the Col de Porte station

рис. 2–4). Необходимо отметить и повышенную чувствительность моделей одиночного решающего дерева и адаптивного бустинга к шумам в данных, о чём свидетельствуют сравнительно высокие оценки  $MAE$  (особенно характерно для расположенных в горах стационаров Коль де Порт и Снокуалми Пасс, см. рис. 3, 4). К сожалению, слабая устойчивость к шумам — общее место для всех алгоритмов, основанных на решающих деревьях [23]. Для постпроцессингового сглаживания результатов моделирования перспективно использование

некоторых статистических приложений из теории сигналов (например, фильтрации Винера).

Отметим ожидаемый результат лучшей эффективности методов машинного обучения в моделировании толщины снежного покрова на стационаре Соданкюла (см. рис. 2), который расположен на равнинной местности по сравнению со стационарами Коль де Порт и Снокуалми Пасс, расположенными в горных районах (см. рис. 3, 4). Таким образом, надёжность методов машинного обучения напрямую зависит от



**Рис. 4.** Толщина снежного покрова на стационаре Снокуалми Пасс по данным наблюдений и рассчитанная помощью моделей машинного обучения

**Fig. 4.** Observational and calculated with machine learning models snow depth data on the Snoqualmie Pass station

физико-географических особенностей расположения исследуемого объекта.

### Выводы

Полученные результаты показывают высокую эффективность применения современных методов машинного обучения для решения задачи моделирования динамики толщины снежного

покрова в различных географических условиях. Модель градиентного бустинга над решающими деревьями дала лучшие результаты по сравнению с моделями одиночного решающего дерева и адаптивного бустинга для всех исследуемых объектов и рассматриваемых сезонов снегонакопления. Несмотря на хорошие результаты моделирования, требуются дополнительное исследование обобщающей способности и устойчивости используемых моделей на более длинных рядах



наблюдений и независимых стационарах, а также оценка их использования в условиях недостатка данных прямых метеорологических наблюдений. Для применения полученных результатов при решении гидрологических задач перспективно привлечение спутниковой информации о состоянии снежного покрова, которая позволила бы найти региональные зависимости снегозапаса от его толщины [28] и напрямую включить модельные ряды наблюдений в расчётные схемы гидрологических моделей формирования стока.

Предложенная схема применения методов машинного обучения для моделирования толщины снежного покрова характеризуется простотой реализации и позволяет разработать программный персонифицированный продукт, который в реальном времени позволяет получить информацию о наблюдаемой толщине снежного покрова [29] и прогнозировать её динамику в соответствии с ожидаемой метеорологической обстановкой. Усилия в данном направлении пре-

доставят локальным сообществам удобный инструмент наблюдения и оценки характеристик снежного покрова и, как следствие, позволят им сформировать дополнительный источник информации для исследований пространственных особенностей распределения снежного покрова [30].

**Благодарности.** Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 16-35-00159 мол\_а. Первичная обработка исходных данных и моделирование динамики снежного покрова на стационарах Снокуалми Пасс и Коль де Порт выполнено при финансовой поддержке РНФ в рамках научного проекта №16-17-10039.

**Acknowledgements.** The reported study was funded by RFBR according to the research project № 16-35-00159 mol\_a. Initial data mining and snow depth modeling on Snoquamie Pass and Col de Porte stations were carried out with RSF financial support according to the research project № 16-17-10039.

