



Разработка автоматизированного программного инструмента на основе методов машинного обучения для решения задач радиопланирования на участках метрополитена

А. А. Адёркина^а, аспирант, преподаватель, orcid.org/0000-0003-4331-4301, aaderkina@mail.ru

А. С. Синицын^а, студент, orcid.org/0000-0002-0793-950X

^аНациональный исследовательский Нижегородский государственный университет им. Н. И. Лобачевского, Гагарина пр., 23, Нижний Новгород, 603950, РФ

Введение: современный подход к радиопланированию обеспечивает пассажирам метрополитена бесперебойный доступ к сети Интернет благодаря использованию специальной модели распространения сигнала, которая вычисляет величины потерь мощности сигнала при его распространении между передатчиком и приемником на линиях метрополитена. Недостатком модели является высокая вычислительная сложность. **Цель:** разработать алгоритм предсказания величин потерь мощности сигнала с использованием методов машинного обучения, характеризующийся высокой точностью и низкой вычислительной сложностью. **Результаты:** анализ методов машинного обучения выявил, что максимально возможную точность при решении поставленной задачи обеспечивает метод случайного леса. Разработана структура данных для обучения выбранного метода и предсказания величин потерь мощности сигнала, содержащая параметры цифровой карты линий метрополитена. Сформирован ряд допущений при разработке итогового алгоритма: задача решается методом классификации, предсказываемые значения являются целыми числами. Разработан алгоритм предсказания величин потерь мощности сигнала, не использующий модель распространения напрямую, что снизило вычислительную сложность и уменьшило время выполнения задач радиопланирования при сохранении высокой точности предсказания. **Практическая значимость:** благодаря использованию методов машинного обучения в разработанных алгоритмах время выполнения задач радиопланирования сократилось с нескольких дней до нескольких часов с сохранением точности, что позволяет обрабатывать большее количество заказов по радиопланированию или же сокращать время работы инженеров на выполнение такого же количества заказов, что приводит к финансовой выгоде.

Ключевые слова — машинное обучение, потери мощности сигнала, алгоритмы предсказания, точность алгоритма, базовая станция, цифровая карта местности.

Для цитирования: Адёркина А. А., Синицын А. С. Разработка автоматизированного программного инструмента на основе методов машинного обучения для решения задач радиопланирования на участках метрополитена. *Информационно-управляющие системы*, 2022, № 5, с. 32–39. doi:10.31799/1684-8853-2022-5-32-39, EDN: IVCTMH

For citation: Aderkina A. A., Sinityn A. S. Development of an automated software tool based on machine learning methods for solving problems of radio planning in subway sections. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2022, no. 5, pp. 32–39 (In Russian). doi:10.31799/1684-8853-2022-5-32-39, EDN: IVCTMH

Введение

Применение методов искусственного интеллекта в настоящее время широко распространено во многих сферах промышленности [1]. Целью данной работы является разработка алгоритма высокой точности для предсказания величины потери мощности радиосигнала при его распространении между передатчиком и приемником вдоль линий метрополитена. Разрабатываемый алгоритм направлен на снижение вычислительной сложности применяемой в настоящее время методики радиопланирования беспроводных сетей в метрополитене [2, 3].

Развитие технологий цифровой связи приводит к разворачиванию все большего числа беспроводных сетей разных поколений и назначений. Неуклонно повышается роль беспроводной

связи в организации повседневной жизни людей, что привело к разворачиванию зон покрытия сетей Wi-Fi (семейство стандартов IEEE 802.11) на общественных пространствах, в том числе внутри тоннелей и на открытых участках метрополитена. Сети такого типа состоят из мобильных станций, размещенных на крыше подвижного состава, и стационарно расположенных вдоль маршрута поезда базовых станций (БС). Качество развернутой сети в большой степени определяется правильным выбором точек расположения БС вдоль путей [4–8].

