УДК 504.064.2.001.18 doi: 10.25750/1995-4301-2025-4-037-043

Сравнение моделей множественной регрессии и многослойного персептрона при картировании поверхностного распределения пыли в снеговом покрове

© 2025. А. С. Буторова, м. н. с.,
А. В. Шичкин, н. с., А. П. Сергеев, к. ф.-м. н., в. н. с.,
А. Г. Буевич, н. с., Е. М. Баглаева, к. ф.-м. н., с. н. с.,
Институт промышленной экологии УрО РАН,
620990, Россия, г. Екатеринбург, ул. С. Ковалевской, д. 20,
e-mail: a.s.butorova@urfu.ru

Снеговой покров служит информативным индикатором загрязнения атмосферного воздуха, поскольку аккумулирует и консервирует вещества, поступающие из атмосферы в составе осадков. Моделирование поверхностного распределения содержания загрязняющих веществ в снеговом покрове предполагает подбор предикторов, которые максимизируют прогностическую способность моделей. Цель настоящей работы заключалась в сравнении моделей множественной регрессии и многослойного персептрона при картографировании поверхностного распределения пыли в снеговом покрове в южной части г. Нового Уренгоя (Ямало-Ненецкий автономный округ, Россия). Предложено применение к подбору пространственных переменных подхода Land Use Regression (LUR), который использует данные о взаимном расположении потенциальных источников загрязнения и мест отбора проб для построения модели множественной линейной регрессии. Чтобы учесть нелинейные связи между предикторами модели и концентрацией пыли, использовался многослойный персептрон (MLP). Всего тестировались четыре различных модели: две на основе LUR и две на основе MLP. Наилучшую производительность показала модель MLP с выбранными для стандартной LUR модели предикторами, к которым добавили координаты мест отбора проб. Выбранные предикторы содержали пространственную информацию о распределении пыли; добавление к ним географических координат позволило дополнить модель геостатистической информацией и улучшить предсказательную способность модели. Модели LUR и MLP, которые использовали пространственные переменные, учитывающие расположение потенциальных источников загрязнения, позволили построить карты распределения пыли, демонстрирующие влияние этих источников на поверхностное распределение пыли, накопленной в снеговом покрове.

Ключевые слова: снеговой покров, содержание пыли, поверхностное распределение, картирование, land use regression, многослойный персептрон.

Comparison of multiple regression and multilayer perceptron models for mapping the surface distribution of dust in snow cover

© 2025. A. S. Butorova ORCID: 0000-0002-1570-6642,
A. V. Shichkin ORCID: 0000-0002-0081-1853, A. P. Sergeev ORCID: 0000-0001-7883-6017,
A. G. Buevich ORCID: 0000-0003-4964-2787, E. M. Baglaeva ORCID: 0000-0001-8400-5017,
Institute of Industrial Ecology of the Ural Branch of the Russian Academy of Sciences,
20, S. Kovalevskoy St., Ekaterinburg, Russia, 620990,
e-mail: a.s.butorova@urfu.ru

Snow cover is an informative indicator of atmospheric air pollution since it accumulates and preserves pollutants coming from the atmosphere as part of precipitation. Modeling the surface distribution of pollutant content in snow cover involves selecting predictors that maximize the predictive ability of the models. The purpose of this study was to compare multiple regression and multilayer perceptron models for mapping the dust surface distribution in the snow cover in the southern part of Novy Urengoy (Yamalo-Nenets Autonomous Okrug, Russia). The authors proposed applying to the selection of spatial variables a Land Use Regression (LUR) approach, which uses data on the relative positions of potential pollution sources and sampling sites to build a multiple linear regression model. To consider the nonlinear relationships between model predictors and dust concentration, a neural network model, a multilayer perceptron (MLP), was used. A total of four different models were tested: two LUR- and two MLP-based models. The MLP model with selected for the standard LUR model predictors and added coordinates of the sampling sites shows the best performance. The selected predictors contain spatial information about dust distribution. The added geographical coordinates made it possible to

supplement the model with geostatistical information and improve its predictive ability. Finally, surface dust distribution maps were restored using four models and kriging. LUR and MLP models with spatial variables, which considered the location of potential pollution sources, produced dust distribution maps demonstrating the influence of these sources on surface distribution of dust accumulated in the snow cover.

Keywords: snow cover, dust content, surface distribution, mapping, land use regression, multilayer perceptron.

