

НЕЙРОСЕТЕВЫЕ МЕТОДЫ РАСПОЗНАВАНИЯ ПОДЗЕМНЫХ ОБЪЕКТОВ В ДАННЫХ ГЕОРАДАРА МОБИЛЬНОГО КОЛЕСНОГО РОБОТА

Кривошей М.И.^{1,а}, Юдин Д.А.^{1,2,б}, Зарипов М.Н.^{1,с}, Буличев О.В.^{1,д},
Муравьев К.Ф.^{1,3,е}, Панов А.И.^{1,2,ф}

¹ Московский физико-технический институт (МФТИ), Москва, Россия.

² Институт искусственного интеллекта AIRI, Москва, Россия.

³ Федеральный исследовательский центр «Информатика и управление» РАН (ФИЦ ИУ РАН), Москва, Россия.

E-mail: ^а krivoshei.mi@mipt.ru, ^б yudin.da@mipt.ru, ^с zaripov.mn@mipt.ru, ^д obulichev@yandex.ru,

^е kirill.mouraviev@yandex.ru, ^ф panov.ai@mipt.ru

Аннотация. В настоящее время для решения задач, связанных с поиском и распознаванием объектов под землёй, часто используется георадар. Это позволяет получать богатую информацию об исследуемой местности на различной глубине, однако ручная интерпретация радарограмм связана с большими трудозатратами. В данной работе предлагается метод GeoRTt для автоматического нахождения подземных объектов интереса на основе нейронной сети оригинальной архитектуры с механизмом внимания GeoAttention, на вход которой подаются А-сканы георадара, установленного на колёсном роботе, перемещающемся в автоматическом либо полуавтоматическом режиме. Предлагаемая нейросетевая модель позволяет учитывать пространственные взаимосвязи между А-сканами георадара даже в тех случаях, когда траектория движения робота отличается от прямой линии. С использованием мобильного колёсного робота и георадара, антенна которого установлена на небольшой высоте над анализируемой поверхностью, собран и размечен уникальный набор данных для распознавания объектов нескольких категорий, находящихся под поверхностью земли. Эксперименты с разработанной нейросетевой моделью на собранном наборе данных продемонстрировали F1-меру классификации свыше 40%, что превосходит по качеству методы-аналоги. В ходе сравнительного анализа различных вариаций архитектуры модели выделены две конфигурации для разных условий решения задачи георадарного исследования.

Ключевые слова: *мобильный колёсный робот, А-сканы, георадар, нейронная сеть, трансформер, распознавание подземных объектов.*

Введение

Для задач, связанных с анализом и распознаванием подземных объектов как природного, так и искусственного происхождения, использование георадара предпочтительно именно потому, что данный тип сенсора даёт исследователю информацию о подповерхностном пространстве куда более богатую, чем металлоискатель и магнитометр, а в ряде случаев (детектирование объектов, документация на которые отсутствует или утеряна, суждения

Для цитирования:

Кривошей М.И., Юдин Д.А., Зарипов М.Н., Буличев О.В., Муравьев К.Ф., Панов А.И. Нейросетевые методы распознавания подземных объектов в данных георадара мобильного колесного робота. *Интеллектуальный транспорт*. 2026. № 3(39). С. 23–36. DOI: 10.24412/3033-6007-2026-339-23-36.

об опорных и др. физических свойствах грунта [1] на основе отраженного сигнала и т.д.) георадар незаменим. Соответственно, актуальность задачи создания надежной и универсальной технологии анализа радарограмм очевидна. На сегодняшний день автоматический анализ радарограмм георадара сопряжён с рядом трудностей. В частности, существующие модели распознавания подземных объектов склонны к ложным срабатываниям, когда в исследуемой области находится много металлического мусора. С другой стороны, если объект содержит мало металлических компонентов или не содержит их вовсе, модель может его не обнаружить. Неизбежно возникающие при движении робота по пересечённой местности отклонения от прямого участка траектории и качания трансмиссии искажают радарограммы [2], что особенно критично для методов, анализирующих радарограммы в формате В-сканов – последовательностей А-сканов по ходу движения робота [3].

Предлагаемая технология позволяет как находить с высокой точностью объекты разной степени локальности (точечные, конечного размера, протяженные с линейным размером, превосходящим размеры исследуемой площади), так и компенсировать возможную неравномерность и криволинейность движения робота.