Основную трудность при выборе координат БС представляет расчет величины затухания сигнала (Path Loss, PL) между точками расположения базовых и мобильных станций в тоннелях метрополитена, так как тоннели имеют сложную геометрию с множеством поворотов,

спусков/подъемов и рассеивателей, которые препятствуют распространению сигнала. Для формирования подхода к определению наилучших точек расположения БС вдоль пути следования поездов разработана модель распространения сигнала в указанных условиях [2, 3]. На основе разработанной модели выработан комплексный подход к определению наилучшего расположения БС вдоль путей. Разработанный подход характеризуется высокой вычислительной сложностью. Для получения финальной расстановки БС требуется в некоторых случаях время до нескольких недель, что является существенным препятствием для развертывания беспроводных сетей на большом количестве участков, перепланирования сетей или сравнения нескольких вариантов конфигурации одной сети.

С целью устранить описанный недостаток существующего подхода предлагается разработка алгоритма на основе методов машинного обучения для предсказания уровня затухания мощности сигнала [9–12]. В работе применялись современные методы, позволившие не использовать напрямую модель распространения, что, в свою очередь, снизило время и стоимость оценки покрытия [9, 13–18].

В работах разных исследовательских групп изучались различные методы машинного обучения для предсказания величины PL [13, 18] или индикатора мощности принятого сигнала [14, 15, 17] для задач сетевого планирования в городской среде [13, 16–18] и внутри помещений [14]. Во всех изученных работах процедуры обучения и тестирования выполнялись с помощью набора данных о потерях на трассе, созданного на основе результатов моделирования сети, использующей цифровую модель местности [13, 16, 18], или на основе полевых измерений [14, 17].

В работе [13] исследовались и использовались следующие алгоритмы: опорный вектор регрессии (Support Vector Machine, SVM), случайный лес (Random Forest, RF) и K-ближайших соседей (K-Nearest Neighbor, KNN). Используемые результаты моделирования включали в себя оба условия распространения — при наличии прямой видимости и без. Результаты показывают, что все оцененные алгоритмы прогнозируют потери на трассе с высокой точностью, обеспечивая среднеквадратичные ошибки порядка 2–2,2 дБ при наличии прямой видимости и 3,4–4,1 дБ без соответственно. В процессе исследований алгоритмов KNN показал наилучшую производительность, таким образом, он является предпочтительным вариантом для прогнозирования потерь на трассе в городских условиях [13].

В работе [14] представлен инструмент оценки на основе машинного обучения, использующий не модель распространения [19], а измеренные

при эксплуатации сети величины индикатора мощности принятого сигнала, зависящие от расстояния, географии и параметров конфигурации БС [20]. Собранные данные применяются для обучения классификатора. После сравнения различных алгоритмов машинного обучения результаты показали, что метод классификации на основе SVM превосходит другие классификаторы, обеспечивая точность до 86,7 % [14].

Формирование данных для обучения и применения алгоритмов машинного обучения

Термин «машинное обучение» обозначает множество математических методов, решающих задачу поиска закономерностей между входными данными (признаками) и выходными данными (ответами) объекта [21]. Объектом в решаемой задаче является процесс затухания радиосигнала при распространении между точками передатчика и приемника вдоль линий метрополитена.

Целью разрабатываемого алгоритма является предсказание величины потерь мощности при распространении сигнала вдоль линий метрополитена по характеристикам геометрии участка распространения. Таким образом, в поставленной задаче признаками объекта являются геометрические параметры области распространения сигнала (цифровой карты зоны), а ответом — величина в децибелах потери мощности сигнала при распространении. В качестве среды распространения радиосигнала рассматриваются открытые участки и тоннели метрополитена.

Для характеристического описания области распространения задается ось линии метрополитена. Для упрощения расчетов ось задается двумя кривыми в горизонтальной и вертикальной плоскостях. Вдоль оси линии в каждой плоскости вводится криволинейная координатная ось. Также линия разбивается на набор сегментов, каждый из которых имеет следующие характеристики: ширина, высота, радиус поворота в горизонтальной плоскости, длина, направление поворота (лево/право или верх/низ), величина уклона в вертикальной плоскости.

