



Углубленное Обучение (Deep Learning) - Новая Парадигма Моделирования Рудных Тел

S. Sullivan¹, C. Green²,
D. Carter³, H. Sanderson⁴
и J. Batchelor⁵

1. Менеджер по продукту, Машинное Обучение, Maptek Pty Ltd, Adelaide SA 5065
steve.sullivan@maptek.com.au
2. Лидер стратегических инноваций, Maptek Pty Ltd, Perth WA 6003
chris.green@maptek.com.au
3. Специалист по данным, Maptek Pty Ltd, Perth WA 6003
derek.carter@maptek.com.au
4. Директор, CYENCY, Perth WA 6000
hugh@cyency.com
5. Директор Оцифровки Рудного тела, Roy Hill Iron Ore Pty Ltd, WA 6015
james.batchelor@royhill.com.au

КРАТКИЙ ОБЗОР

Ключевым вкладом в любую концепцию, исследование, план или бюджет является геологическая или ресурсная модель. Обычно эти модели требуют большой субъективной ручной интерпретации и оценки с использованием того метода, который генерирует наименьшую ошибку. Сквозной процесс, в зависимости от размера модели и масштаба, и сложности переменных, может занять несколько месяцев, что является утечкой ресурсов компании и не дает никакой тактической выгоды или гибкости.

Модели должны обеспечивать наилучшую имитацию геологических процессов и физических наблюдений и независимо от методологии должны быть надежными и защищаемыми. Если это может быть достигнуто быстро с определенной мерой неопределенности, то будут реализованы возможности для оптимизации бизнес-процессов, снижения затрат и принятия более быстрых и разумных решений, основанных на неопределенности.

Развитие компьютерного моделирования привело к тому, что интерпретация рудных тел перешла от 1D-бумаги к 2,5-D-цифровой форме, и в течение многих лет этот метод превосходил все остальные, но по своей сути его точность всегда зависела от навыков, эффективности и субъективности оператора. В последнее время все большую популярность приобретают полуавтоматические методы, такие как моделирование переменных по категориям и условное моделирование, но эти методы также имеют ограничения, такие как время обработки и масштабируемость.

Вывод меры неопределенности вокруг оценки или модели требует применения соответствующего метода моделирования, который сам по себе занимает слишком много времени, чтобы стать частью любого тактического процесса, и чаще всего изолирован от долгосрочного стратегического планирования.

Многие прорывные технологии, внедренные Индустрией 4.0, приносят с собой захватывающие возможности для оптимизации бизнес-процессов, снижения затрат и принятия более быстрых и разумных решений, основанных на неопределенности. Поскольку горняки стремятся сохранить конкурентное преимущество, здоровую прибыль и эффективно справляться с техническими и операционными проблемами гибким способом. В этой нестабильной отрасли необходимость перехода к цифровым преобразованиям становится все более важной.

В этой статье представлен новый подход к углубленному обучению нейронных сетей, который может быстро (в течение нескольких минут или часов) генерировать классифицированные/доменные модели рудных тел, включая оценку множества числовых переменных и неопределенностей, непосредственно из пространственно привязанных предварительно закодированных выборочных данных. Это будущее моделирования рудных тел.

Представлен пример, демонстрирующий применение нового метода углубленного обучения к месторождению железной руды Roy Hill в Западной Австралии, а также краткий сравнительный анализ с традиционной оценкой запасов, полученной с помощью обычного кригинга.

ВВЕДЕНИЕ

С 2017 года Maptek и Roy Hill работают над несколькими совместными инвестиционными проектами, направленными на изучение путей улучшения знаний о рудных телах и использования многочисленных прорывных технологий Индустрии 4.0, одним из которых было применение Углубленного Обучения в моделировании рудных тел.

Создание традиционных геологических моделей и оценок запасов (в совокупности именуемых в данной статье моделями рудных тел) для небольших сложных рудных тел или больших рудных тел с большими данными может потреблять много времени и ресурсов компании. Как правило, создание такой модели, как модель рудного тела Roy Hill, может занять 3-4 месяца — даже при внедрении автоматизации процессов с помощью рабочих процессов и сложного интегрированного программирования (Batchelor, 2019).

Это делает включение новых данных и новых знаний медленным процессом со значительным управлением изменениями, который выполняется на 6 ежемесячных циклах скользящего планирования. Таким образом, традиционные модели рудных тел не способны обеспечить какую-либо реальную тактическую ценность в краткосрочном и даже краткосрочном среднесрочном горизонте.