Для решения данных проблем предлагается трансформерная архитектура GeoRTr, которая на первом этапе, с целью придания модели быстрого действия и уменьшения потребления видеопамати, разбивает исследуемую поверхность на независимые секторы, а на втором – применяет к каждому из секторов классифицирующую модель на основе трансформерного энкодера, кодирующего каждый А-скан совместно с его локальными координатами. Использование механизма внимания позволяет решить проблему методов детекции объектов на двумерных изображениях на основе архитектуры YOLO [4], неспособных информативно кодировать пространственное положение каждого А-скана [2]. В то же время, разбиение на секторы решает проблемы быстрого действия и потребления видеопамати, актуальные для трансформерных моделей [3], а использование архитектуры с небольшим числом параметров решает проблему переобучения модели при малом размере обучающей выборки.

Основной вклад нашей статьи состоит в следующем:

- предлагается оригинальная архитектура нейросетевого классификатора А-сканов на основе механизма внимания, названная GeoRTr, учитывающая пространственные взаимосвязи А-сканов, разбиение исследуемого поля на секторы и содержащая относительно малое число параметров, что позволяет бороться с переобучением при малом размере обучающей выборки;
- с использованием мобильного колёсного робота и георадара собран и размечен уникальный набор данных для распознавания объектов нескольких категорий, находящихся под поверхностью земли;
- эксперименты с разработанной нейросетевой моделью на собранном наборе данных продемонстрировали F1-меру классификации выше 40%, что превосходит по качеству методы-аналоги. В ходе сравнительного анализа различных вариаций архитектуры модели выделены две конфигурации для разных условий решения задачи георадарного исследования.




Рис. 1. Архитектура предложенного метода GeoRTg для классификации А-сканов, полученных от георадара

1. Анализ предметной области

1.1. Анализ методов обнаружения подземных объектов на В-сканах георадара

Для обнаружения подземных объектов зачастую используются модели детекции на базе YOLO, в частности модифицированные архитектуры, такие как HFL-YOLOv8 [5], TLAD-YOLO [6], ME-YOLO [7], FLS-YOLO [8]. Для повышения устойчивости модели к шуму и чувствительности к геометрическим особенностям радарограмм применяются специальные методы предобработки данных – такие как топологический анализ данных TDA [9]. Предварительное выделение на изображении структурных признаков (форма гипербол, замкнутые контуры) повышает точность работы YOLOv5 на В-сканах. На примере YOLOv5 показано, что при использовании TDA $mAP@0,5$ увеличивается с 0,975 до 0,993, $mAP@0,5:0,95$ – с 0,757 до 0,801.

Ещё одним способом адаптации YOLO для детекции объектов на В-сканах является замена стандартных свёрточных слоёв на специальные – такие как GhostConv [10] и C3Ghost [10]. Основная идея этих модификаций в том, чтобы сохранить максимальное разнообразие карт признаков при малом числе параметров модели и высоком быстродействии. Вместо того, чтобы использовать стандартную свёртку с m фильтрами, GhostConv применяет стандартную свёртку лишь с $n < m$ фильтрами, а остальные $m - n$ фильтров представлены простыми линейными преобразованиями. Экспериментально показано, что использование GhostConv в базовой модели YOLOv8n снижает число параметров с 3,6М до 1,9М и GFLOP с 8,3 до 4,9, а mAP на одном из наборов данных увеличивается с 0,715 до 0,723.

Метод MCGA-Net [11] для детекции дефектов автомобильных дорог представляет собой архитектуру YOLOv8, адаптированную для обработки данных многоантенных георадаров. Модель последовательно обрабатывает тензор из нескольких В-сканов с использованием произведения Эйнштейна, а затем детектирует дефекты модулем на базе YOLOv8. На собранном авторами

наборе данных модель показала метрики: Precision = 0,928, Recall = 0,94, mAP@50 = 0,967.

Для обнаружения подземных объектов также используются специальные легковесные свёрточные архитектуры [12]. Один из методов основан на архитектуре VGG16 с добавлением слоя Global Average Pooling для уменьшения числа параметров и борьбы с переобучением. Решается задача нахождения подземных полостей путём детекции максимумов гипербол на В-сканах. На реальных данных модель показала точность обнаружения подземных полостей, равную 1,0.

В модели GPR-TSBiNet [13] для обнаружения подземных заземляющих линий используется трансформерная архитектура GPR-Trans в комбинации с модифицированной SC-BiFPN и функцией потерь Shape-IoU. На реальных данных модель имеет метрику APsmall = 0,494.