Для составления цифровой карты зоны между фиксированными двумя точками участок между ними покрывается координатной сеткой следующим образом: координата одной из точек (передатчика или приемника) объявляется начальной, далее с выбранным шагом (например, 25 м) вдоль оси линии определяются следующие узлы сетки в сторону второй точки до момента превышения ее координат. Координата последней точки округляется до ближайшего узла построенной координатной сетки. В каждом узле

полученной координатной сетки определяются следующие параметры: радиус поворота и направление в горизонтальной плоскости, величина уклона и направление уклона в вертикальной плоскости, расстояние между точками передатчика (Tx) и приемника (Rx), тип рассматриваемого участка (тоннельный/наземный).

Минимально необходимым набором признаков для описания цифровой карты зоны распространения радиосигнала были выбраны следующие метрики:

- расстояния между точкам Tx и Rx вдоль оси линии;
- направление поворота пути в точках Tx, Rx в горизонтальной плоскости;
- радиус поворота пути в точках Tx, Rx в горизонтальной плоскости;
- направление уклона пути в точках Tx, Rx в вертикальной плоскости;
- величина уклона пути в точках Tx, Rx в вертикальной плоскости;
- идентификатор типа участка (открытый/тоннельный) в точках Tx, Rx;
- усредненные метрики между точками (направление поворота, радиус поворота, направление уклона, величина уклона).

В качестве дополнительных метрик рассматривались:

- медианные метрики между точками (направление поворота, радиус поворота, направление уклона, величина уклона);
- среднеквадратичные отклонения метрик между точками (направление поворота, радиус поворота, направление уклона, величина уклона) от средних значений;
- минимальное значение метрик между точками (направление поворота, радиус поворота, направление уклона, величина уклона);
- максимальное значение метрик между точками (направление поворота, радиус поворота, направление уклона, величина уклона).

Усредненные, медианные, среднеквадратичные, минимальные и максимальные значения находятя по массиву соответствующих метрик, полученных в каждом узле нанесенной на участок сетке.

Выбор алгоритма машинного обучения и набора признаков для предсказания величины потерь мощности сигнала

Выходной ответ любой задачи, решаемой методами машинного обучения, может быть или меткой одного из набора классов, тогда это задача классификации [22], или вещественным значением, тогда это задача регрессии [21]. При проведении данного исследования были рассмо-

трены наиболее популярные алгоритмы классификации и регрессии [22]. Исследуемые модели (табл. 1) могут быть использованы для решения задач обоих типов.

В данной работе исследованы и использованы методы машинного обучения с учителем, которые представляют собой набор математических функций, преобразующих входные в выходные данные на основе примеров пар ввода-вывода [20].

В первом подходе задача решалась как задача регрессии, т. е. выходными значениями были вещественные значения PL. Для оценки методов в этом случае использовалась метрика – коэффициент детерминации R^2 , равный отношению дисперсии предсказанных данных к дисперсии исходных данных [12]. Для разумных моделей коэффициент детерминации лежит в пределах от 0 до 1, причем случай $R^2 = 1$ соответствует идеальной модели, $R^2 = 0$ – модели на уровне оптимальной «константной», $R^2 < 0$ – модели хуже «константной» (такие алгоритмы не нужно рассматривать). Оптимальным константным алгоритмом называется такой алгоритм, который всегда возвращает среднее значение ответов для объектов обучающей выборки.


При решении исследуемой задачи как задачи классификации для оценки точности используется метрика точность, равная процентному отношению правильно предсказанных значений относительно всех значений.

Результаты применения обоих подходов представлены в табл. 1. Примеры зависимостей величины PL от расстояния между точками Tx и Rx, полученные с помощью исходной модели распространения сигнала [2, 3] и алгоритма на основе метода машинного обучения, приведены на рис. 1.