Хуже всего то, что любые ошибки или оплошности, требующие немедленного исправления, порождают большую работу и стресс для участников, что приводит либо к значительному превышению сроков моделирования, либо в некоторых случаях к признанию недостатков модели. В то время как предпринимаются все усилия, чтобы предотвратить подобные случаи, манипуляции человека с десятками тысяч проб и моделирование отдельных областей изолированно для последующего слияния в единую модель, поддаются, по крайней мере, одной ошибке. В конце концов, мы всего лишь люди.

Подход углубленного обучения нейронных сетей, представленный в этой статье, может быстро (в течение нескольких минут или часов) генерировать классифицированные/доменные модели рудных тел, включая оценку множества числовых переменных и неопределенностей — непосредственно из пространственно привязанных предварительно закодированных выборочных данных. Это означает, что при условии достоверности исходных данных риск человеческой ошибки в значительной степени сводится на нет. Даже если входные данные содержат ошибку, влияние повторного запуска всего процесса незначительно из-за времени, затраченного на перестройку модели с использованием этого подхода.

Алгоритм углубленного обучения сначала генерирует нейронную сеть (NN) из предварительно закодированных выборок, а затем с помощью NN ограничивает интерполяцию числовых атрибутов. Построение блочной модели — это просто случай преобразования нейронов в воксели, а затем агрегирования вокселей для создания блоков, с которыми мы знакомы

Убрав обычные ручные процессы, такие как редактирование строк, каркас, сшивание моделей и т. д. единственное реальное ограничение — это время, необходимое для интерпретации и кодирования анализов или скважинных показаний. Расширьте применение машинного обучения к компоненту интерпретации и доминирования, и появится псевдо-автоматизированный метод моделирования рудных тел в реальном времени.

ТЕКУЩАЯ РЕАЛЬНОСТЬ - ГЕНЕРАЦИЯ ДОМЕНА

Модель должна изображать лучшее понимание геологических процессов и наблюдений, однако объемная интерпретация геологических наблюдений хороша лишь настолько, насколько хороши знания, опыт, предубеждения и терпение геолога, строящего модель. На самом деле несколько возможных интерпретаций могут быть получены несколькими геологами, и как таковая геологическая неопределенность так же важна, как и неопределенность содержания. Эта геологическая неопределенность часто упускается из виду прежде всего потому, что, в отличие от неопределенности содержания, нет простого способа уловить или передать ее.

В 1990-е годы переход от аналоговых 2D-ручных методов моделирования рудных тел к цифровым 2.5D-компьютерным программным методам был революционным в искусстве моделирования рудных тел. Сегодня сложная парадигма больших данных делает даже эту революционную методологию медленной и громоздкой. Например, месторождение Roy Hill в настоящее время состоит из >1 000 000 м метров данных о буровых скважинах обратной циркуляции RC (до сих пор) из ~50 000 буровых скважин, и полная повторная модель и переоценка заняли бы несколько месяцев. Даже моделирование изолированных областей, а затем сшивание этих областей обратно в родительскую модель и повторная оценка могут занять более 3 месяцев. Из-за этого модели генерируются не чаще, чем каждые 6 месяцев, что ограничивает способность Roy Hill проверять геологические гипотезы или быстро внедрять новые знания в глобальном масштабе и разрабатывать новые модели в тактическом горизонте.

В течение некоторого времени быстрые методы, такие как явное и условное моделирование, предлагали более быстрые и менее громоздкие альтернативы традиционным цифровым методам. Однако эти методы страдают от проблем эффективности и масштабируемости при применении к большим сложным телам или проблемам больших данных.

Использование углубленного обучения для прогнозирования переменных по категориям, таких как геологические области, является высокоэффективным процессом, требующим мало входных параметров, и может генерировать результат, который включает в себя меру неопределенности прогноза. Затем неопределенность может быть использована для принятия обоснованных решений на этапах разведки и оценки проекта, вплоть до планирования и оперативного исполнения. Неопределенность также может быть использована для лучшей количественной оценки достоверности при оценке ресурсов и запасов, заявленных в соответствии с кодексом JORC, снижая субъективность вокруг этого процесса.