При экологическом мониторинге, помимо наблюдения непосредственно за уровнем загрязнения атмосферы, выполняют отбор проб атмосферных осадков, определяют содержание загрязняющих веществ (ЗВ) в почве, растительности, снеговом покрове [1–3]. Снеговой покров является информативным индикатором загрязнения не только поступающих из атмосферы осадков, но и атмосферного воздуха [4]. Во-первых, снеговой покров как естественный планшет-накопитель позволяет достаточно объективно оценить величину сухих и влажных выпадений в холодный сезон. Снег аккумулирует и консервирует ЗВ в результате процессов сухого и влажного вымывания. Во-вторых, наблюдаемая концентрация ЗВ в снеговом покрове, как правило, на несколько порядков выше, чем концентрация ЗВ в атмосферном воздухе, что позволяет измерять концентрации ЗВ в снеговом покрове достаточно простыми методами и с высокой степенью надёжности. Было показано, что снег может служить индикатором загрязнения атмосферы сульфатами [5], нитратами [6], тяжёлыми металлами [7–9], аммонием [10], полициклическими ароматическими и нефтяными углеводородами [11, 12] и рядом других веществ [13, 14].

Отбор проб снегового покрова не требует сложного оборудования по сравнению, например, с отбором проб воздуха. Одна проба снега, взятая на полную глубину снегового покрова, даёт репрезентативные данные о загрязнении в период от момента образования устойчивого снегового покрова до момента отбора пробы. Отбор проб снега сосредоточен в регионах Земли, где снеговой покров остаётся устойчивым постоянно или сезонно. В высокогорных ландшафтах, таких как Тибетское нагорье, некоторое количество снегового покрова сохраняется почти круглый год [15]. В Канаде, Чили, Китае, Дании, Финляндии, Швеции, Исландии, Норвегии, России, на севере Соединённых Штатов Америки и Канады снеговой покров образуется ежегодно и сохраняется на протяжении не менее одного месяца с перерывами, не превышающими трёх дней [1, 16].

Мониторинг загрязнения снегового покрова включает в себя методы оценки и моделирования (прогноза) состояния снегового покрова [2, 17, 18]. Моделирование поверхностного распределения ЗВ предполагает подбор предикторов, которые максимизируют прогностическую способность модели. Для построения модели множественной линейной регрессии распределения пыли в настоящей работе авторы предложили применить подход Land Use Regression (LUR) [19], основанный на использовании данных о расположении потенциальных источников загрязнения (промышленных зон, автомобильных дорог, жилых строений и др.) по отношению к местам отбора проб. Далее было принято решение дополнительно использовать модели на основе нейронных сетей, которые улавливают нелинейные взаимосвязи между переменными-предикторами и концентрацией ЗВ, так как они имеют более высокую прогностическую способность, чем модели на основе стандартного метода LUR [20–22].

Цель настоящей работы – сравнение моделей восстановления поверхностного распределения пыли в снеговом покрове и построение с помощью этих моделей карт распределений.

Объекты и методы исследования

Стандартная модель LUR в данном исследовании сравнивается с моделью на основе использования многослойного персептрона (MLP), которая, с одной стороны, продуктивна при прогнозировании нелинейных связей, и, с другой стороны, не требует значительных вычислительных ресурсов [20]. К предикторам ещё двух моделей на основе LUR и MLP добавлялись координаты мест отбора проб, что позволило учесть пространственное распределение данных. Подход LUR продуктивно дополняется моделями машинного обучения для повышения точности прогноза [20, 21]. Результативность комбинирования моделей на основе кригинга и LUR с алгоритмами машинного обучения для оценки пространственного распределения ЗВ продемонстрирована, например, в работе [22].

Исследуемая территория. В качестве исходных данных для построения и тестирования моделей в работе использовались

данные о содержании пыли, полученные в рамках масштабного скрининга снегового покрова в южной части г. Нового Уренгоя в 2007–2008 гг. Новый Уренгой – крупнейший из городов Ямало-Ненецкого автономного округа (ЯНАО), разделённый на северную и южную части двумя реками, Тамчара-Яха и Седэ-Яха. Устойчивый снеговой покров на территории образовался 15.10.2007 г., пробы снега отбирали с 22 по 27 марта 2008 г. Март в Новом Уренгое характеризуется среднемесячной температурой −15,4 °C и большим количеством осадков. Климат на территории классифицируется как Dfc по системе классификации типов климата Кёппена-Гейгера, где D – субарктический (холодный континентальный) климат, f – отсутствие сухого сезона, c – холодное лето [23].