По значениям метрики R^2 , близким к единице, можно сделать вывод, что модели хорошо применимы для решения задач регрессии. На примере предсказания PL методом опорных векторов (рис. 1, а) видно, что предсказанные значения хорошо повторяют реальную зависимость. Но так как значения всех моделей, приведенных

■ **Таблица 1.** Сравнение моделей машинного обучения
 ■ **Table 1.** Comparison of machine learning models

Модель	Параметр R^2	Точность
SVM	0,99	0,71
Дерево решений	0,99	0,95
Случайный лес	0,99	0,98
К-ближайших соседей	0,99	0,94
Логистическая регрессия	1	0,8



■ **Рис. 1.** Демонстрация применения методов опорных векторов (а) и случайный лес (б) для предсказания величины PL
 ■ **Fig. 1.** Demonstration of the application of SVM (а) and Random Forest (б) methods for predicting the value of PL

в таблице, близки к единице, коэффициент детерминации невозможно использовать для сравнения методов между собой.

По значениям метрики точности при решении задачи классификации видно, что этот класс модели хорошо применим для решения исходной задачи. Эти выводы подтверждаются графически на рис. 1, б, где представлен набор реальных данных и предсказанных. В результате сравнения методов для решения задач проекта был выбран метод классификации случайный лес.

При исследовании возможности достижения максимальной точности в выбранном методе рассматривалось различное количество признаков в обучающих данных [12]. В первом подходе был взят набор из 16 минимально необходимых признаков, перечисленных в предыдущем разделе. Далее рассматривался расширенный набор из 32 метрик.

Использование расширенного набора метрик привело к незначительному повышению точности алгоритма на 0,015, но увеличило время выполнения в 1,8 раза. В результате было решено пользоваться набором из основных метрик.

Таким образом, при разработке алгоритма предсказания величины затухания мощности сигнала при его распространении между двумя фиксированными точками с помощью выбранного метода машинного обучения для достижения максимальной точности предсказания были сделаны следующие допущения:

- для разрабатываемого алгоритма выбран метод классификации случайный лес;
- для использования метода классификации выходные значения предсказанных величин выражались в целых значениях децибел.

Погрешность предсказания в таком подходе составит 1 дБ;



– для обучения разработанного алгоритма и предсказания величины PL использовался набор из 16 минимально необходимых признаков.

Примеры работы алгоритма предсказания PL и его точность

В ходе разработки алгоритма решена задача предсказания величины PL по значениям геометрических параметров области распространения. Примеры применения разработанного алгоритма представлены на рис. 2, а, б. Каждая точка на кривых – величина PL между соседней БС с меньшей координатой (черные точки на рисунках) и текущей точкой (например, значение PL для точки с координатой 31 600 м – это PL между БС с координатой 31 400 и текущей точкой 31 600). Дистанция между любыми двумя соседними точками каждой кривой составляет 25 м. По приведенным примерам видно соответствие предсказанных значений со значениями, предсказанными исходной моделью [2, 3].

Точность разработанного алгоритма приведена в табл. 2, где указаны средние значения ошибки разработанного алгоритма при предсказании PL и координат расположения БС по сравнению с существующим подходом на основе исходной модели распространения сигнала [2].

Значения, приведенные в табл. 2, показывают, что разработанный алгоритм характеризуется высокой точностью, а главным его преимуществом является существенное снижение времени выполнения. Исходный алгоритм радиоплани-



■ **Рис. 2.** Применение разработанного алгоритма на тоннельном (а) и открытом (б) участке
 ■ **Fig. 2.** Application of the developed algorithm in the tunnel (а) and open (б) section

■ **Таблица 2.** Точность разработанного алгоритма
 ■ **Table 2.** Accuracy of the developed algorithm

Параметр	Значение сценария	
	тоннельного	наземного
Ошибка предсказания PL, дБ	1,9	0,3
Ошибка определения координат БС, м	107	75
Ошибка плотности БС, БС/км	0,5	0,3

рования [2] требует многократного вызова исходной модели распространения сигнала. Время выполнения радиопланирования, заключающегося в расстановке БС на одном тоннельном участке длиной 3 км линии метрополитена, составляет около часа. С помощью разработанного алгоритма предсказания PL, использующего метод случайного леса, удалось сократить время выполнения до одной минуты.

