



# ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ в георадарных исследованиях автомобильных дорог

В настоящее время специалистами РОСДОРНИИ в рамках реализации национального проекта «БКД» проводятся исследования, направленные на формирование новых подходов и методик повышения точности и производительности результатов инженерных изысканий и обследований автомобильных дорог. Одной из задач исследования является поиск имеющихся решений в области искусственного интеллекта для автоматической обработки результатов георадарного обследования, а также экспериментальная апробация таких решений на практике.

Р. А. Еремин, к.т.н.; А. М. Кулижников, д.т.н., профессор; Н. Г. Пудова, инженер; Е. О. Зверев, инженер; Д. Р. Галимов, инженер;  
Ф. А. Гришин, инженер (ФАУ «РОСДОРНИИ»)



Статья подготовлена по материалам отчета о НИР по теме исследования за 2020–2021 гг. [1], в рамках работы было проанализировано 95 источников информации, в том числе более половины из них — иностранные. Отчет [1] о НИР включает анализ опыта исследователей из России, США, Великобритании, Канады, Австралии, Китая, Италии, Турции, Испании, Польши, Южной Кореи, Бразилии, Вьетнама, Ирана, Индии, Индонезии.

Целью научного исследования является поиск новых возможностей повышения производительности, точности и технологичности камеральной обработки данных георадарного обследования.

Георадарные исследования автомобильных дорог все чаще входят в практику диагностики и проектно-изыскательских работ, а также при строительстве и последующей эксплуатации. Вместе с тем, уровень развития технологий ежегодно меняется, появляются новые программно-аппаратные средства для сбора и обработки данных, полученных этими методами обследования.

Наиболее распространенное применение георадаров — определение толщины слоев дорожных одежд, выделение локальных объектов (инженерных коммуникаций и иных подземных строительных конструкций), выделение ослабленных зон (просадки, грунты повышенной влажности, разуплотненные грунты) в слоях основания дорожных одежд, земляном полотне



Рисунок 1. Шестиканальный георадиолокационный комплекс на базе передвижной дорожной лаборатории РОСДОРНИИ

и подстилающих грунтах. При этом необходимо выявлять причину ослабления дорожных конструкций. Метод георадиолокации является единственным геофизическим способом неразрушающего контроля дорожных конструкций автомобильных дорог, позволяющим выполнять обследование на скорости движения транспортного потока и при этом получать непрерывную геофизическую информацию о геологической среде и конструкции дорожной одежды с высокой разрешающей способностью. Для достижения упомянутой цели РОСДОРНИИ был создан многоканальный георадиолокационный комплекс на базе передвижной дорожной лаборатории (рисунок 1). Система включает 6 антенных блоков георадара, которые

одновременно записывают георадарные профили на всю глубину дорожной одежды и ширину полосы движения со скоростью до 80 км/ч. Шаг сканирования вдоль автомобильной дороги 10–30 см. Производительность сбора данных может достигать 300 погонных км (с учетом количества полос движения) за рабочую смену, что позволяет получать минимум 1800 км георадарных профилей ежедневно. Объем собранных одной передвижной лабораторией георадарных данных за сезон может превышать 100000 км погонных георадарных профилей. Такой объем данных может потребоваться, например, для решения задач оценки технического состояния автомобильных дорог в соответствии с [2]. Очевидно, что собранные за полевой сезон данные должны