Отбор проб. Пробы снега отбирали в узлах сетки с запланированным шагом 250 м с помощью снегомерного пробоотборника [24]. Окончательное местоположение пробы определялось с учётом местных условий и могло в некоторых случаях значительно отличаться от запланированного. При моделировании использовались координаты окончательного (реального) местоположения проб. Наблюдаемая глубина снегового покрова варьировала от 0,25 до 1,35 м в зависимости от рельефа. Пробоотборник отвесно погружался в снег на полную глубину снегового покрова до соприкосновения с подстилающей поверхностью.

Каждая проба состояла из нескольких кернов – образцов цилиндрической формы диаметром 0,1 м, отобранных методом конверта так, чтобы суммарная масса пробы была не менее 0,5 кг. Количество кернов в пробе варьировалось от 2 до 12. Чтобы исключить попадание в пробу частиц почвы, последние два сантиметра снега удалялись из керна. Все пробы были упакованы в двойные полиэтиленовые пакеты, промаркированы уникальными номерами и доставлены в аккредитованную химическую лабораторию.

Химический анализ отобранных проб проводился в соответствии с действующими на момент проведения анализа нормативными документами в аккредитованной аналитической лаборатории Института промышленной экологии УрО РАН (г. Екатеринбург, Россия).

В лаборатории пробы снега из полиэтиленовых пакетов перемещали в ёмкости и растапливали при комнатной температуре. Талую воду отфильтровывали через заранее подготовленные и взвешенные фильтры. Фильтры с осадком твёрдых частиц (твёрдой фазой) просушивали, после чего твёрдую фазу пробы подвергали химическому анализу. Содержание твёрдых частиц (пыли) в пробе вычисляли как отношение массы твёрдой фазы к объёму пробы (в мг/л).

Выбор источников и пространственных переменных. В качестве исходных данных использовали концентрации твёрдых частиц (пыли) в пробе (в мг/л). Для моделирования было отобрано 150 проб снега, из них 125 проб вошли в тренировочный набор, 25 – в тестовый.

Источники загрязнения – основные и второстепенные автомобильные дороги – выбирали исходя из предметного предположения о наличии связи между расположением автомобильных дорог, как потенциальных источников загрязнения, и содержанием пыли в снеговом покрове.

Первоначально выбирали и рассчитывали большой набор потенциальных переменных-предикторов, из которых затем отбирали наиболее информативные. Для этого в каждом месте отбора проб строили набор буферных зон радиусами 100, 200, 300, 400 и 500 м. Буферная зона представляет собой круг с центром в месте отбора проб. В настоящей работе для построения буферных зон использовали геоинформационную систему ArcGIS.

Для каждой буферной зоны строили пересечения с выбранными источниками загрязнения и вычисляли площади этих пересечений, величины которых представляли собой пространственные переменные. В результате было получено 10 пространственных переменных: r100, r200, r300, r400, r500 – площади пересечений дорог основного типа (roads) с буферными зонами с радиусами 100, 200, 300, 400, 500 м соответственно; sr100, sr200, sr300, sr400, sr500 – площади пересечений дорог второстепенного типа (subroads) с буферными зонами с радиусами 100, 200, 300, 400, 500 м соответственно.

Следующий шаг – выбор из 10 пространственных переменных наиболее информативных предикторов для моделей. Все пары переменных были проверены на мультиколлинеарность – наличие сильной линейной корреляции между переменными регрессионной модели. В результате были отброшены предикторы со значением коэффициента инфляции дисперсии (VIF), превышающим 3 [25]. Оставшиеся три пространственных переменных r100, r500 и sr500 имели значения VIF 1,35, 1,55 и 1,18, соответственно.

В среде Matlab тестировали три модели линейной регрессии: 1) модель, содержащую

линейную комбинацию предикторов (параметр 'linear' функции fitlm()); 2) модель, содержащую линейную комбинацию предикторов и квадраты этих предикторов (параметр 'purequadratic' функции fitlm()); 3) модель, содержащую линейную комбинацию предикторов, квадраты этих предикторов и все попарные произведения предикторов (параметр 'quadratic' функции fitlm()). Прогноз, полученный с помощью модели на основе чисто квадратичной линейной регрессии ('purequadratic'), оказался самым точным. Таким образом, в качестве предикторов использовали три отобранных переменных r100, r500, sr500 и их квадраты $(r100)^2$, $(r500)^2$, $(sr500)^2$ – всего 6 предикторов.