Существует ряд методов, таких как MHInvNet [1] и LeakInv-CUNet [14] на базе U-Net и Pix2pixGAN [15] на базе генеративно-состязательной модели, решающих смежную с распознаванием подземных объектов задачу – построение карты диэлектрической проницаемости подповерхностного пространства.

1.2. Анализ методов обнаружения подземных объектов с учётом 2D-координат

Метод GPR-Former [2] использует для обнаружения объектов ванильный трансформер, что позволяет учитывать взаимное расположение координат А-сканов. Авторы рассмотрели три варианта позиционного кодирования: синусоидальное, rotary, линейный слой, и лучшие метрики модель выдала на синусоидальном. Все А-сканы исследуемой поверхности разделяются на группы с помощью K-D дерева. Наибольшие метрики модель показала при размере группы, равном 1024: AR = 0,4834, F2-score = 0,7277.

Существует подход, использующий специальную рекуррентную архитектуру Mamba [3] для обнаружения объектов. На первом этапе 6-канальный пространственный кодировщик на основе ResNet-18 кодирует каждые 2 соседних В-скана в один тензор, аналогичный по размерности исходным В-сканам, который затем подаётся в Mamba как последовательность А-сканов. На собранном авторами датасете метрики составили: RMSE = 0,06 м, R^2 = 0,94.

Методы, реализующие обнаружение подземных объектов с учётом 2D-координат, имеют более высокую обобщающую способность в сравнении с опирающимися на В-сканы (которые, как правило, основаны на обученном с нуля YOLO). Однако такие методы обладают зачастую более сложной и ресурсоёмкой трансформерной архитектурой, что может быть не оправдано в тех случаях, когда объекты интереса сильно контрастируют на радарограммах.

2. Создание обучающего набора георадарных данных, содержащего подземные объекты интереса

Для создания обучающей и валидационной выборок использовался георадар, способный синхронизировать свои данные с точным геодезическим приемником сантиметровой точности, то есть была применена следующая схема:

Неподвижный геодезический навигационный приемник, играющий роль

«базы», то есть источника дифференциальных поправок к навигационным данным, передаваемых по беспроводному каналу на навигационный приемник-ровер», георадар с закрепленным на нем навигационным приемником-ровером, прикрепленный к роботу, и собственно робот, совершающий развертку исследуемой площадки так, чтобы вблизи каждой точки площадки георадар прошел хотя бы раз. Удаление ровера от базы не превышало 500 м. На выходе георадара получаем амплитуду отраженного импульса как функцию времени, прошедшего с момента излучения импульса, а также точные (сантиметровая точность) координаты георадара на момент излучения импульса. Производится примерно 100 сканирований в секунду, для каждого сканирования измеряется интенсивность отраженного сигнала в 500–2000 равноотстоящих друг от друга моментах времени (количество выставлялось в настройках георадара в зависимости от структуры площадки), здесь чем более поздний момент – тем более длинному пути сигнала он соответствует, и, соответственно, может быть вычислена глубина, на которой он был отражен.

В качестве носителя использовалась модифицированная колесная платформа AgileX Scout 2. На ней были установлены георадар GSSI SIR 3000 с антенной 400 МГц, геодезический приемник Javad Maxor, фронтальная RGB-D камера Intel RealSense D455i и средства колесной одометрии. Антенна георадара закреплялась перед платформой и перемещалась на небольшой высоте над поверхностью. Колесное шасси обеспечивало плавное движение и устойчивое положение антенны на неровном грунте, что уменьшало искажения радарограмм, связанные с изменением скорости и вертикальными колебаниями сенсора.




Рис. 2. Мобильный робототехнический комплекс с георадаром GSSI SIR 3000 и антенной 400 МГц

Сканирование выполнялось по системе параллельных профилей с шагом около 0,3 м. Данные записывались преимущественно при движении в одном направлении, чтобы уменьшить влияние направления движения и взаимного

положения антенны и платформы на форму сигнала. После завершения очередного профиля оператор переводил комплекс на соседнюю линию, а прямолинейный участок робот проходил в полуавтоматическом режиме.

Управление прямолинейным движением осуществлялось по данным колесной одометрии. Для ограничения накапливаемой ошибки использовалась визуальная коррекция по контрастному ориентиру, установленному в конце профиля и поднятому над уровнем растительности. RGB-D камера определяла направление и расстояние до ориентира.

Для определения объекта с камеры использовалась дообученная YOLOv8n. При его обнаружении оценка положения уточнялась, после чего робот останавливался на заданном безопасном расстоянии. Такая схема обеспечивала воспроизводимое прохождение профилей без использования спутниковых координат в контуре управления.