быть обработаны до наступления очередного сезона полевых работ. В большинстве случаев обработка и интерпретация радарограмм производится в ручном или полуавтоматическом режиме с постоянным контролем оператора, что не позволяет обрабатывать большие объемы полученных данных. В зависимости от качества данных скорость обработки георадарного профиля может варьироваться от нескольких сотен метров до 10 км/ч, что соизмеримо меньше скорости сбора данных — 60–80 км/ч. Таким образом, значительный объем получаемой информации в результате выполнения обследования по протяженным участкам автомобильных дорог приводит к необходимости разрабатывать максимально автоматические методы обработки и интерпретации георадарных данных. В этой связи становится актуальной задача поиска эффективных и производительных алгоритмов для обработки и интерпретации радарограмм с целью определения участков изменения конструкции дорожной одежды и толщин слоев, обнаружения ослабленных зон на радарограммах (просадки, зоны повышенной влажности и разуплотнения, пустоты, неоднородные включения и др.), выделения локальных объектов, находящихся в железобетоне, земляном полотне или естественном основании (коммуникации, арматура, водопропускные трубы и др.). Автоматизация процесса распознавания георадарных данных позволит увеличить эффективность и скорость камеральной обработки, уйти от субъективной оценки и интерпретации полученного материала оператором. Для автоматизированного выделения границ слоев дорожной одежды, и тем самым определения их толщин, разработано немало количество алгоритмов полуавтоматической и неинтеллектуальной автоматической векторизации отражающих горизонтов на георадарном профиле. Однако в первом случае все также большая роль уделяется работе интерпретатора, который всегда должен уточнять область поиска границы слоя. А во втором случае полная автоматизация не гарантирует

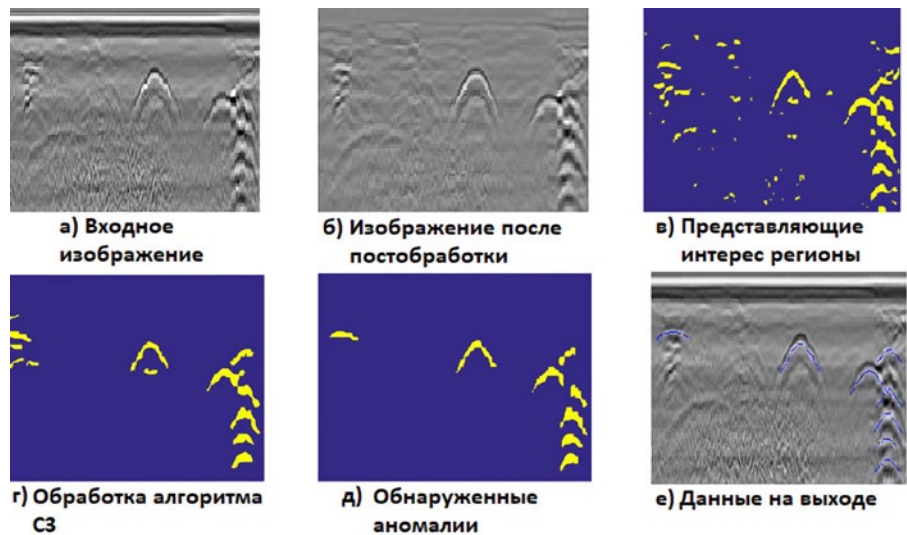


Рисунок 2. Иллюстрация работы алгоритма С3

объективного результата, выделяя все объекты, в т.ч. не относящиеся к реальным отражениям от слоев дорожной одежды. Использование искусственного интеллекта позволяет интерпретировать георадарные данные без помощи человека, но при этом наследуя когнитивные функции человеческого разума. При этом снижаются экспертозависимость результата от негативного влияния человеческого фактора и трудозатраты. Основными инструментами при использовании искусственного интеллекта являются компьютерное зрение, машинное обучение и искусственные нейронные сети (ИНС) [1]. Нейронная сеть — это одно из направлений искусственного интеллекта, цель которого — смоделировать аналитические механизмы, осуществляемые человеческим мозгом. Наиболее широкое распространение при интерпретации радарограмм получило применение сверточных нейронных сетей (CNN). В последнее время было разработано множество видов ИНС, которые показывают высокую производительность при картировании инженерных коммуникаций, арматурных стержней в железобетоне, решении задачи поиска ослабленных зон на радарограммах. Как показывает опыт, ИНС эффективны при поиске границ слоев дорожной одежды, грунтов земляного полотна и геологических слоев естественного залегания в основании насыпи автомобильной дороги.