Заключение

Проведены анализ методов машинного обучения и сравнение методов регрессии и классификации; определен метод, обеспечивающий максимально возможную точность при решении поставленной задачи предсказания величины PL; разработана структура данных для обучения выбранного метода. На основании информации о цифровой карте исследуемого участка сформирован ряд допущений при разработке итогового

алгоритма предсказания величины потери мощности сигнала.

Разработанный алгоритм предсказания PL характеризуется высокой точностью и малым временем исполнения, что позволило существенно сократить время выполнения радиопланирования.

Финансовая поддержка

Работа выполнена за счет гранта Фонда содействия развитию малых форм предприятий в научно-технической сфере (№ 16184ГУ/2020) в рамках проекта «Разработка методов машинного обучения при определении оптимального количества и расположения базовых станций для обеспечения непрерывного покрытия тоннелей общественного транспорта радиосетью».

Литература

1. Тюльпа Д. Применение искусственного интеллекта в промышленности. Предпосылки и возможности. *САПР и графика*, 2020, № 1, с. 26–30. <https://sapr.ru/article/25989> (дата обращения: 15.05.2021).
2. Адёркина А. А., Шашанов М. А., Шумилов В. Ю., Трушанин А. Ю. Радиопланирование систем беспроводной связи в тоннелях метрополитена. *Радиотехнические и телекоммуникационные системы*, 2020, № 1, с. 41–53.
3. Адёркина А. А., Шашанов М. А., Шумилов В. Ю., Трушанин А. Ю. Измерение и анализ ослабления сигнала диапазона 5 ГГц при распространении вдоль участков метрополитена различного типа.

Радиотехнические и телекоммуникационные системы, 2021, № 1, с. 33–45.