## Литература

1. Brun E., Durand Y., Martin E., Braun L. Snow modeling as an efficient tool to simulate snow cover evolution at different spatial scales // IAHS Publications-Series of Proceedings and Reports-Intern Assoc Hydrological Sciences. 1994. V. 223. P. 163–176.
2. Gusev E.M., Nasonova O.N., Dzhogan L.Y., Ayzel G.V. Simulating the formation of river runoff and snow cover in the northern West Siberia // Water Resources. 2015. V. 42. № 4. P. 460–467. doi: 10.1134/S0097807815040065.
3. Гельфан А.Н., Морейдо В.М. Динамико-стохастическое моделирование формирования снежного покрова на Европейской территории России // Лёд и Снег. 2014. Т. 54. № 2. С. 44–52. doi: 10.15356/2076-6734-2014-2-44-52.
4. Singh P., Spitzbart G., Hübl H., Weinmeister H.W. Hydrological response of snowpack under rain-on-snow events: a field study // Journ. of Hydrology. 1997. V. 202. № 1. P. 1–20. doi: 10.1016/S0022-1694(97)00004-8.
5. СНиП 2.01.07–85. Нагрузки и воздействия. М.: изд. Минстроя России, 1996. 82 с.
6. Борзенкова А.В., Шмакин А.Б. Изменения толщины снежного покрова и суточной интенсивности снегопадов, влияющие на расходы по уборке магистралей в российских городах // Лёд и Снег. 2012. Т. 52. № 2. С. 59–70. doi: 10.15356/2076-6734-2012-2-59-70.
7. Armstrong R.L., Brun E. Snow and Climate. Physical Processes, Surface Energy Exchange and Modeling. Cambridge: Cambridge Univ. Press, 2008. 222 p.

## References

1. Brun E., Durand Y., Martin E., Braun L. Snow modeling as an efficient tool to simulate snow cover evolution at different spatial scales. IAHS Publications-Series of Proceedings and Reports-Intern Assoc Hydrological Sciences. 1994, 223: 163–176.
2. Gusev E.M., Nasonova O.N., Dzhogan L.Y., Ayzel G.V. Simulating the formation of river runoff and snow cover in the northern West Siberia. Water Resources. 2015, 42 (4): 460–467. doi: 10.1134/S0097807815040065.
3. Gelfan A.N., Moreido V.M. Dynamic-stochastic modeling of snow cover formation on the European territory of Russia. *Led i Sneg. Ice and Snow*. 2014, 54 (2): 44–52. doi: 10.15356/2076-6734-2014-2-44-52 [In Russian].
4. Singh P., Spitzbart G., Hübl H., Weinmeister H.W. Hydrological response of snowpack under rain-on-snow events: a field study. *Journ. of Hydrology*. 1997, 202 (1): 1–20. doi: 10.1016/S0022-1694(97)00004-8.
5. SNiP 2.01.07-85. *Nagruzki i vozdeystviya*. Load and Force. Moscow, 1996: 82 p. [In Russian].
6. Borzenkova A.V., Shmakin A.B. Changes in the snow cover thickness and of daily snowfall intensity affecting the highways cleaning expenses in russian cities. *Led i Sneg. Ice and Snow*. 2012, 52 (2): 59–70. doi: 10.15356/2076-6734-2012-2-59-70 [In Russian].
7. Armstrong R.L., Brun E. Snow and Climate. Physical Processes, Surface Energy Exchange and Modeling. Cambridge: Cambridge Univ. Press, 2008: 222 p.