### АНАЛИЗ ОТЕЧЕСТВЕННОГО И ЗАРУБЕЖНОГО ОПЫТА ПОВЫШЕНИЯ АВТОМАТИЗАЦИИ ОБРАБОТКИ ГЕОРАДАРНЫХ ДАННЫХ

Известные зарубежные и отечественные публикации наиболее полно отражают современные тенденции в области автоматизированной обработки и интерпретации георадарных данных, например, решают задачи автоматизированного поиска на радарограммах коммуникаций, арматуры, водопропускных труб и прочих локальных объектов по характерному отражению — гиперболе дифрагированной волны. Авторы одной из работ [3] применяют к георадарным данным в режиме реального времени алгоритм искусственного интеллекта С3 (Column Connection Clustering), который позволяет после прохождения обучения на смоделированных радарограммах выделять уже на реальных георадарных профилях как отдельные гиперболы, так и части дифрагированных волн (рисунок 2). Тем самым рассмотренный метод автоматической интерпретации позволяет уточнить местоположение локального объекта и получить по гиперболам дифракции электрофизические параметры среды (скорость и диэлектрическую проницаемость). Для поиска гипербола дифракции с целью определения электрофизических характеристик среды могут применяться и неинтеллектуальные алгоритмы, такие как метод SURF и фильтрационный поиск [4]. Метод SURF, основанный на обнаружении ключевых точек на изображении по изменению градиента яркости,






Рисунок 3. Поиск вершин гиперболического годографа методом SURF




Рисунок 4. Исходная радарограмма и результат фильтрации составным пространственным фильтром

позволяет достаточно устойчиво определять вершины гипербол, при этом отсеивая ложные точки, расположенные на боковых ветвях гипербол (рисунок 3).

Фильтрационный поиск базируется на двумерной пространственной фильтрации радарограммы с использованием масок. При этом используется комбинация из трех пространственных масок, каждая из которых настроена на выделение определенного элемента гиперболы (левой ветви, вершины или правой ветви). Результат фильтрации «составным» фильтром представлен на рисунке 4.

Таким образом, выделяя на радарограмме гиперболы, авторы [4] автоматически получают скорости

распространения электромагнитной волны в среде и, соответственно, диэлектрическую проницаемость. Достаточно сложной задачей при поиске локальных объектов является задача определения не только электрических характеристик вмещающей среды и глубины расположения локального объекта, но и восстановления реального изображения по георадарному профилю. В статье [5] авторы используют нейронную сеть GPRInvNet, которая относится к глубоким нейронным сетям для обработки георадарных данных, чтобы успешно выделить локальные объекты, трещины и полости внутри бетона. В ходе эксперимента были смоделированы радарограммы по созданным типовым моделям объектов с гиперболами дифракции. Результаты моделирования и восстановления изображения представлены на рисунке 5.

Результаты эксперимента показали, что GPRInvNet эффективнее справляется с задачей по выделению небольших объектов, таких как стержни арматуры, и лучше отображает трещины. На следующем этапе был проведен эксперимент на реальных георадарных данных, полученных по бетонному блоку, в котором искусственно были устроены стержни армирования, полость (заполненная водой) и трещина. Результаты моделирования приведены на рисунке 6. Нейронная сеть с архитектурой GPRInvNet при достаточном количестве данных для обучения показала хорошие результаты по их обработке на конструкциях с различными

дефектами, которые имеют неправильную форму и геометрию.

Одна из востребованных на практике и успешно решаемых в георадиолокации задач с помощью применения автоматизированных алгоритмов — выделение границ конструктивных слоев дорожной одежды с целью определения их толщин [6–11]. Однако существующие подходы, описанные в статьях, являются довольно непроизводительными и экспертозависимыми, т.к. достаточно часто используют полуавтоматические способы выделения отражающих границ.

Так, например, достаточно широко распространен алгоритм, основанный на комплексном анализе трассировок [12–14]. Разделение сигнала происходит по силе отражения (мгновенная амплитуда или огибающая сигнала) и косинусу его мгновенной фазы (также называемой косинусной фазой). Алгоритм использует эту функцию для отслеживания любого отражения с непрерывной осью синфазности, соединяя фазы сигнала с одинаковой полярностью и близким временем прихода сигнала. Данный алгоритм был использован [15] для выделения конструктивных слоев на радарограммах, полученных на взлетно-посадочной полосе (ВПП) аэропорта (рисунок 7). Положительные амплитуды отмечены на рисунке 7Б и 7В зеленым цветом, отрицательные — красным.