Модели. В работе были протестированы четыре различные модели: 1) стандартная модель LUR с шестью выбранными предикторами; 2) модель LUR, в которой к шести выбранным предикторам добавляли географические координаты мест отбора проб (модель LUR+XY); 3) модель MLP с использованием шести выбранных предикторов; 4) модель MLP, в которой к шести выбранным предикторам добавляли географические координаты мест отбора проб (модель MLP+XY) (рис. 1).

Исходными данными для модели LUR были измеренные концентрации тренировочного набора (125 значений) и шесть выбранных предикторов. Прогноз строили на основе уравнения множественной линейной регрессии. Производительность LUR модели проверяли на значениях тестового набора.

В модели LUR+XY к шести исходным предикторам добавляли координаты мест отбора проб X и Y, что позволило учесть пространственное расположение мест отбора проб. Прогноз строили на основе уравнения множественной линейной регрессии, как в исходной LUR модели.

Модель MLP представляла собой многослойный персептрон с входным, скрытым и выходным слоями с функцией активации гиперболический тангенс. Скрытый слой состоял из 7 нейронов. Обучение MLP проводилось по алгоритму Левенберга-Марквардта. На вход MLP подавали значения тренировочного набора и набор выбранных предикторов. На выходе MLP получали значения концентрации пыли, предсказанные по тестовому набору.

В модели MLP+XY прогноз строили с помощью MLP с той же структурой, что и у предыдущей модели. На вход сети в дополнение к шести предикторам исходной LUR модели подавали географические координаты мест отбора проб. На выходе обученного MLP получали предсказанные значения концентрации пыли.

Результаты и обсуждение

В таблице представлены результаты оценки производительности моделей. Самую высо-

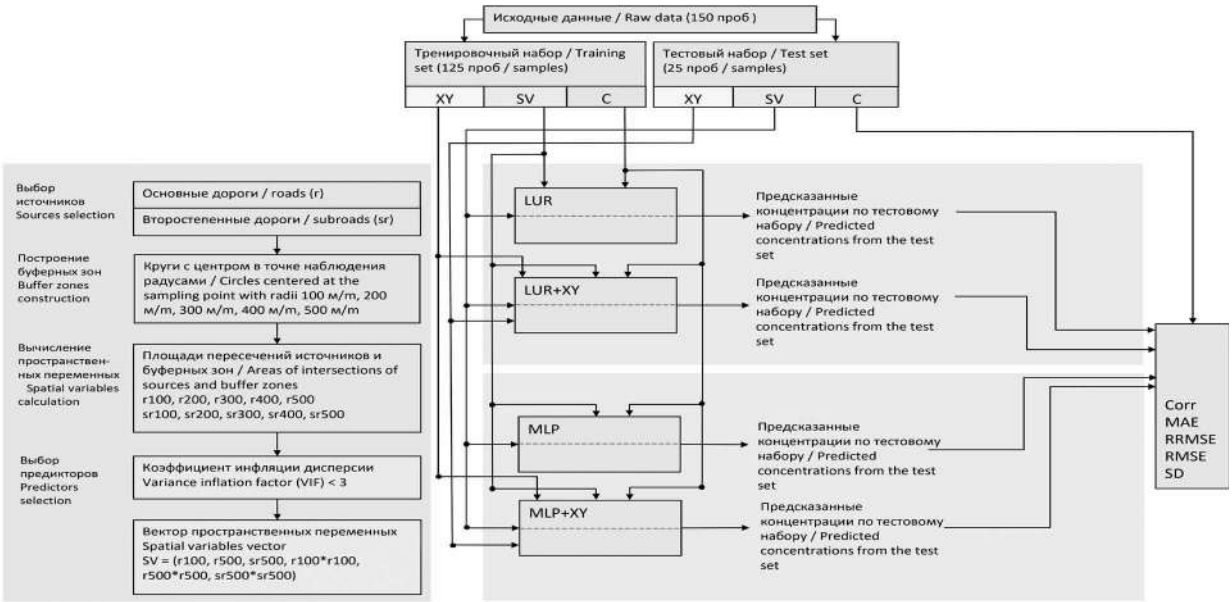

Рис. 1. Схема исследования. Здесь и в таблице: Corr – коэффициент корреляции, MAE – средняя абсолютная ошибка, RRMSE – относительная среднеквадратическая ошибка, RMSE – среднеквадратическая ошибка, SD – стандартное отклонение

Fig. 1. Research scheme. Here and in the table: Corr – correlation coefficient, MAE – mean absolute error, RRMSE – relative root mean square error, RMSE – root mean square error, SD – standard deviation

А. С. Буторова, А. В. Шичкин, А. П. Сергеев, А. Г. Буевич, Е. М. Баглаева «Сравнение моделей множественной регрессии и многослойного персептрона при картировании поверхностного распределения пыли в снеговом покрове». С. 37.