8. Сократов В.С., Шмакин А.Б. Численное моделирование снежного покрова на о. Гукера (архипелаг Земля Франца-Иосифа) // Лёд и Снег. 2013. Т. 53. № 3. С. 55–62. doi: 10.15356/2076-6734-2013-3-55-62.
9. Anderson E.A. National Weather Service river forecast system: Snow accumulation and ablation model. V. 17. US Department of Commerce, National Oceanic and Atmospheric Administration, National Weather Service, 1973. 217 p.
10. Etchevers P., Martin E., Brown R., Fierz C., Lejeune Y., Bazile E., Boone A., Dai Y.-J., Essery R., Fernandez A., Gusev Y., Jordan R., Koren V., Kowalczyk E., Nasonova O., Pyles R.D., Schlosser A., Shmakin A.B., Smirnova T.G., Strasser U., Verseghy D., Yamazaki T., Yang Z.-L. Validation of the energy budget of an alpine snowpack simulated by several snow models (SnowMIP project) // Annals of Glaciology. 2004. V. 38. № 1. P. 150–158. doi: 10.3189/172756404781814825.
11. Henderson-Sellers A., Pitman A.J., Love P.K., Irannejad P., Chen T.H. The project for intercomparison of land surface parameterization schemes (PILPS): Phases 2 and 3 // Bulletin of the American Meteorological Society. 1995. V. 76. №. 4. P. 489–503. doi: 10.1175/1520-0477(1995)076<0489:TPFIOL>2.0.CO;2.
12. Gusev E.M., Nasonova O.N., Dzhoghan L.Y. Physically based modeling of many-year dynamics of daily streamflow and snow water equivalent in the Lena R. basin // Water Resources. 2016. V. 43. № 1. P. 21–32. doi: 10.1134/S0097807816010085.
13. Айзель Г.В. Расчеты речного стока для неизученных бассейнов: потенциал применения гидрологической модели и аппарата искусственных нейронных сетей // Инженерные изыскания. 2014. № 7. С. 60–66.
14. Elder K., Michaelsen J., Dozier J. Small basin modeling of snow water equivalence using binary regression tree methods // IAHS Publications-Series of Proceedings and Reports-Intern Assoc Hydrological Sciences. 1995. V. 228. P. 129–140.
15. Gharaei-Manesh S., Fathzadeh A., Taghizadeh-Mehrjardi R. Comparison of artificial neural network and decision tree models in estimating spatial distribution of snow depth in a semi-arid region of Iran // Cold Regions Science and Technology. 2016. № 122. P. 26–35. doi: 10.1016/j.coldregions.2015.11.004.
16. Balk B., Elder K. Combining binary decision tree and geostatistical methods to estimate snow distribution in a mountain watershed // Water Resources Research. 2000. V. 36. № 1. P. 13–26. doi: 10.1029/1999WR900251.
17. Волчек А.А., Костюк Д.А., Петров Д.О. Оценка водного эквивалента снега по данным пассивного микроволнового сканирования земной поверхности с использованием искусственных нейронных сетей для территории Российской Федера-
8. Sokratov V.S., Shmakin A.B. Numerical modeling of snow cover on Hooker Island (Franz Josef Land archipelago). *Led i Sneg*. Ice and Snow. 2013, 53 (3): 55–62. doi: 10.15356/2076-6734-2013-3-55-62 [In Russian].
9. Anderson E.A. National Weather Service river forecast system: Snow accumulation and ablation model. US Department of Commerce, National Oceanic and Atmospheric Administration, National Weather Service, 1973 (17): 217 p.
10. Etchevers P., Martin E., Brown R., Fierz C., Lejeune Y., Bazile E., Boone A., Dai Y.-J., Essery R., Fernandez A., Gusev Y., Jordan R., Koren V., Kowalczyk E., Nasonova O., Pyles R.D., Schlosser A., Shmakin A.B., Smirnova T.G., Strasser U., Verseghy D., Yamazaki T., Yang Z.-L. Validation of the energy budget of an alpine snowpack simulated by several snow models (SnowMIP project). *Annals of Glaciology*. 2004, 38 (1): 150–158. doi: 10.3189/172756404781814825.
11. Henderson-Sellers A., Pitman A.J., Love P.K., Irannejad P., Chen T.H. The project for intercomparison of land surface parameterization schemes (PILPS): Phases 2 and 3. *Bulletin of the American Meteorological Society*. 1995, 76 (4): 489–503. doi: 10.1175/1520-0477(1995)076<0489:TPFIOL>2.0.CO;2.
12. Gusev E.M., Nasonova O.N., Dzhoghan L.Y. Physically based modeling of many-year dynamics of daily streamflow and snow water equivalent in the Lena R. basin. *Water Resources*. 2016, 43 (1): 21–32. doi: 10.1134/S0097807816010085.
13. Ayzel G.V. Runoff calculations for ungauged basins: potential of hydrological model and artificial neural networks use. *Inzhenernye izyskaniya*. Engineering Research. 2014, 7: 60–66. [In Russian].
14. Elder K., Michaelsen J., Dozier J. Small basin modeling of snow water equivalence using binary regression tree methods. *IAHS Publications-Series of Proceedings and Reports-Intern Assoc Hydrological Sciences*. 1995, 228: 129–140.
15. Gharaei-Manesh S., Fathzadeh A., Taghizadeh-Mehrjardi R. Comparison of artificial neural network and decision tree models in estimating spatial distribution of snow depth in a semi-arid region of Iran. *Cold Regions Science and Technology*. 2016, 122: 26–35. doi: 10.1016/j.coldregions.2015.11.004.
16. Balk B., Elder K. Combining binary decision tree and geostatistical methods to estimate snow distribution in a mountain watershed. *Water Resources Research*. 2000, 36 (1): 13–26. doi: 10.1029/1999WR900251.
17. Volchek A.A., Kostyuk D.A., Petrov D.O. Water equivalent of snow retrieved from data of passive microwave scanning with the use of artificial neural networks over the Russian Federation territory. *Led i Sneg*. Ice and Snow. 2016, 56 (1): 43–51. doi: 10.15356/2076-6734-2016-1-43-51 [In Russian].