Рис. 3. Полуавтоматическое движение робота с визуальной коррекцией по ориентиру в конце профиля

Навигация робота и пространственная привязка измерений решали разные задачи. Система одометрии и камера использовались для управления движением, тогда как приемник-ровер получал дифференциальные поправки от неподвижной базы и формировал координаты георадарных трасс сантиметровой точности. Записи георадара и навигационного приемника снабжались временными метками и синхронизировались при последующей обработке. В результате каждый А-скан сопоставлялся с координатами на площадке независимо от способа управления платформой.

Данные георадара характерны тем, что они несут отпечаток не только одного непосредственно выделенного объекта, но и всех объектов, оказавшихся на пути электромагнитного импульса. Так, импульс, отраженный от сильно заглубленного объекта, несет в себе не только информацию о данном

объекте, но и дифракционные изменения от всех более близких к георадару локальных объектов на его пути, что позволяет судить об их форме и материале.

Затем, точно зная подземное строение площадки, сканирование которой производилось, полученный материал, то есть файлы с выдачей георадара, привязанные к точному времени и геодезическим координатам с навигационного приемника, нарезали на фрагменты с маркировкой соответствующей им подземной структуры и создавали обучающую выборку. Для создания выборки использовалась грунтовая поверхность с невысокой травой; почва умеренно влажная.

Исследуемая поверхность представляет собой поле размером 80×60 метров со средней диэлектрической проницаемостью подповерхностного пространства $\varepsilon = 8$, на котором закопаны разнородные археологические объекты на глубине в несколько десятков сантиметров. Всего закопано 13 объектов в разных частях поля.

Для быстрого действия модели и меньших затрат видеопамати, а также для решения проблемы небольшого размера обучающей выборки, исследуемая поверхность размера 80×60 метров разбивается на сектора 30×30 сантиметров – считается, что в каждом из таких секторов А-сканы имеют сильную пространственную взаимосвязь. В каждом из секторов находится не более 5000 А-сканов. Набор данных разбивается на обучающую и валидационную выборки в пропорции 8:2 путём сэмплирования А-сканов из всей исследуемой поверхности.

3. Предлагаемый подход GeoRTr для распознавания подземных объектов в данных георадара мобильного колесного робота

3.1. Общая постановка задачи

А-скан георадара представляет собой 512-мерный вектор d , каждая компонента которого представляет собой амплитуду на определённом временном отсчёте:

$$d = (d_1, \dots, d_{512}). \quad (1)$$

Входной вектор модели GeoRTr представляет собой сектор D размера 30×30 сантиметров со всеми находящимися в нём А-сканами:

$$D = \{(d_i, x_i, y_i)\}_{x_D-0,15 \leq x_i \leq x_D+0,15}^{y_D-0,15 \leq y_i \leq y_D+0,15}, \quad (2)$$

где (x_D, y_D) – координаты центра сектора.

Для модели f_θ задача классификации формулируется следующим образом:

$$f_\theta : \mathbb{R}^{514 \times T_i} \rightarrow [0, 1]^{T_i}, \quad (3)$$

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \left[-\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^{T_i} (y_{i,k} \log f_\theta(d_{i,k}) + (1 - y_{i,k}) \log (1 - f_\theta(d_{i,k}))) + \lambda R(\theta) \right], \quad (4)$$

где T_i – число А-сканов в секторе i , N – число секторов, $d_{i,k}$ – k -й по счёту

А-скан в i -м секторе, $y_{i,k} \in \{0, 1\}$ – метка его класса, $R(\theta)$ – регуляризация с коэффициентом λ .

В случае большой погрешности определения координат объектов интереса в обучающей выборке, модель может обучаться классифицировать не каждый А-скан, а секторы целиком:

$$f_{\theta} : \mathbb{R}^{514 \times T_i} \rightarrow [0, 1], \quad (5)$$

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \left[-\frac{1}{N} \sum_{i=1}^N (y_i \log f_{\theta}(D_i) + (1 - y_i) \log (1 - f_{\theta}(D_i))) + \lambda R(\theta) \right], \quad (6)$$

где D_i – i -й по счёту сектор.