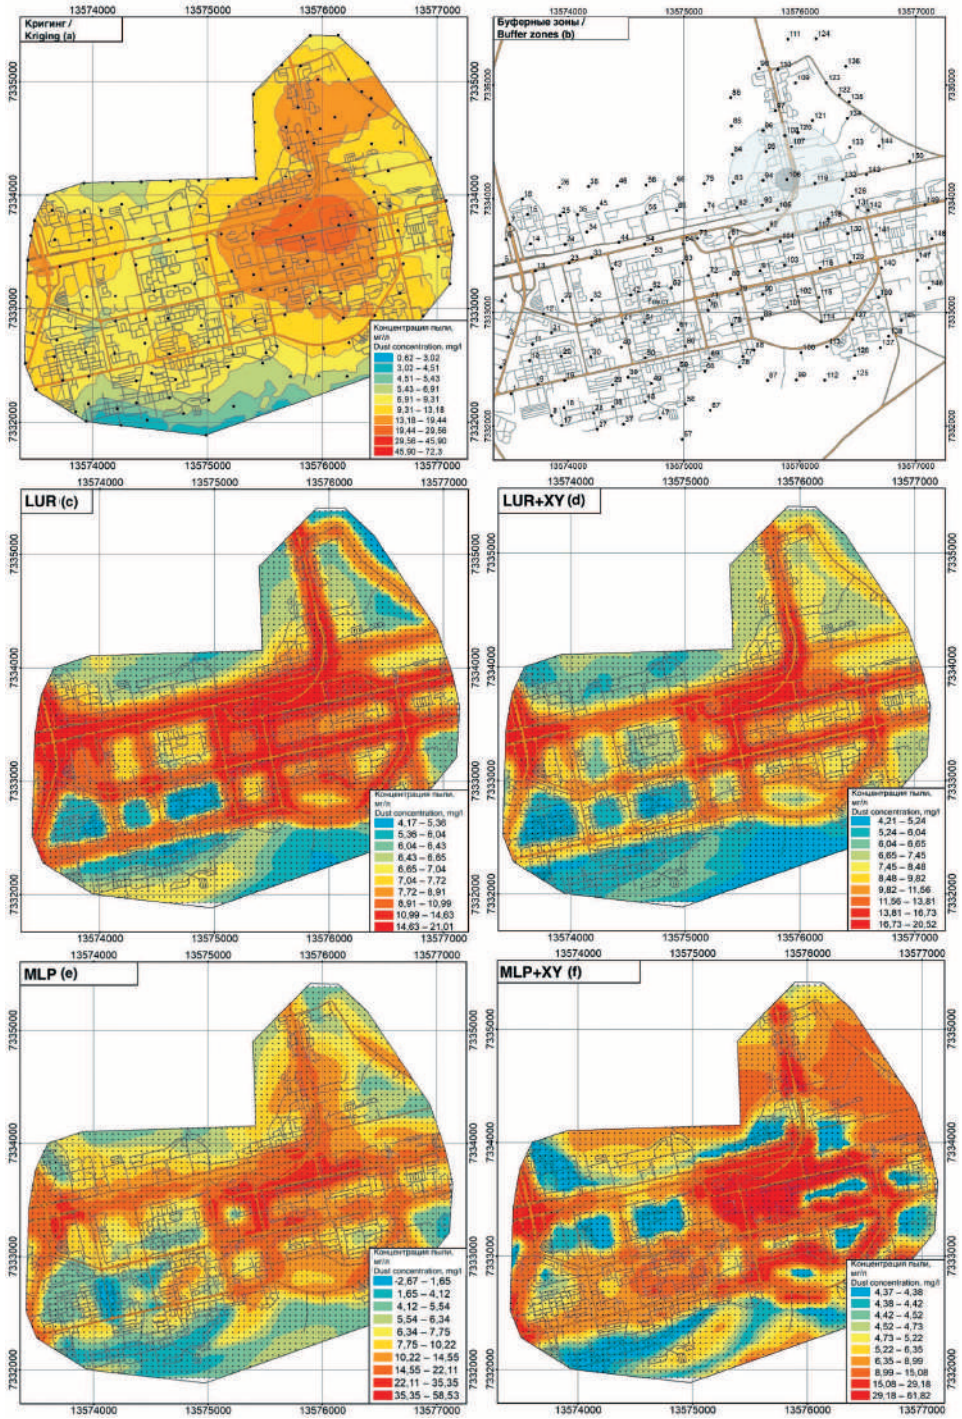

Рис. 2. Моделирование поверхностного распределения пыли в снеговом покрове: (a) – результат кригинга, (b) – пример построения буферных зон радиусом 100 и 500 м для пробы № 106, (c)–(f) – результаты моделей на основе LUR и MLP
Fig. 2. Modelling of dust surface distribution in snow cover: (a) – the result of kriging, (b) – an example of buffer zones constructing with 100 and 500 m radius for sample No. 106, (c)–(f) – the results of LUR- and MLP-based models

Таблица / Table

Оценка производительности моделей / Model performance assessme

Модель Model	Коэффициент корреляции Correlation coefficient	MAE	RRMSE	RMSE	SD
LUR	0,66	10,39	1,21	16,61	3,58
LUR+XY	0,69	10,13	1,09	16,3	3,96
MLP	0,78	8,97	0,85	13,82	6,58
MLP+XY	0,81	8,64	0,7	12,82	7,67

Примечание: стандартное отклонение исходных данных составило 16,52.
Note: Standard deviation of raw data was 16.52.

кую производительность по всем показателям продемонстрировала модель MLP с исходными предикторами, выбранными для LUR модели, и координатами мест отбора проб. Традиционная LUR модель показала самую низкую производительность, однако модель LUR, в которой к исходным предикторам добавили координаты мест отбора проб, была немного точнее: коэффициент корреляции модели LUR+XY 0,69 против 0,66 у исходной LUR модели. Тем не менее, производительность модели LUR+XY ниже, чем производительность моделей на основе MLP.

Преимущества моделей на основе MLP подтверждаются полученными числовыми показателями (табл.). Добавление координат мест отбора проб к предикторам моделей позволило дополнить модели геостатистической информацией и улучшить их производительность: в случае моделей на основе MLP коэффициент корреляции равен 0,78 для MLP против 0,81 для MLP+XY. При этом производительность моделей на основе MLP выше, поскольку многослойный персептрон является нелинейной моделью и позволяет более точно описать связь между пространственными переменными и концентрацией ЗВ на исследуемой территории.