В своей статье “Наука и статистика”, опубликованной в середине 1970-х годов, Джордж Бокс отметил, что “все модели ошибочны, но некоторые полезны”. Эта цитата стала чем-то вроде мантры для разработчиков моделей рудных тел и, возможно, может быть переписана как “все модели ошибочны, и путем проб и ошибок некоторые из них в конечном итоге окажутся полезными некоторое время и с некоторыми модификациями”. Реальность такова, что без возможности надежно и эффективно фиксировать локализованную неопределенность модели единственный способ проверить эффективность модели — это попытаться и потерпеть неудачу, что может быть чрезвычайно дорогостоящей кривой обучения в производственной среде.

Поэтому, если с помощью технологии углубленного обучения можно быстро генерировать и регенерировать модели рудных тел с мерой локализованной неопределенности, то, возможно, следующая или что-то в этом роде станет новой мантрой “все модели ошибочны, неопределенность делает их полезными”.

ТЕКУЩАЯ РЕАЛЬНОСТЬ - ОЦЕНКА СОДЕРЖАНИЙ

После валидации данных, интерпретации, построения каркасов и объемного моделирования следующий шаг включает интерполяцию или оценку числовых значений, таких как содержания и тонны, в блоки или ячейки. Алгоритмы оценки широко используются в различных отраслях промышленности на многих программных платформах.

Обычно используемые методы оценки включают обратное расстояние, кригинг (несколько вариантов) и моделирование (также с различными вариантами). Все они были разработаны и переработаны с течением времени, преследуя цель уменьшения ошибки оценки, повышения эффективности (скорости) и, в случае моделирования, меры неопределенности. Размеры блоков определяются в зависимости от расстояния между буровыми скважинами и размера пробы с целью минимизации погрешности оценки при достижении требуемой точности геологической границы.

Настройка параметров оценки для наиболее часто используемых методов может быть громоздким и трудоемким процессом. В Roy Hill в общей сложности 84 переменные оцениваются в 14 геологических областях с использованием комбинации обычного кригинга и обратного взвешивания расстояний. Чтобы сделать процесс подготовки оценки более эффективным и менее подверженным человеческим ошибкам (например, ошибкам ввода данных), было использовано большое количество сценариев. В общей сложности определено более 200 000 значений параметров оценки, которые необходимо обновлять для каждой двухгодичной процедуры оценки.

Что касается моделирования неопределенности, то условное моделирование (один из наиболее часто используемых методов) может быть использовано для генерации нескольких реализаций, которые могут быть подвергнуты последующей обработке для установления неопределенности значения в любой заданной точке пространства. Эти методы требуют больших затрат времени, процессора, оперативной памяти и дискового пространства, поэтому обычно используются для оценки должной осмотрительности или для сокращенных наборов данных и, как правило, не включаются в рутинные циклы оценки.

Некоторые другие методы моделирования, такие как мультигауссовский кригинг, могут быть использованы для определения неопределенности как результата процедуры оценки, но им не хватает множественных реализаций и, следовательно, детализации, обеспечиваемой условным моделированием. (Ортис, 2004).

В конечном счете, все процедуры оценки и моделирования требуют значительного времени и усилий в отношении конфигурации, выполнения и анализа. Они также зависят от многих человеческих решений, которые неизменно сопровождаются нематериальными предубеждениями, проявляющимися в общей неопределенности оценки и не поддающимися отличению от неопределенности, обусловленной данными. Затем возникает зависимость от моделей пространственной дисперсии, таких как вариограммы, и предположение, что одна и та же модель является глобально репрезентативной, что является длинной дугой для рисования в широких или сложных телах.

С точки зрения эффективности и действенности обычные процедуры имеют много ограничений.

МЕТОДИКИ МАШИННОГО ОБУЧЕНИЯ

Углубленное обучение (также известное как углубленное структурированное обучение или иерархическое обучение) — это ветвь методов машинного обучения, основанных на искусственных нейронных сетях (ANN или NN). Обучение может быть контролируемым, полуконтролируемым или неконтролируемым.

Хотя термин "Углубленное Обучение" был введен в середине 1980-х годов, некоторые из самых ранних примеров алгоритмов Углубленного Обучения можно проследить до 1960-х годов, а влияние Углубленного Обучения в промышленном контексте впервые почувствовалось в начале 2000-х. Примерно в 2012 году началась революция углубленного обучения, и сегодня трудно представить себе мир без него, поскольку он играет жизненно важную роль во множестве крупных глобальных отраслей, включая медицину, фармацевтику, машиностроение, безопасность и совсем недавно горнодобывающую промышленность.