Предлагаемый авторами [15] метод автопикерки слоев является экспертонезависимым, имеет всего

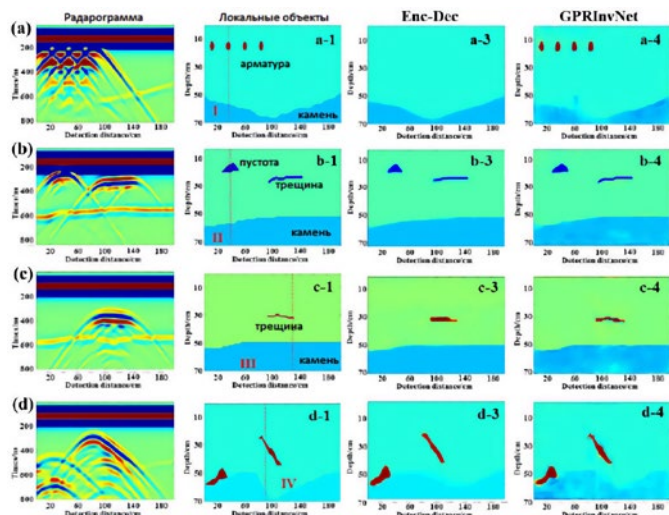


Рисунок 5. Результаты инверсии простых дефектов *a* — арматура, *b* — полость и трещина, *c* — одна трещина с водой, *d* — многочисленные трещины с водой

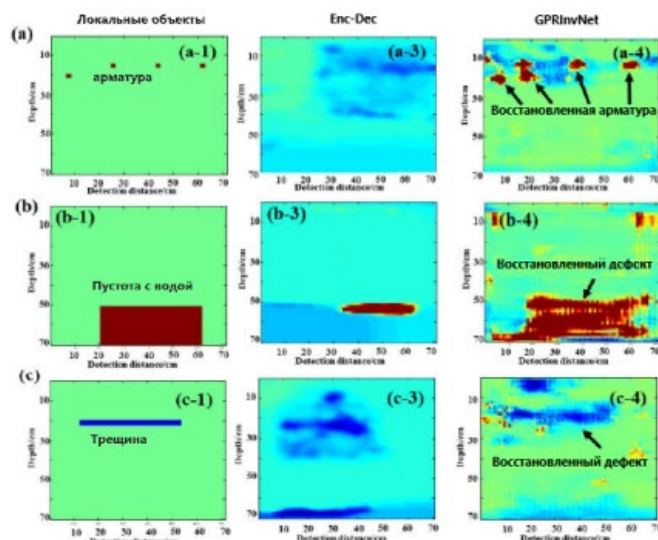


Рисунок 6. Результаты инверсии *a* — арматура, *b* — пустота с водой, *c* — трещина




Рисунок 7. Автоматическое выделение слоев на радарограммах по ВПП  
А — радарограмма, Б — все автоматически выбранные отражения, Б' — отражения, автоматически идентифицированные как одна из первых трех фаз отражений




Рисунок 8. Сравнение определения границ нейронной сети MLP  
Сплошная линия — разметка оператора, пунктирная — предсказание сети

несколько параметров для настройки отслеживания границ, но при этом пользователь может проверять результат на каждом этапе, процедура интерпретации — интерактивна. Полностью автоматический алгоритм выделения границ слоев дорожных одежд с использованием искусственного интеллекта описан в статье [16]. В работе рассматриваются нейронные сети трех видов: многослойный перцептрон (MLP), сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN). В результате исследований автор показал, что ИНС на основе MLP способна достаточно качественно предсказывать расположение границы раздела сред. Результаты, представленные на рисунке 8, показывают, что нейронная сеть MLP может выделять границы не хуже человека.