Для восстановления поверхностного распределения пыли на исследуемой территории была построена регулярная сетка с шагом 50 м (рис. 2, см. цв. вкладку II).

Для каждой точки сетки строилось поверхностное распределение содержания пыли с помощью классического геостатистического метода кригинга [26] и моделей на основе LUR и MLP. Карта поверхностного распределения пыли, построенная с помощью кригинга, не даёт представления о связи между концентрацией ЗВ и источниками загрязнения. На рисунке 3а можно отметить только то, что концентрация пыли выше в центральной части города, это естественным образом можно объяснить интенсивным автомобильным трафиком в оживлённом городском районе.

Карты поверхностного распределения пыли, построенные с применением LUR-подхода, свидетельствуют о наличии связи между содержанием пыли в снеговом покрове и расположением автомобильных дорог на территории южной части г. Новый Уренгой. Поскольку ЗВ, выбрасываемые источником, распространяются и рассеиваются, то, чем дальше находится место отбора проб от источника загрязнения, тем меньшая концентрация ЗВ в ней наблюдается.

Как показали результаты исследования, карты поверхностного распределения содержания пыли, восстановленные моделями MLP с применением LUR-подхода, имеют более высокую точность, поскольку MLP способен улавливать нелинейные взаимосвязи между подобранными предикторами и содержанием пыли в снеговом покрове. Кроме того, построение предикторов с применением LUR подхода позволило сократить объём данных, необходимых для обучения MLP.

Область наибольшего загрязнения снегового покрова наблюдается со смещением от одной из центральных дорог ул. Магистральной к югу. Улица является магистральной и связывает между собой городские микрорайоны, промышленные и социально-значимые объекты, обеспечивает подъезд к внешнегородским автомобильным дорогам, в том числе к дорогам до г. Надым и г. Старый Уренгой. На ул. Магистральную приходится основной поток движения легкового, грузового, коммерческого и общественного транспорта.