4. **Domínguez-Bolaño T., Rodríguez-Piñeiro J., García-Nay J. A., Yin X., Castedo L.** Measurement-based characterization of train-to-infrastructure 2.6 GHz propagation channel in a modern subway station. *IEEE Access*, 2018, vol. 6, pp. 52814–52830. doi:10.1109/ACCESS.2018.2870564
5. **Briso-Rodríguez C., Fratilesco P., Xu Y.** Path loss modeling for train-to-train communications in subway tunnels at 900/2400 MHz. *IEEE Antennas and Wireless Propagation Letters*, 2019, vol. 18, no. 6, pp. 1164–1168. doi:10.1109/LAWP.2019.2911406
6. **Guan K., Zhong Z., Ai B., Briso-Rodríguez C.** Statistical modeling for propagation in tunnels based on distributed antenna systems. *IEEE Antennas and Propagation Society International Symposium (AP-SURSI)*, 2013, pp. 1920–1921. doi:10.1109/APS.2013.6711618
7. **Hou X., Shu H.** Research on radio network planning and optimization in TETRA digital trunking system. *IEEE Second Intern. Conf. on Instrumentation, Measurement, Computer, Communication and Control*, 2012, pp. 821–824. doi:10.1109/IMCCC.2012.198
8. **Roullier-Callaghan A.** A radio coverage and planning tool. *6th IEEE High Frequency Postgraduate Colloquium (Cat. No. 01TH8574)*, 2001, pp. 35–40. doi:10.1109/HFPSC.2001.962156
9. **Binzer T., Landstorfer F. M.** Radio network planning with neural networks. *Vehicular Technology Conf. Fall 2000. IEEE VTS Fall VTC2000. 52nd Vehicular Technology Conf. (Cat. No. 00CH37152)*, 2000, vol. 2, pp. 811–817. <https://ieeexplore.ieee.org/document/887116> (дата обращения: 15.08.2021).
10. **Van Nguyen T., Jeong Y., Shin H., Win M. Z.** Machine learning for wideband localization. *IEEE Journal on Selected Areas in Communications*, 2015, vol. 33, no. 7, pp. 1357–1380. doi:10.1109/JSAC.2015.2430191
11. **Alvizu R., Troia S., Maier G., Pattavina A.** Matheuristic with machine-learning-based prediction for software-defined mobile metro-core networks. *Journal of Optical Communications and Networking*, 2017, vol. 9, no. 9, pp. D19–D30.
12. **VanderPlas J.** *Python data science handbook: Essential tools for working with data.* O'Reilly Media, Inc., 2017. 546 p.
13. **Moraitis N., Tsipi L., Vouyioukas D.** Machine learning-based methods for path loss prediction in urban environment for LTE networks. *16th Intern. Conf. on Wireless and Mobile Computing, Networking and Communications (WiMob), Thessaloniki (Greece)*, 2020. <https://ieeexplore.ieee.org/document/9253369> (дата обращения: 15.08.2021).
14. **Dai L., Zhang H., Zhuang Y.** Propagation-model-free coverage evaluation via machine learning for future 5G networks. *IEEE 29th Annual Intern. Symp. on Personal, Indoor and Mobile Radio Communications (PIMRC)*, 2018. <https://ieeexplore.ieee.org/document/8580992> (дата обращения: 15.08.2021).
15. **Moysen J., Giupponi L., Mangues-Bafalluy J.** A machine learning enabled network planning tool. *IEEE 27th Annual Intern. Symp. on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, 2016, pp. 1–7.
16. **Abdallah A. A., Saab S. S., Kassas Z. M.** A machine learning approach for localization in cellular environments. *IEEE/ION Position, Location and Navigation Symp. (PLANS)*, 2018, pp. 1223–1227.
17. **Politanskyi R., Klymash M.** Application of artificial intelligence in cognitive radio for planning distribution of frequency channels. *3rd Intern. Conf. on Advanced Information and Communications Technologies (AICT)*, 2019, pp. 390–394.
18. **Vallejo-Cabrejas G., Batolome-Pascual P.** Application of radio channel modelling to a planning tool in a mobile radio indoor communication system. *IEEE 43rd Vehicular Technology Conf.*, 1993, pp. 219–222.
19. **Dai L., Zhang H.** Propagation-model-free base station deployment for mobile networks: Integrating machine learning and heuristic methods. *IEEE Access*, 2020, vol. 8, pp. 83375–83386. doi:10.1109/ACCESS.2020.2990631
20. **Raj N.** Indoor RSSI prediction using machine learning for wireless networks. *Intern. Conf. on COMMunication Systems & NETWORKS (COMSNETS)*, 2021, pp. 372–374. <https://ieeexplore.ieee.org/document/9352852> (дата обращения: 15.08.2021).
21. **Müller A. C., Guido S.** *Introduction to machine learning with Python: A guide for data scientists.* O'Reilly Media, Inc., 2016. 398 p.
22. **Le J.** *The top 10 machine learning algorithms every beginner should know.* https://builtin.com/data-science/tour-top-10-algorithms-machine-learning-newbies?utm_campaign=News&utm_medium=Community&utm_source=DataCamp.com (дата обращения: 05.02.2021).

UDC 004.021, 004.896, 004.852
doi:10.31799/1684-8853-2022-5-32-39
EDN: IVCTMH

Development of an automated software tool based on machine learning methods for solving problems of radio planning in subway sections

A. A. Aderkina^a, Post-Graduate Student, Lecturer, orcid.org/0000-0003-4331-4301, aaderkina@mail.ru
A. S. Sinitsyn^a, Student, orcid.org/0000-0002-0793-950X

^aNational Research Lobachevsky State University of Nizhny Novgorod, 23, Gagarin Ave., 603950, Nizhny Novgorod, Russian Federation