3.2. Подход к решению

Антенна георадара имеет частоту 400 МГц. На глубине в несколько десятков сантиметров расположены подземные объекты интереса: они имеют различные размеры и материалы. Объекты могут состоять из керамики, железа, других материалов. Требуется для каждого А-скана определить, находится ли в его зоне видимости (используемая модель георадара может обнаруживать объекты на глубине 40–60 сантиметров в радиусе 30 сантиметров) какой-либо объект. Каждый А-скан может принадлежать к одному из двух классов: «объект» или «не объект».

Модель представляет собой оригинальную трансформерную архитектуру, применяемую независимо к каждому из секторов. 512-мерные сканы георадара и 2D-координаты кодируются в единое 256-мерное признаковое пространство, размерность которого сохраняется до применения модуля классификации. Архитектура включает в себя 3 оригинальных слоя внимания GeoAttention, Global Max Pooling для независимой агрегации признаков для каждой глубины (условно, каждой глубине соответствует определённое время приёма отражённого сигнала в наносекундах) и двухслойный модуль классификации. Модель содержит 2,5М параметров.

3.3. Кодирование входных векторов

А-сканы и 2D-координаты приводятся в единое 256-мерное признаковое пространство. Для кодирования А-сканов используется линейный слой, для кодирования координат – двухслойная полносвязная нейронная сеть с функцией активации ReLU. Позиционный эмбединг в неизменном виде подаётся на вход каждого из слоёв внимания.

3.4. Механизм внимания

Используется оригинальный механизм внимания GeoAttention. На каждом слое он принимает на вход 2 вектора: эмбединг предыдущего слоя или модуля и позиционный эмбединг. Это позволяет сохранять на всех слоях точную информацию о 2D-координатах каждого А-скана. Поступающие на вход векторы суммируются и подаются четырёхголовому стандартному механизму самовнимания (self-attention), выход которого обрабатывается




Рис. 4. Укрупненная схема предлагаемого подхода GeoRT обнаружения подземных объектов при помощи классификации А-сканов. Он отличается оригинальным механизмом внимания GeoAttention, сохраняющим на всех слоях точную информацию о взаимном расположении А-сканов и имеющим несколько голов внимания

двухслойной нейронной сетью с функцией активации GELU, dropout и нормализацией.

3.5. Количественная оценка качества предлагаемого подхода

Для оценки качества модели основными метриками являются precision, recall, F1-score. F1-score используется как общая оценка точности метода, несмещённая относительно баланса классов, Recall (полнота) – метрика наиболее важная для задач, где имеет критическое значение нахождение как можно большего числа объектов при допущении ложных обнаружений, Precision (точность) – наибольшее значение имеет, если ложные обнаружения должны быть сведены к минимуму.

4. Результаты экспериментов

Эксперименты с предложенным подходом поиска подземных объектов GeoRT осуществлялись на собранном наборе данных. Тестировались различные варианты архитектуры метода – с различным числом слоёв GeoAttention с 4 головами внимания.

Первый вариант метода с 4 головами внимания и 2 слоями энкодера отличается не очень высокими метриками. Модель с 4 головами и 4 слоями отличается тем, что не имеет на валидационной выборке ложных срабатываний (precision = 1,0) при низкой полноте нахождения объектов (F1-score = 0,29, recall = 0,17). Модель с 4 головами и 3 слоями показывает

наиболее высокое значение $F1\text{-score} = 0,44$ ($\text{precision} = 0,67$), хотя имеет не самую высокую полноту обнаружения ($\text{recall} = 0,33$). Для сравнения, многослойный перцептрон имеет самое низкое значение $F1\text{-score} = 0,19$, а универсальный и достаточно эффективный для задач классификации метод градиентного бустинга CatBoost имеет метрики, схожие с неоптимальными вариантами архитектуры GeoRTr.

Таблица 1. Метрики качества разработанного метода GeoRTr при использовании разного числа голов и слоёв в сравнении с другими существующими методами

Модель	Precision	Recall	F1-score
GeoRTr 2 слоя, 4 головы	0,50	0,17	0,25
GeoRTr 3 слоя, 4 головы	0,67	0,33	0,44
GeoRTr 4 слоя, 4 головы	1,00	0,17	0,29
MLP	0,11	1,00	0,19
CatBoost	1,00	0,17	0,29

На рисунке 5 показаны результаты инференса различных моделей на смешанных данных из тестовой, валидационной и части обучающей выборок. Видно, что многослойный перцептрон MLP склонен давать ложноположительные срабатывания. Остальные модели имеют схожую картину предсказания, но имеют разную точность работы при объезде скоплений объектов.