Машинное обучение в его различных формах ранее применялось при подсчетах запасов с разной степенью успеха. Наиболее практичными, коммерчески доступными простыми алгоритмами NN являются методы Радиальной базисной функции (RBF), и хотя эти методы могут обеспечить разумные результаты из небольшого числа заданных пользователем параметров, результаты, как правило, отражают "радиальную" природу алгоритма, а не истинные лежащие в основе геологические тенденции. Кроме того, процедуры RBF очень медленно применяются к большим наборам данных и поэтому ограничены в их применении во многом так же, как и методы моделирования.

На протяжении многих лет нейросетевые алгоритмы обещали решить множество обобщенных задач, но без заметного успеха. Однако цифровая трансформация, вызванная Революцией углубленного обучения, Индустрией 4.0 и возрождением Искусственного Интеллекта (ИИ), показала, что NNS может обеспечить впечатляющие результаты в широком спектре областей, включая машинное зрение, распознавание речи и понимание естественного языка и перевод. Большая часть этой технологии не нова, но масштаб, в котором она применяется, увеличился экспоненциально, и было показано, что NNS значительно улучшается с увеличением масштаба.

Размер NN является функцией числа скрытых слоев (H) и числа "нейронов" (N) в каждом слое. Термин "нейрон" происходит от первоначального биологического вдохновения для сетей, но может рассматриваться как взвешенная сумма нейронов в предыдущем слое, показанная в виде точки ниже.

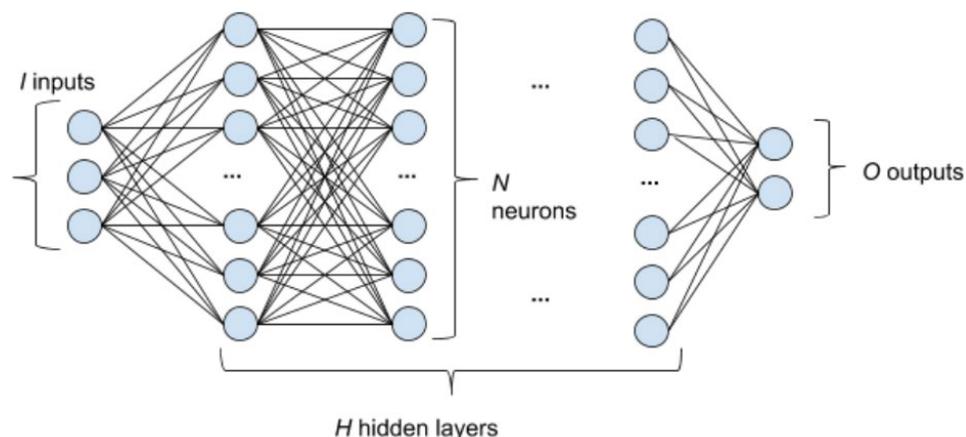


РИС. 1 – Схематическая архитектура модели NN.

Размер входных данных (I) и размер выходных данных (O) обычно фиксируются приложением — в этом случае размер входных данных будет равен 3 — X, Y, Z местоположение интересующей точки, а размер выходных данных будет зависеть от того, что запрашивается — например, ряд оцениваемых значений оценок или прогнозируемый код домена.

Поскольку каждый нейрон в каждом слое связан с каждым нейроном в предыдущем слое и, если число нейронов остается постоянным для каждого слоя, общее число весов в модели будет приблизительно равно $N^2 \cdot H$. Размер модели при сохранении и общее время, необходимое для вычисления прогноза, примерно пропорциональны числу весов в модели.

Некоторые исследования использовали нейронные сети для моделирования месторождений. В 2010 году Dutta с соавторами использовали Нейронную Сеть с $H=1$ скрытым слоем и $N=12$ нейронами для моделирования золотого месторождения. Совсем недавно, в 2017 году, Nezamolhosseini, Mojtahedzadeh и Gholamnejad использовали $H=3$ скрытых слоя с $N=20$ нейронами для моделирования запасов железной руды.

Недавние феноменальные усовершенствования аппаратного и программного обеспечения машинного обучения теперь позволяют создавать гораздо более крупные модели. Значительное увеличение размера модели означает, что любые предыдущие предположения о применимости NNS к наукам о земле должны быть пересмотрены в свете этих улучшений.

ПОСТРОЕНИЕ NN МОДЕЛЕЙ

Модель NN создается непосредственно из данных примера с помощью процесса, известного как обучение. Таблица выборок, которая соответствует входным данным (X, Y, Z) желаемым выходным данным (значения содержаний и/или коды доменов), подготавливается и отправляется в обучающий алгоритм — эти данные обычно берутся из составной базы данных бурения.