Introduction: The modern approach to radio planning provides subway passengers with uninterrupted access to the Internet. This is achieved through the use of a special signal propagation model which calculates signal power loss during its propagation between a transmitter and a receiver on subway lines. The disadvantage of the model is the high computational complexity. **Purpose:** Using machine learning methods to develop an algorithm for predicting the signal power loss, the algorithm being characterized by high accuracy and low computational complexity. **Results:** The analysis of machine learning methods revealed that the maximum possible accuracy in solving the problem is provided by the random forest method. A data structure containing the parameters of a digital map of subway lines was developed to train the selected method and predict a signal power loss. While developing the final algorithm a number of assumptions were made, such as: the problem is solved as a classification problem, the predicted values are integers. A signal power loss prediction algorithm that does not directly use the propagation model was developed, which reduced the computational complexity and the execution time for solving radio planning problems, with high prediction accuracy maintained. **Practical relevance:** Due to the use of machine learning methods in developed algorithms the time for performing radio planning was reduced from several days to several hours, with accuracy preserved. This allows to process more radio planning orders or to reduce the working time for engineers to complete the same number of orders, which is a financial benefit.

Keywords – machine learning, signal power loss, prediction algorithms, accuracy of an algorithm, base station, digital map.

For citation: Aderkina A. A., Sinitsyn A. S. Development of an automated software tool based on machine learning methods for solving problems of radio planning in subway sections. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2022, no. 5, pp. 32–39 (In Russian). doi:10.31799/1684-8853-2022-5-32-39, EDN: IVCTMH

Financial support

The work was supported by a grant from the Foundation for the Promotion of the Development of Small Forms of Enterprises in the Scientific and Technical Sphere (No. 16184GU/2020) as part of the project “Development of machine learning methods for determining the optimal number and location of base stations to ensure continuous coverage of public transport tunnels with a radio network”.

Reference

1. Tyulpa D. The use of artificial intelligence in industry. Prerequisites and opportunities. *SAPR i grafika*, 2020, no. 1, pp. 26–30. Available at: <https://sapr.ru/article/25989> (accessed 15 May 2021) (In Russian).
2. Aderkina A. A., Shashanov M. A., Shumilov V. Yu., Trushanin A. Yu. Radio planning of wireless communication systems in metro tunnels. *Radio Engineering and Telecommunication Systems*, 2020, no. 1, pp. 41–53 (In Russian).
3. Aderkina A. A., Shashanov M. A., Shumilov V. Yu., Trushanin A. Yu. Measurement and analysis of signal attenuation in the 5 GHz band during propagation along various types of subway sections. *Radio Engineering and Telecommunication Systems*, 2021, no. 1, pp. 33–45 (In Russian).
4. Domínguez-Bolaño T., Rodríguez-Piñero J., García-Nay J. A., Yin X., Castedo L. Measurement-based characterization of train-to-infrastructure 2.6 GHz propagation channel in a modern subway station. *IEEE Access*, 2018, vol. 6, pp. 52814–52830. doi:10.1109/ACCESS.2018.2870564
5. Briso-Rodríguez C., Fratilesco P., Xu Y. Path loss modeling for train-to-train communications in subway tunnels at 900/2400 MHz. *IEEE Antennas and Wireless Propagation Letters*, 2019, vol. 18, no. 6, pp. 1164–1168. doi:10.1109/LAWP.2019.2911406
6. Guan K., Zhong Z., Ai B., Briso-Rodríguez C. Statistic modeling for propagation in tunnels based on distributed antenna systems. *IEEE Antennas and Propagation Society Intern. Symp. (APSURSI)*, 2013, pp. 1920–1921. doi:10.1109/APS.2013.6711618
7. Hou X., Shu H. Research on radio network planning and optimization in TETRA digital trunking system. *IEEE Second Intern. Conf. on Instrumentation, Measurement, Computer, Communication and Control*, 2012, pp. 821–824. doi:10.1109/IMCCC.2012.198
8. Roullier-Callaghan A. A radio coverage and planning tool. *6th IEEE High Frequency Postgraduate Colloquium (Cat. No. 01TH8574)*, 2001, pp. 35–40. doi:10.1109/HFPSC.2001.962156
9. Binzer T., Landstorfer F. M. Radio network planning with neural networks. *Vehicular Technology Conf. Fall 2000. IEEE VTS Fall VTC2000. 52nd Vehicular Technology Conf. (Cat. No. 00CH37152)*, 2000, vol. 2, pp. 811–817. Available at: <https://ieeexplore.ieee.org/document/887116> (accessed 15 August 2021).
10. Van Nguyen T., Jeong Y., Shin H., Win M. Z. Machine learning for wideband localization. *IEEE Journal on Selected Areas in Communications*, 2015, vol. 33, no. 7, pp. 1357–1380. doi:10.1109/JSAC.2015.2430191
11. Alvizu R., Troia S., Maier G., Pattavina A. Matheuristic with machine-learning-based prediction for software-defined mobile metro-core networks. *Journal of Optical Communications and Networking*, 2017, vol. 9, no. 9, pp. D19–D30.
12. VanderPlas J. *Python data science handbook: Essential tools for working with data*. O'Reilly Media, Inc., 2017. 546 p.
13. Moraitis N., Tsipi L., Vouyioukas D. Machine learning-based methods for path loss prediction in urban environment for LTE networks. *16th Intern. Conf. on Wireless and Mobile Computing, Networking and Communications (WiMob), Thessaloniki (Greece)*, 2020. Available at: <https://ieeexplore.ieee.org/document/9253369> (accessed 15 August 2021).
14. Dai L., Zhang H., Zhuang Y. Propagation-model-free coverage evaluation via machine learning for future 5G networks. *IEEE 29th Annual Intern. Symp. on Personal, Indoor and Mobile Radio Communications (PIMRC)*, 2018. Available at: <https://ieeexplore.ieee.org/document/8580992> (accessed 15 August 2021).
15. Moysen J., Giupponi L., Mangles-Bafalluy J. A machine learning enabled network planning tool. *IEEE 27th Annual Intern. Symp. on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, 2016, pp. 1–7.
16. Abdallah A. A., Saab S. S., Kassas Z. M. A machine learning approach for localization in cellular environments. *IEEE/ION Position, Location and Navigation Symp. (PLANS)*, 2018, pp. 1223–1227.
17. Politansky R., Klymash M. Application of artificial intelligence in cognitive radio for planning distribution of frequency channels. *3rd Intern. Conf. on Advanced Information and Communications Technologies (AICT)*, 2019, pp. 390–394.