Заключение

Важная часть работы при построении прогноза заключалась в подборе предикторов модели. Предикторы выбирали исходя из предметного предположения о наличии связи между концентрацией пыли и расположением автомобильных дорог. Наилучшую производительность показала модель MLP с предикторами, выбранными для исходной LUR модели,

к которым добавили координаты мест отбора проб. Совместное использование выбранных предикторов и данных по географическим координатам позволило дополнить модель геостатистической информацией и улучшить итоговую предсказательную способность модели.

Таким образом, модели на основе нейронных сетей, в частности MLP, показали достаточно высокую производительность на небольшом наборе данных благодаря подбору информативных предикторов. Использование MLP позволило улавливать нелинейную монотонную связь между концентрацией пыли в снеговом покрове и пространственными переменными. При этом количество нейронов в скрытом слое MLP было малым, чтобы сеть не переобучалась. Можно заключить, что для повышения прогностической точности предпочтительно использовать модели машинного обучения, которые способны улавливать нелинейные взаимосвязи между переменными-предикторами и концентрацией ЗВ.

Исследование выполнено за счет субсидий Минобрнауки РФ на выполнение научной темы FUMN-2024-0003.

References

1. Nazarenko Y., Ariya P.A. Interaction of air pollution with snow and seasonality effects // Atmosphere. 2021. V. 12. No. 4. Article No. 490. doi: 10.3390/atmos12040490

2. Szwed M., Kozłowski R. Snow cover as an indicator of dust pollution in the area of exploitation of rock materials in the Świętokrzyskie Mountains // Atmosphere. 2022. V. 13. No. 3. Article No. 409. doi: 10.3390/atmos13030409

3. Trifonova T.A., Kurochkin I.N., Kurbatov Yu.N. Heavy metals in soils of various functional zones of urbanized territories: assessment of the content and environmental risk // Theoretical and Applied Ecology. 2023. No. 2. P. 38–46 (in Russian). doi: 10.25750/1995-4301-2023-2-038-046

4. Vasilenko V.N., Nazarov I.M., Fridman Sh.D. Snow pollution monitoring. Leningrad: Gidrometeoizdat, 1985. 181 p. (in Russian).

5. Molozhnikova Ye.V., Shikhovtsev M.Yu., Netsvetaeva O.G., Khodzher T.V. Ecological zoning of the Baikal basin based on the results of chemical analysis of the composition of atmospheric precipitation accumulated in the snow cover // Appl. Sci. 2023. V. 13. No. 14. Article No. 8171. doi: 10.3390/app13148171

6. Cui X., Ouyang W., Liu L., Guo Z., Zhu W. Nitrate losses from forest during snowmelt: An underestimated source in mid-high latitude watershed // Water Res. 2024. V. 249. Article No. 121005. doi: 10.1016/j.watres.2023.121005

7. Vijayan A., Österlund H., Marsalek J., Viklander M. Laboratory melting of late-winter urban snow samples: the magnitude and dynamics of releases of heavy metals and PAHs // Air Soil Pollut. 2019. V. 230. No. 8. Article No. 182. doi: 10.1007/s11270-019-4201-2

8. Zhang F., Meng B., Gao S., Hough R., Hu P., Zhang Z., Yu S., Li K., Liu Z., Cui S. Levels, inventory, and risk assessment of heavy metals in wetland ecosystem, Northeast China: Implications for snow cover monitoring // Water. 2021. V. 13. No. 16. Article No. 2161. doi: 10.3390/w13162161

9. Yakovlev E., Druzhinina A., Zykova E., Zykov S., Ivanchenko N. Assessment of heavy metal pollution of the snow cover of the Severodvinsk industrial district (NW Russia) // Pollution. 2022. V. 8. No. 4. P. 1274–1293. doi: 10.22059/poll.2022.341500.1438

10. Tian R., Tian L. Two decades ammonium records from ice core in Qiangyong glacier in the Northern Himalayas // Atmos. Res. 2019. V. 222. P. 36–46. doi: 10.1016/j.atmosres.2019.02.004

11. Sun L., Ai X., Yao X., An Q., Liu X., Yakovleva E., Zhang L., Sun H., Zhang K., Zang S. Relationship between atmospheric pollution and polycyclic aromatic hydrocarbons in fresh snow during heavy pollution episodes in a cold city, northeast China // Ecotoxicol. Environ. Saf. 2023. V. 260. Article No. 115091. doi: 10.1016/j.ecoenv.2023.115091