Существует ряд параметров, которые могут быть скорректированы при построении NN, таких как количество слоев и количество нейронов, а также более технические параметры, такие как тип нелинейности, топология соединения, размеры пакетов и скорость обучения. Для данного сайта настройка этих параметров может привести к небольшим улучшениям результатов, однако представленные здесь результаты генерируются из одного и того же набора параметров. Это очень желательно, поскольку позволяет пользователю, не знающему базового алгоритма, использовать NN-ы для получения быстрых и точных оценок.

ИСТОРИЯ ПРИМЕРА (КЕЙСА)

Roy Hill - единственная независимая железорудная компания со значительным западно-австралийским владением, имеющая интегрированную корпоративную штаб-квартиру в Перте и Центр Удаленных Операций (ROC), расположенный в международном аэропорту Перта.

Месторождение железной руды Roy Hill расположено в Чичестерском хребте на северной стороне долины реки Фортескью, в районе Пилбара на Северо-Западе Австралии. Район добычи полезных ископаемых расположен примерно в 1300 км к северу от Перта и в 100 км к северу от регионального центра Ньюмана. Экспортный объект в Порт-Хедленде расположен в 342 км по железной дороге от рудника.

Организация состоит примерно из 2400 штатных сотрудников, работающих на обычном открытом карьере, крупногабаритной добыче полезных ископаемых с нескольких производственных стенов, питающих завод по мокрой переработке 55 млн тонн в год и направляющихся в Порт-

Хедленд по одной линии 344 км тяжеловесной железной дороги. Доставка осуществляется через специально построенный, выделенный двухпалубный железорудный портовый комплекс.

Минерализация на Roy Hill расположена в нижней части Наммулди (Nammuldi) железной формации Марра-Мамба (Marra Mamba) (рис.2) и состоит примерно из 2Bt \geq 50% запасов железной руды Fe со средним содержанием Fe 56,4%.