Рис. 5. Визуализация работы метода GeoRTr с различным числом слоёв GeoAttention, а также многослойного перцептрона и CatBoost. Красные точки – объект есть, синие – объекта нет. Каждая точка – А-скан валидационной выборки

Заключение

В настоящей статье рассмотрен нейросетевой вариант решения задачи распознавания объектов под землёй в данных георадара мобильного колёсного робота, основанный на применении специального механизма внимания GeoAttention к каждому из секторов, на которые разбивается исследуемая поверхность. Разработанный подход демонстрирует высокую точность работы.

Отметим, что программная реализация была испытана на пересеченной местности с сильными перепадами высоты, что вносило возмущения в прямолинейность и равномерность движения робота, а также были непроходимые участки, которые робот объезжал. Это показывает устойчивость предлагаемой технологии по отношению к неблагоприятному рельефу участка, а также к неравномерному и непрямолинейному движению робота.

В дальнейшем планируется собрать больше разнообразных данных для обучения модели, доработать архитектуру метода, добавив кодировщик вертикальных колебаний георадара и оценок диэлектрической проницаемости исследуемой поверхности. Это позволит как достичь более высокой точности модели в пределах одной исследуемой поверхности, так и сделать модель более устойчивой к изменению типа исследуемого грунта и неровностям поверхности. Также планируется добавить возможность поиска глубоко расположенных объектов с оценкой глубины их залегания, а также возможность детектирования нескольких объектов одинаковой или разной природы, расположенных непосредственно один над другим на разной глубине, которая также будет вычисляться моделью.

Благодарности

Работа частично выполнена в рамках НИР «Разработка метода одновременной локализации и картирования TerraCognitaSLAM на основе георадара и визуально-инерциальных сенсоров для условий недоступного спутникового сигнала» (по Договору между Центральным университетом и МФТИ).

Авторы выражают благодарность Центру робототехники Сбера за предоставление робота AgileX Scout 2.0 для проведения экспериментов, а также Шишкову Д. Л. за предоставление георадарного оборудования для сбора набора данных, описанного в настоящей статье.

Список литературы

- [1] Wu, M. Two-stage GPR image inversion method based on multi-scale dilated convolution and hybrid attention gate / M. Wu, Q. Liu, S. Ouyang // Remote Sensing. – 2025. – Vol. 17. – No. 2. – Art. 322. – DOI 10.3390/rs17020322.
- [2] Lee, K. GPR-Former: Context-Aware Moisture Detection / K. Lee, C. Feng // ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction. – Montreal : IAARC Publications, 2025. – Vol. 42. – P. 1–8. – DOI 10.22260/isarc2025/0002.
- [3] Jeon, M. Efficient and Robust Temporal Modeling for LGPR Odometry With Mamba / M. Jeon, H. Lee, J. Lee // IEEE Access. – 2026. – Vol. 14. – P. 38775–38792. – DOI 10.1109/ACCESS.2026.3672677.
- [4] Automated railway subgrade defect detection using GPR and an enhanced YOLOv11 framework / M. T. Tegegne, R. Yang, S. Huang [et al.] // Transportation Geotechnics. – 2026. – Vol. 62. – Art. 102105. – DOI 10.1016/j.trgeo.2026.102105.