Далее авторы рассматривают использование CNN и RNN для решения задач сегментации и выделения отражающих границ на радарограммах, полученных при обследовании автомобильной дороги. При этом CNN на нормализованных георадарных данных превзошла результаты MLP более чем на 15%. RNN представляют собой класс ИНС,

собранный по признаку наличия внутренней памяти о предыдущих поданных на вход измерениях за счет обратных связей между нейронами. Результаты работы данной ИНС показали, что при выделении отражающих границ практически отсутствуют выбросы (рисунк 9). Это связано с тем, что сама сеть при обработке учитывает выбросы при предыдущем предсказании и не повторяет их на следующей итерации. Таким образом, в статье [16] делают вывод, что RNN показала хорошие результаты, несмотря на более низкую точность относительно CNN, и поэтому является наиболее подходящей для использования при выделении конструктивных слоев дорожной одежды на георадарных данных.

На основании исследованного опыта можно сделать вывод, что результат работы нейросети зависит от сложности исходных данных, на которых ИНС проходила обучение. Различные фрагменты границ, найденные нейросетью, должны правильно классифицироваться как относящиеся к одной или нескольким границам конструктивных слоев.

Георадар часто используется не только для определения толщины конструктивных слоев дорожной одежды, но и с целью выделения ослабленных зон в слоях дорожной одежды: участков повышенной влажности грунтов, пустот, зон разуплотнения грунтов в рабочем слое земляного полотна и подстилающих грунтовых основаниях. При этом в большинстве случаев обработка и интерпретация таких радарограмм выполняется вручную либо с использованием полуавтоматических алгоритмов. Критериями выделения ослабленных зон на радарограммах применительно к автомобильным дорогам в свое время занимались разные авторы [17–22].

Первым шагом для решения поставленных задач в Российской Федерации и за рубежом было использование автоматизированных алгоритмов распознавания образов при обработке георадарных данных, однако и этот полуавтоматический метод требовал обязательного участия оператора.

Использование глубоких CNN для поиска полостей под




Рисунок 9. Пример предсказания рекуррентной нейронной сети данных  
Сплошная линия — разметка оператора, пунктирная — предсказание сети




Рисунок 10. Результат работы трехмерного георадара по автомобильной дороге  
а) исходная радарограмма, б) радарограмма после фильтрации, в) амплитудный срез на глубине 0,35 м

асфальтобетонным покрытием на данных трехмерного георадара описано в статье [23] (рисунк 10). Авторы использовали отфильтрованные георадарные данные с 13 км автомобильной дороги, включающие 27 полостей, 18 люков и 29 труб, которые передали для обучения в глубокую CNN. На тестовой выборке 86% данных было классифицировано корректно, что было признано авторами статьи как приемлемая точность.

Одну из наиболее важных задач по распознаванию областей повышенной влажности в грунтах основания с помощью нейросети попытались решить в статье [24]. Необходимые георадарные данные для изучения, проверки и тестирования нейросети были записаны на участке, где был точно известен уровень влажности грунта: высокий или низкий. Для классификации использовался оригинальный метод с аппроксимационным полиномом, а полиномиальные коэффициенты использовались для обучения нейронной сети (MLP). Нейронная сеть была обучена распознавать уровень влажности и классифицировать



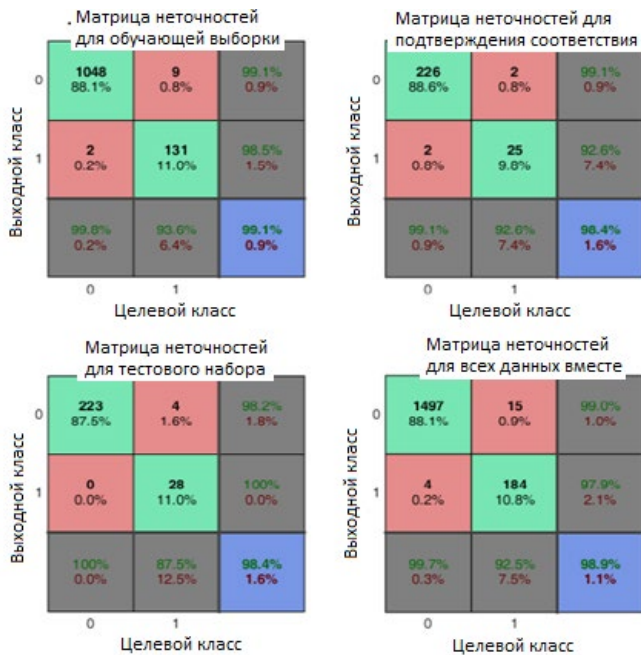



Рисунок 11. Матрицы, показывающие статистику правильной и неправильной классификации рассматриваемых участков