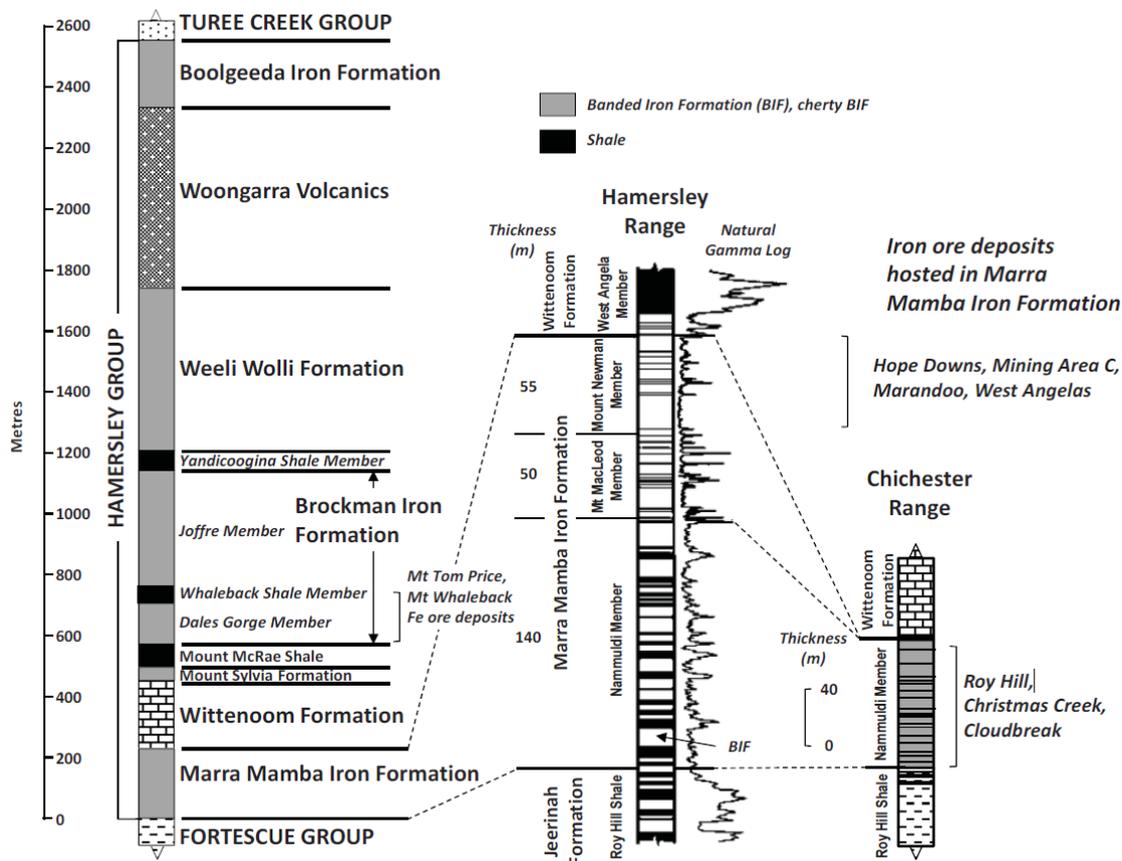


РИС. 2 – Стратиграфическое расположение железорудного месторождения Рой-Хилл.

Возможность для Разрушительных Экспериментов

Знание рудных тел является ключевым компонентом программы Roy Hill Smart Mine, которая направлена на создание завтрашнего рудника сегодня, и в 2017 году Maptek и Roy Hill сформировали совместный проект совместного инвестирования для изучения путей улучшения знаний о рудных телах путем использования нескольких прорывных технологий Индустрии 4.0, одной из которых было Углубленное Обучение.

"Умный" в Roy Hill — это больше, чем просто технология, он использует технологию как разрушитель и активатор таким образом, чтобы освободить нас от рутинных и механистических процессов, предоставляя больше времени для критического и творческого мышления, анализа и рассуждений. Сочетание этого с поведенческими науками и социальными навыками, такими как влияние, коучинг и эмпатия, создает возможность и видение для формирования рабочего места к лучшему.

Программное обеспечение Vulcan используется для моделирования рудного тела Roy Hill уже более десяти лет. За последние 6-7 лет Roy Hill приложил много усилий для автоматизации своих

процессов с помощью системной интеграции и программирования, чтобы быстро манипулировать наборами данных и заменять повторяющиеся механистические задачи.

Два ключевых вида деятельности, которые было чрезвычайно трудно упорядочить, — это генерация геологической интерпретации и объемное моделирование и последующая оценка содержания. Roy Hill генерирует от 70 000 до 100 000 новых проб RC (обратная циркуляция) каждые шесть месяцев, которые требуют интерпретации и моделирования небольшой командой из 3 геологов в течение 4-месячного периода времени. Процесс создания новых геологических моделей может быть ресурсоемким, оставляя мало времени на то, чтобы остановиться, подумать, развить и обдумать идеи.

Поэтому неудивительно, что Roy Hill выбрал геологическое моделирование и оценку в качестве критического центра для применения Искусственного Интеллекта. Некоторые работы были выполнены ранее Роем Хиллом с использованием Примитивного вывод Бейеса для предсказания геологических областей (доменов). Хотя это был небольшой шаг, это был шаг в правильном направлении, поскольку он продемонстрировал, насколько мощными могут быть методы вероятностного моделирования и машинного обучения.

Основным результатом проекта по углубленному обучению было, как можно быстрее, построение геологических моделей и выполнение оценок непосредственно и быстро на основе выборочных данных, прошедших минимальную предварительную обработку. Кроме того, требовалось, чтобы результирующий результат был сопоставим со многими общепринятыми традиционными методами и с определенным уровнем неопределенности.

Проект представлял собой как технические, так и философские проблемы. Команде был представлен сдвиг парадигмы вокруг того, что такое моделирование, почему мы делаем это определенным образом и что действительно важно для клиентов с точки зрения выпуска и конечного использования. Затем, обдумывая эти вопросы, мы спросили себя, как это можно или нужно сделать по-другому, чтобы обеспечить для Roy Hill хорошее положение в будущем.

Ключевым элементом в инновационном пути было осознание и управление присущими нам предубеждениями и зависимостями от ментальных моделей, а также позволение нам больше ориентироваться на данные. Это легче сказать, чем сделать, учитывая, что мы, как технические специалисты, разрабатываем ментальные модели в течение многих лет, и все, что бросает вызов нашим "инстинктам", естественно, встречается с недоверием и презрением.

Углубленное Обучение для Оценки Содержаний

Для доказательства концепции была выбрана небольшая площадь хорошо выраженного бурения (25mE x 25mN) в районе Дельты на северо-востоке месторождения 23kmE x 23kmN. Данные для этой области состояли из предварительно обработанных анализов проб 2m RC Fe.