- [5] Lei, W. HFL-YOLOv8: a hyperbolic feature-enhanced lightweight network for object detection in ground penetrating radar images / W. Lei, S. Yu, T. Zhang // *Applied Soft Computing*. – 2026. – Vol. 188. – Art. 114403. – DOI 10.1016/j.asoc.2025.114403.
- [6] TLAD-YOLO: Lightweight network for intelligent detection of railway tunnel lining anomalies using ground penetrating radar / P. Zheng, A. Zhang, Z. Shi [et al.] // *Journal of Applied Geophysics*. – 2025. – Vol. 241. – Art. 105869. – DOI 10.1016/j.jappgeo.2025.105869.
- [7] ME-YOLO: A novel real-time detection network for pavement interlayer distress using ground-penetrating radar / S. Cao, C. Lu, X. Wang [et al.] // *Journal of Applied Geophysics*. – 2026. – Vol. 245. – Art. 106057. – DOI 10.1016/j.jappgeo.2025.106057.
- [8] FLS-YOLO: a multi-scale subsurface defect detection network via heterogeneous grouping and spatial reconstruction / W. Zhang, Z. Liu, Q. Yang, X. Qiu // *Signal, Image and Video Processing*. – 2026. – Vol. 20. – No. 5. – Art. 262. – DOI 10.1007/s11760-026-05352-z.
- [9] A Novel Shape-Aware Topological Representation for GPR Data with DNN Integration / M. Kang, S. Kaji, S.-Y. Lee [et al.] // *arXiv*. – 2025. – arXiv:2506.06311. – DOI 10.48550/arXiv.2506.06311.
- [10] Arvas, M. M. Detection of underground objects from GPR data using a lightweight YOLO-based approach / M. M. Arvas, A. Çınar // *Scientific Reports*. – 2026. – DOI 10.1038/s41598-026-59135-0.
- [11] Intelligent recognition of GPR road hidden defect images based on feature fusion and attention mechanism / H. Lv, Y. Zhang, J. Dai [et al.] // *IEEE Transactions on Geoscience and Remote Sensing*. – 2025. – Vol. 63. – P. 1–17.
- [12] Lightweight CNN model for automatic detection and depth estimation of subsurface voids using GPR B-scan data / A. Mojahid, D. El Ouai, K. El Amraoui [et al.] // *Natural Hazards Research*. – 2025. – Vol. 5. – No. 2. – P. 432–446. – DOI 10.1016/j.nhres.2025.02.001.
- [13] GPR-TSBiNet: An information gradient enrichment model for GPR B-scan small target detection / C. Wang, Y. Guan, M. Chi [et al.] // *Sensors*. – 2025. – Vol. 25. – No. 7. – Art. 2223. – DOI 10.3390/s25072223.
- [14] Attention-Module-Guided Time-Lapse Leakage Plume Imaging Driven by LeakInv-CUNet GPR Inversion Framework / H. Wang [et al.] // *IEEE Access*. – 2025. – Vol. 13. – P. 122514–122529.
- [15] Enhanced Pix2pixGAN with Spatial-Channel Attention for Underground Medium Inversion from GPR / S. Yang, L. Guo, Y. Yang, H. Ye // *Remote Sensing*. – 2026. – Vol. 18. – No. 3. – Art. 448. – DOI 10.3390/rs18030448.

NEURAL NETWORK METHODS FOR RECOGNIZING UNDERGROUND OBJECTS IN THE DATA OF A MOBILE WHEELED ROBOT'S GROUND-PENETRATING RADAR

**Krivoshey M. I.^{1, a}, Yudin D. A.^{1, 2, b}, Zарipov M. N.^{1, c}, Bulichev O. V.^{1, d},
Muravyev K. F.^{1, 3, e}, Panov A. I.^{1, 2, f}**

¹ Moscow Institute of Physics and Technology (MIPT), Moscow, Russia.

² Artificial Intelligence Research Institute (AIRI), Moscow, Russia.

³ Federal Research Center "Computer Science and Control" of the RAS (FRC CSC RAS), Moscow, Russia.

E-mail: ^a krivoshei.mi@mipt.ru, ^b yudin.da@mipt.ru, ^c zaripov.mn@mipt.ru, ^d obulichev@yandex.ru,

^e kirill.mouraviev@yandex.ru, ^f panov.ai@mipt.ru

For citation:

Krivoshey M. I., Yudin D. A., Zарipov M. N., Bulichev O. V., Muravyev K. F., Panov A. I. Neural Network Methods for Recognizing Underground Objects in the Data of a Mobile Wheeled Robot's Ground-Penetrating Radar. *Intelligent transport*, 2026, no. 3(39), pp. 23–36. DOI: 10.24412/3033-6007-2026-339-23-36. (in Russian)

Abstract. Currently, ground-penetrating radar (GPR) is often used to solve problems related to searching for and recognizing underground objects. This allows for obtaining rich information about the studied area at various depths, but manual interpretation of radargrams is labor-intensive. This paper proposes the GeoRTr method for automatically detecting underground objects of interest. It is based on an original neural network architecture with a GeoAttention mechanism. The network's input is A-scans from a GPR mounted on a wheeled robot moving in automatic or semi-automatic mode. The proposed neural network model accounts for spatial relationships between A-scans even when the robot's trajectory deviates from a straight line. Using a mobile wheeled robot and a GPR with an antenna mounted at a low altitude above the surface being analyzed, a unique dataset was collected and labeled for recognizing several categories of subsurface objects. Experiments with the developed neural network model on the collected dataset demonstrated a classification F1-score of over 40%, surpassing comparable methods. A comparative analysis of various model architecture variations identified two configurations for different ground-penetrating radar object search conditions.