- ции // Лёд и Снег. 2016. Т. 56. № 1. С. 43–51. doi: 10.15356/2076-6734-2016-1-43-51.
18. Электронный ресурс: *Buitinck L., Louppe G., Blondel M., Pedregosa F., Mueller A., Grisel O., Niculae V., Prettenhofer P., Gramfort A., Grobler J., Layton R., VanderPlas J., Joly A., Holt B., Varoquaux G.* API design for machine learning software: experiences from the scikit-learn project // arXiv preprint. 2013. <http://arxiv.org/abs/1309.0238>.
  19. Электронный ресурс: *Morin S., Lejeune Y., Lesaffre B., Panel J.-M., Poncet D., David P., Sudul M.* A 18-years long (1993–2011) snow and meteorological dataset from a mid-altitude mountain site (Col de Porte, France, 1325 altitude). 2012. <https://doi.pangaea.de/10.1594/PANGAEA.774249>.
  20. Электронный ресурс: Arctic research centre of Finnish Meteorological Institute: observations on Sodankyla station (Finland). <http://litdb.fmi.fi/index.php>.
  21. *Wayand N.E., Massmann A., Butler C., Keenan E., Stemberis J., Lundquist J.D.* A meteorological and snow observational data set from Snoqualmie Pass (921 m), Washington Cascades, USA // Water Resources Research. 2015. V. 51. № 12. P. 10092–10103. doi: 10.1002/2015WR017773.
  22. *Breiman L., Friedman J., Stone C.J., Olshen R.A.* Classification and regression trees. CRC press, 1984. 360 p.
  23. *Hastie T., Tibshirani R., Friedman J., Franklin J.* The elements of statistical learning: data mining, inference and prediction. Springer, 2005. 758 p.
  24. *Freund Y., Schapire R.E.* A decision-theoretic generalization of on-line learning and an application to boosting // Journ. of computer and system sciences. 1997. V. 55. № 1. P. 119–139. doi: 10.1007/3-540-59119-2\_166.
  25. *Schapire R.E., Freund Y.* Boosting: Foundations and algorithms. MIT press, 2012. 528 p.
  26. *Friedman J.H.* Greedy function approximation: a gradient boosting machine // Annals of Statistics. 2001. V. 29. № 5. P. 1189–1232.
  27. *Kohavi R.* A study of cross-validation and bootstrap for accuracy estimation and model selection // Intern. Joint Conf. on Artificial Intelligence (Ijcai). 1995. V. 14. № 2. P. 1137–1145.
  28. *Jonas T., Marty C., Magnusson J.* Estimating the snow water equivalent from snow depth measurements in the Swiss Alps // Journ. of Hydrology. 2009. V. 378. №. 1. P. 161–167. doi: 10.1016/j.jhydrol.2009.09.021.
  29. *Hinkler J., Pedersen S.B., Rasch M., Hansen B.U.* Automatic snow cover monitoring at high temporal and spatial resolution, using images taken by a standard digital camera // Intern. Journ. of Remote Sensing. 2002. V. 23. № 21. P. 4669–4682. doi: 10.1080/01431160110113881.
  30. *Muller C.L., Chapman L., Johnston S., Kidd C., Illingworth S., Foody G., Overeem A., Leigh R.R.* Crowdsourcing for climate and atmospheric sciences: current status and future potential // Intern. Journ. of Climatology. 2015. V. 35. № 11. P. 3185–3203. doi: 10.1002/joc.4210.