12. Cui S., Song Z., Zhang L., Zhang Z., Hough R., Fu Q., An L., Shen Z., Li Y.-F., Liu D., Gao S. Polycyclic aromatic hydrocarbons in fresh snow in the city of Harbin in northeast China // Atmos. Environ. 2019. V. 215. Article No. 116915. doi: 10.1016/j.atmosenv.2019.116915

13. Mezina K., Melgunov M., Belyanin D. ^{7}Be, $^{210}Pb_{atm}$ and ^{137}Cs in snow deposits in the Arctic part of Western Siberia (Yamal-Nenets Autonomous District) // Atmosphere. 2020. V. 11. No. 8. Article No. 825. doi: 0.3390/atmos11080825

14. Saltan N.V., Sviatkovskaya E.A., Trostenyuk N.N. Assessment of snow cover pollution in urban ecosystems of the Kola North in the zone of influence of railway branches // Theoretical and Applied Ecology. 2022. No. 1. P. 78–83 (in Russian). doi: 10.25750/1995-4301-2022-1-078-083

15. Kopanev I.D. Methods for studying snow cover. Leningrad: Gidrometizdat, 1971. 226 p. (in Russian).

16. Sergeev A.P., Shichkin A.V., Buevich A.G., Baglaeva E.M. Counter-prediction approach to predict the missing values of a spatial series on the example of the dustiness in the snow cover // Model. Earth Syst. Environ. 2023. V. 9. P. 1523–1530. doi: 10.1007/s40808-022-01577-2

17. Rakhmatova A.Y., Sergeev A.P., Shichkin A.V., Buevich A.G., Baglaeva E.M. Three-day forecasting of greenhouse gas CH_4 in the atmosphere of the Arctic Belyy Island using discrete wavelet transform and artificial neural

networks // Neural Comput. Applic. 2021. V. 33. No. 16. P. 10311–10322. doi: 10.1007/s00521-021-05792-3

18. Israel Yu.A., Filippova L.N., Insarov G.E. Semevskiy F.N., Semenov S.M. Environmental monitoring and regulation of the state of the natural environment // Problems of ecological monitoring and ecosystem modelling. V. 4. Leningrad: Gidrometeoizdat, 1981. P. 6–19 (in Russian).

19. Briggs D.J., Collins S., Elliott P., Fischer P., Kingham S., Lebret E., Pryl K., van Reeuwijk H., Smallbone K., van der Veen A. Mapping urban air pollution using GIS: a regression-based approach // Int. J. Geogr. Inf. Sci. 1997. V. 11. No. 7. P. 699–718. doi: 10.1080/136588197242158

20. Han L., Zhao J., Gao Y., Gu Z. Prediction and evaluation of spatial distributions of ozone and urban heat island using a machine learning modified land use regression method // Sustainable Cities Soc. 2022. V. 78. No. 2. Article No. 103643. doi: 10.1016/j.scs.2021.103643

21. Champendal A., Kanevski M., Huguenot P.-E. Air pollution mapping using nonlinear land use regression models // Computational science and its applications: proceedings of the International conference. V. 8581. Cham: Springer, 2014. P. 682–690. doi: 10.1007/978-3-319-09150-1_50

22. Wong P.Y., Lee H.Y., Chen Y.C., Zeng Y.T., Chern Y.R., Chen N.T., Candice Lung S.C., Su H.J., Wu C.D. Using a land use regression model with machine learning to estimate ground level $PM_{2.5}$ // Environ. Pollut. 2021. V. 277. Article No. 116846. doi: 10.1016/j.envpol.2021.116846

23. Köppen W. Das geographische System der Klimate // Handbuch der Klimatologie / Eds. W. Köppen, R. Geiger. Bd. 1. Teil C. Berlin: Borntraeger, 1936. 44 p. (in German).

24. Sergeev A.P., Buevich A.G., Berg D.B. Snow sampler // Patent RU 80587 U1. Application: 2008131261/22, 29.07.2008. Date of publication: 10.02.2009. Bull. 4 (in Russian).

25. Sheather S. A modern approach to regression with R. New York: Springer-Verlag, 2009. 393 p. doi: 10.1007/978-0-387-09608-7

26. Matheron G. Principles of applied geostatistics. Moskva: Mir, 1968. 408 p. (in Russian).