грунт как влажный и сухой. В итоге были представлены матрицы неточностей отдельно для обучающего набора, для набора проверки и тестового набора, а в конце для всех данных вместе (рисунок 11).


На рисунке 11, если нейросеть распознала участок как область высокой влажности (Выходной класс=1), который на самом деле таким является (Целевой класс=1), то задача решена эффективно. Аналогично задача является решенной успешно, если нейросеть опознала участок как сухой (Выходной класс=0), который таким и является (Целевой класс=0). Остальные ситуации соответствовали ошибкам. Таким образом, авторы [24] показали, что эффективность применения нейросетей для задач распознавания участков повышенной влажности в грунте в среднем составила 98,9% со средней ошибкой 1,1%.

Для поиска пустот в строительных конструкциях также могут использоваться алгоритмы компьютерного зрения, которые применяются к предварительно обработанным радарограммам [25]. Авторы приводят пример обработки георадарных данных, полученных по стене из строительных блоков, внутри которых находились пустоты, подтвержденные путем вскрытия. Ко всем полученным радарограммам была применена процедура атрибутного анализа «взаимная корреляция»: фрагменты соседних трасс сравниваются между собой и в случае их схожести или различия исходная радарограмма

трансформируется (рисунок 12). На каждой радарограмме можно выделить зоны неоднородности свойств, которые соответствуют полостям. Далее к полученным результатам атрибутного анализа были применены процедуры автоматического поиска пустот, основанные на алгоритмах цифровой обработки изображений и распознавания образов (рисунок 13), которые



а) стена 1



б) стена 2

Рисунок 12. Результат обработки радарограмм с помощью атрибута «взаимная корреляция»




Рисунок 13. Результат автоматического поиска пустот

эффективно выделили на радарограмме участки с полостями. Таким образом, анализ различных источников показал обоснованность и актуальность задачи автоматизированной обработки и интерпретации георадарных данных. В прикладных целях автоматизация обработки георадарных данных может применяться для:

- ♦ определения толщины слоев дорожных одежд;
- ♦ оценки структуры, а также свойств дорожных конструкций и иных строительных конструкций при обследовании автомобильных дорог и искусственных сооружений на них;
- ♦ выявления неблагоприятных грунтово-гидрологических условий естественного основания (переувлажненные и разуплотненные грунты, неоднородные включения);
- ♦ обнаружения скрытых дефектов сооружений и их конструкций;
- ♦ уточнения местоположения инженерных коммуникаций и поиска иных погребенных в грунте объектов.

### ВЫЯВЛЕНИЕ ПЕРСПЕКТИВНЫХ ТЕНДЕНЦИЙ РАЗВИТИЯ В ЧАСТИ АВТОМАТИЗАЦИИ ОБРАБОТКИ БОЛЬШИХ ОБЪЕМОВ ПРОСТРАНСТВЕННЫХ ДАННЫХ

При обработке и интерпретации георадарных данных обычно выделяют три основных типа объектов:

- ♦ линии (границы или фрагменты отражающих границ конструктивных слоев, УГВ или сопутствующих коммуникаций, квазилинейные фрагменты локальных объектов, таких как поверхность железобетонных плит);
- ♦ точечные локальные объекты-дифракторы, когда размер локального объекта сопоставим с разрешающей способностью антенного блока и, следовательно, от данного локального объекта формируется специфическое отражение электромагнитного сигнала в виде гиперболы

(трубопроводы различного назначения, электрические кабели, стержни армирования либо отверстия в железобетонных конструкциях, крупнообломочные фракции в грунте, бетонные блоки и пр.);

- ♦ области, выделяемые на радарограммах по изменению типа волновой картины, в том числе по изменению спектральных и фазовых характеристик электромагнитного сигнала (просадки, переувлажненные грунты, разуплотненные грунты, пустоты и суффозия грунтов, неоднородные включения, разрушения монолитных материалов, коррозия и т.д.).