  18. Internet source: *Buitinck L., Louppe G., Blondel M., Pedregosa F., Mueller A., Grisel O., Niculae V., Prettenhofer P., Gramfort A., Grobler J., Layton R., VanderPlas J., Joly A., Holt B., Varoquaux G.* API design for machine learning software: experiences from the scikit-learn project // arXiv preprint. 2013. <http://arxiv.org/abs/1309.0238>.
  19. Internet source: *Morin S., Lejeune Y., Lesaffre B., Panel J.-M., Poncet D., David P., Sudul M.* A 18-years long (1993–2011) snow and meteorological dataset from a mid-altitude mountain site (Col de Porte, France, 1325 altitude). 2012. <https://doi.pangaea.de/10.1594/PANGAEA.774249>.
  20. Internet source: Arctic research centre of Finnish Meteorological Institute: observations on Sodankyla station (Finland). <http://litdb.fmi.fi/index.php>.
  21. *Wayand N.E., Massmann A., Butler C., Keenan E., Stemberis J., Lundquist J.D.* A meteorological and snow observational data set from Snoqualmie Pass (921 m), Washington Cascades, USA. Water Resources Research. 2015, 51 (12): 10092–10103. doi: 10.1002/2015WR017773.
  22. *Breiman L., Friedman J., Stone C.J., Olshen R.A.* Classification and regression trees. CRC press, 1984: 360 p.
  23. *Hastie T., Tibshirani R., Friedman J., Franklin J.* The elements of statistical learning: data mining, inference and prediction. Springer, 2005: 758 p.
  24. *Freund Y., Schapire R.E.* A decision-theoretic generalization of on-line learning and an application to boosting. Journ. of computer and system sciences. 1997, 55 (1): 119–139. doi: 10.1007/3-540-59119-2\_166.
  25. *Schapire R.E., Freund Y.* Boosting: Foundations and algorithms. MIT press, 2012: 528 p.
  26. *Friedman J.H.* Greedy function approximation: a gradient boosting machine. Annals of Statistics. 2001, 29 (5): 1189–1232.
  27. *Kohavi R.* A study of cross-validation and bootstrap for accuracy estimation and model selection. Intern. Joint Conf. on Artificial Intelligence (Ijcai). 1995, 14 (2): 1137–1145.
  28. *Jonas T., Marty C., Magnusson J.* Estimating the snow water equivalent from snow depth measurements in the Swiss Alps. Journ. of Hydrology. 2009, 378 (1): 161–167. doi: 10.1016/j.jhydrol.2009.09.021.
  29. *Hinkler J., Pedersen S.B., Rasch M., Hansen B.U.* Automatic snow cover monitoring at high temporal and spatial resolution, using images taken by a standard digital camera. Intern. Journ. of Remote Sensing. 2002, 23 (21): 4669–4682. doi: 10.1080/01431160110113881.
  30. *Muller C.L., Chapman L., Johnston S., Kidd C., Illingworth S., Foody G., Overeem A., Leigh R.R.* Crowdsourcing for climate and atmospheric sciences: current status and future potential. Intern. Journ. of Climatology. 2015, 35 (11): 3185–3203. doi: 10.1002/joc.4210.