Процесс был выполнен путем запуска исполняемого файла Python в интерфейсе Vulcan T-оболочки с помощью командной строки, состоящей из следующих параметров:

1. имя файла `ascii`, содержащего образец данных (файл.csv)
2. верхний и нижний каркас (файлы.00t), используемый для ограничения построения модели, например, подошва и топографические поверхности
3. файл определения блока (файл.bdf), содержащий схему модели и переменные, требующие оценки
4. требуемое имя выходной модели (файл.bmf).

Затем все данные были зашифрованы, сжаты и впоследствии загружены в веб-сервис Amazon (AWS), где выполнялось автоматическое назначение параметров оценки, геологическое моделирование, интерполяция содержаний и анализ неопределенности.

По завершении процесса углубленного обучения модель блока Vulcan была создана, зашифрована, сжата и загружена в исходный каталог проекта Windows для анализа. Сквозной процесс перехода от образца к модели был завершен менее чем за час, что заняло бы месяцы при использовании ручного метода.

Примеры результирующей генерации домена и оценки класса можно увидеть на следующих рисунках:

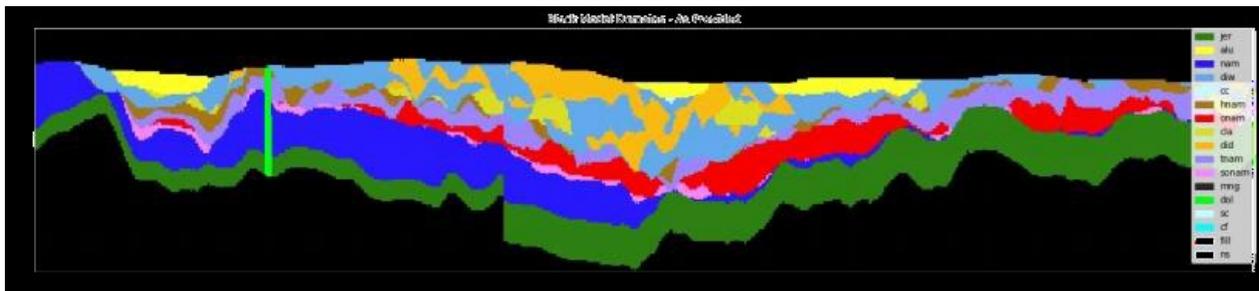


РИС. 3 – Разрез железорудного месторождения Roy Hill, полученный с помощью обычного каркасного моделирования.

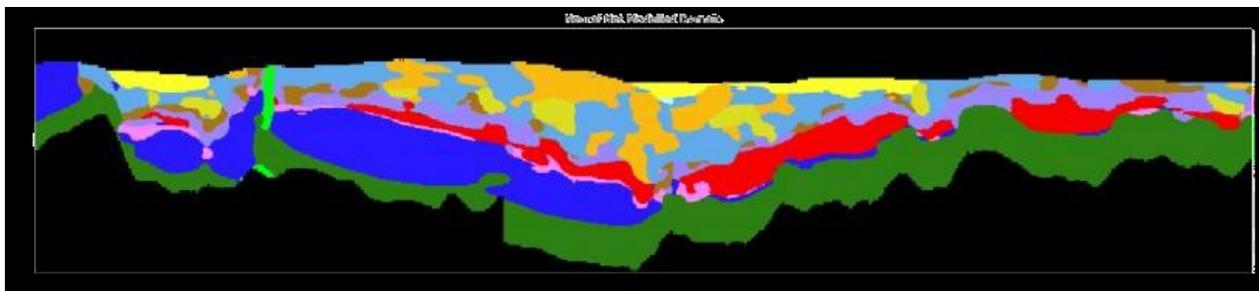


РИС. 4 – Разрез железорудного месторождения Roy Hill, сформированный с помощью Углубленного Обучения.