Keywords: *mobile wheeled robot, A-scans, ground-penetrating radar, neural network, transformer, underground object recognition.*

References

- [1] Wu, M., Liu, Q., & Ouyang, S. (2025). Two-stage GPR image inversion method based on multi-scale dilated convolution and hybrid attention gate. *Remote Sensing*, 17(2), Article 322. <https://doi.org/10.3390/rs17020322>
- [2] Lee, K., & Feng, C. (2025). GPR-Former: Context-aware moisture detection. In *ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction* (pp. 1–8). IAARC Publications. <https://doi.org/10.22260/isarc2025/0002>
- [3] Jeon, M., Lee, H., & Lee, J. (2026). Efficient and robust temporal modeling for LGPR odometry with Mamba. *IEEE Access*, 14, 38775–38792. <https://doi.org/10.1109/ACCESS.2026.3672677>
- [4] Tegegne, M. T., Yang, R., Huang, S., Xiao, H., Yang, Z., Zhang, Q., Liu, Y., & Qi, W. (2026). Automated railway subgrade defect detection using GPR and an enhanced YOLOv11 framework. *Transportation Geotechnics*, 62, Article 102105. <https://doi.org/10.1016/j.trgeo.2026.102105>
- [5] Lei, W., Yu, S., & Zhang, T. (2026). HFL-YOLOv8: A hyperbolic feature-enhanced lightweight network for object detection in ground penetrating radar images. *Applied Soft Computing*, 188, Article 114403. <https://doi.org/10.1016/j.asoc.2025.114403>
- [6] Zheng, P., Zhang, A., Shi, Z., Wang, S., Ma, Y., & Liu, Z. (2025). TLAD-YOLO: Lightweight network for intelligent detection of railway tunnel lining anomalies using ground penetrating radar. *Journal of Applied Geophysics*, 241, Article 105869. <https://doi.org/10.1016/j.jappgeo.2025.105869>
- [7] Cao, S., Lu, C., Wang, X., Zhang, P., Jin, G., & Cai, W. (2026). ME-YOLO: A novel real-time detection network for pavement interlayer distress using ground-penetrating radar. *Journal of Applied Geophysics*, 245, Article 106057. <https://doi.org/10.1016/j.jappgeo.2025.106057>
- [8] Zhang, W., Liu, Z., Yang, Q., & Qiu, X. (2026). FLS-YOLO: A multi-scale subsurface defect detection network via heterogeneous grouping and spatial reconstruction. *Signal, Image and Video Processing*, 20(5), Article 262. <https://doi.org/10.1007/s11760-026-05352-z>

- [9] Kang, M., Kaji, S., Lee, S.-Y., Kim, T., Ryu, H.-H., & Choi, S. (2025). *A novel shape-aware topological representation for GPR data with DNN integration* (arXiv:2506.06311). arXiv. <https://doi.org/10.48550/arXiv.2506.06311>
- [10] Arvas, M. M., & Çınar, A. (2026). Detection of underground objects from GPR data using a lightweight YOLO-based approach. *Scientific Reports*. <https://doi.org/10.1038/s41598-026-59135-0>
- [11] Lv, H., Zhang, Y., Dai, J., Wu, H., Wang, J., & Wang, D. (2025). Intelligent recognition of GPR road hidden defect images based on feature fusion and attention mechanism. *IEEE Transactions on Geoscience and Remote Sensing*, 63, 1–17.
- [12] Mojahid, A., El Ouai, D., El Amraoui, K., El-Hami, K., Aitbenamer, H., Verrelst, J., & Barone, P. M. (2025). Lightweight CNN model for automatic detection and depth estimation of subsurface voids using GPR B-scan data. *Natural Hazards Research*, 5(2), 432–446. <https://doi.org/10.1016/j.nhres.2025.02.001>
- [13] Wang, C., Guan, Y., Chi, M., Shen, F., Yu, Z., Chen, Q., & Chen, C. (2025). GPR-TSBiNet: An information gradient enrichment model for GPR B-scan small target detection. *Sensors*, 25(7), Article 2223. <https://doi.org/10.3390/s25072223>
- [14] Wang, H., et al. (2025). Attention-module-guided time-lapse leakage plume imaging driven by LeakInv-CUNet GPR inversion framework. *IEEE Access*, 13, 122514–122529.
- [15] Yang, S., Guo, L., Yang, Y., & Ye, H. (2026). Enhanced Pix2pixGAN with spatial-channel attention for underground medium inversion from GPR. *Remote Sensing*, 18(3), Article 448. <https://doi.org/10.3390/rs18030448>