Условно все алгоритмы автоматизированной или автоматической обработки и интерпретации результатов георадарного обследования можно разделить на два основных класса: интеллектуальные и неинтеллектуальные (рисунки 14).

Неинтеллектуальные алгоритмы поиска отражающих границ можно разделить на 2 типа: автоматизированные (поиск от принудительно указанной начальной точки, поиск от принудительно указанных начальной и опорных точек) и автоматические (поиск по опорным точкам, которые определил автоматизированный алгоритм самостоятельно из расчета заданных оператором начальных параметров (окно поиска, фаза, порог амплитуды и др.)). В свою очередь, алгоритмы поиска границ могут использовать в качестве входных данных исходные и усиленные георадиолокационные трассы, а также изображения георадарного профиля. Существуют также решения, позволяющие отслеживать границы слоев и определять относительное изменение их толщины непосредственно в процессе сбора данных (онлайн-режим).

Неинтеллектуальные алгоритмы поиска локальных объектов преимущественно базируются на обнаружении гиперболических волн (дифрагированных волн), поиске ослабленных зон посредством атрибутного анализа. В рамках указанной процедуры выполняется преобразование исходного георадарного профиля на основании анализа различных спектральных и фазовых атрибутов, а также анализа



Рисунок 14. Алгоритмы обработки и интерпретации георадиолокационных данных

атрибутов цветов изображения в более наглядный для обнаружения ослабленной зоны на радарограмме вид. При этом профиль может быть преобразован как на всю свою протяженность и глубину, так и в определенном фрагменте. Также атрибутный анализ может быть применен к амплитудным картам (интерполированные по серии параллельных или пересекающихся вертикальных разрезов горизонтальные срезы с разной глубиной заложения). Результат атрибутного анализа может быть представлен как в виде маски (слоя), равномерно покрывающей исходный георадарный профиль, так и в виде обособленного профиля (изображения). В ряде случаев результат атрибутного анализа дублируется графиками изменения параметров, указывая на пиковые значения в определенных местах профиля.

Интеллектуальные алгоритмы отличаются тем, что не требуют участия человека в процессе интерпретации и векторной разметки профиля. Пройдя процедуру обучения на выборке данных нужного объема, интеллектуальный алгоритм самостоятельно формирует набор исходных параметров поиска, который впоследствии используется при работе с аналогичными данными. Иными словами, человеку достаточно запустить алгоритм, но не заниматься настройкой параметров для его функционирования. Анализ опыта, изученного в рамках НИР [1], показывает растущую роль технологий искусственного интеллекта в автоматической обработке данных. В частности, машинного обучения и компьютерного зрения

(в т.ч. искусственных нейронных сетей).

Компьютерное зрение — это область искусственного интеллекта, связанная в т.ч. с теорией и технологией создания машин, которые могут производить обнаружение, отслеживание и классификацию объектов на изображениях. Компьютерное зрение предусматривает процедуры первичной предобработки, когда изображение приводится к наиболее наглядному виду (используя методы цифровой обработки изображений) и последующего извлечения различных объектов. Зачастую при использовании компьютерного зрения с целью извлечения объектов из изображения используется такой класс архитектурных ИНС как сверточные нейронные сети.

Машинное обучение — это класс методов искусственного интеллекта, характерной чертой которых является не прямое решение задачи, а обучение за счет применения решений множества сходных задач. Для построения таких методов используются средства математической статистики, численных методов, математического анализа, методов оптимизации, теории вероятностей, теории графов, различные техники работы с данными в цифровой форме. Машинное обучение может осуществляться:

- ♦ с учителем — когда на вход алгоритму подаются размеченные экспертом данные и система учится логике эксперта в классификации подобных данных;