18. Vallejo-Cabrejas G., Batolome-Pascual P. Application of radio channel modelling to a planning tool in a mobile radio indoor communication system. *IEEE 43rd Vehicular Technology Conf.*, 1993, pp. 219–222.
 19. Dai L., Zhang H. Propagation-model-free base station deployment for mobile networks: Integrating machine learning and heuristic methods. *IEEE Access*, 2020, vol. 8, pp. 83375–83386. doi:10.1109/ACCESS.2020.2990631
 20. Raj N. Indoor RSSI prediction using machine learning for wireless networks. *Intern. Conf. on COMMunication Systems & NETworkS (COMSNETS)*, 2021, pp. 372–374. Available at: <https://ieeexplore.ieee.org/document/9352852> (accessed 15 August 2021).
 21. Müller A. C., Guido S. *Introduction to machine learning with Python: A guide for data scientists*. O'Reilly Media, Inc., 2016. 398 p.
 22. Le J. *The top 10 machine learning algorithms every beginner should know*. Available at: https://builtin.com/data-science/tour-top-10-algorithms-machine-learning-newbies?utm_campaign=News&utm_medium=Community&utm_source=DataCamp.com (accessed 5 February 2021).
-

ПАМЯТКА ДЛЯ АВТОРОВ

Поступающие в редакцию статьи проходят обязательное рецензирование.

При наличии положительной рецензии статья рассматривается редакционной коллегией. Принятая в печать статья направляется автору для согласования редакторских правок. После согласования автор представляет в редакцию окончательный вариант текста статьи.

Процедуры согласования текста статьи могут осуществляться как непосредственно в редакции, так и по e-mail (ius.spb@gmail.com).

При отклонении статьи редакция представляет автору мотивированное заключение и рецензию, при необходимости доработать статью — рецензию.

Редакция журнала напоминает, что ответственность за достоверность и точность рекламных материалов несут рекламодатели.