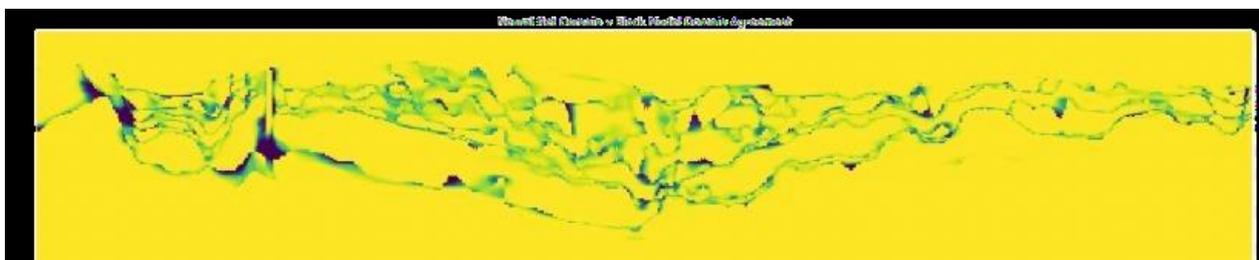


РИС. 5 – Разрез железорудного месторождения Roy Hill, сформированный с помощью углубленного обучения, показывающее неопределенность прогноза.

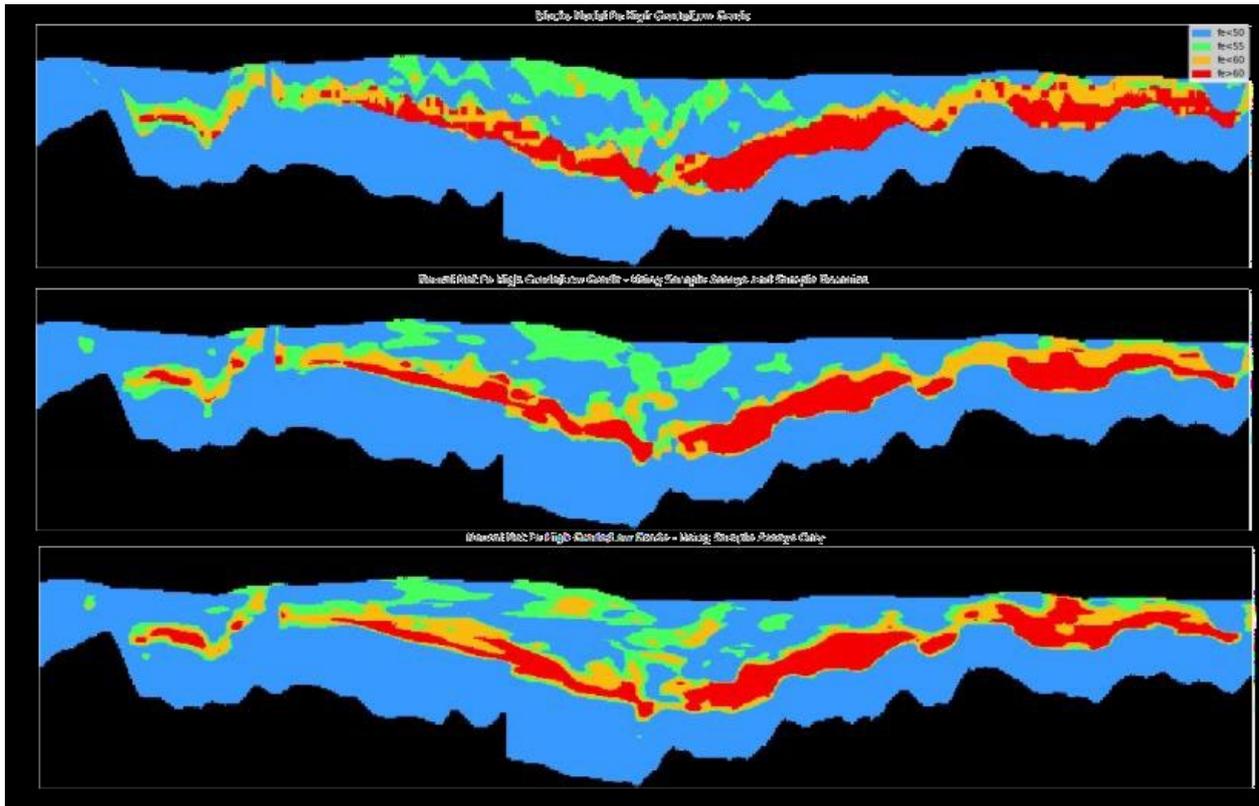


РИС. 6 – Разрезы через те же места, что и на рис. 3-5, показывающие сверху вниз: содержания железной руды, оцененные с использованием обычного кригинга в каркасной модели; содержание железной руды, оцененные с использованием углубленного обучения и доминированных выборочных данных; содержания железной руды, оцененные с использованием углубленного обучения и недоминированных выборочных данных.

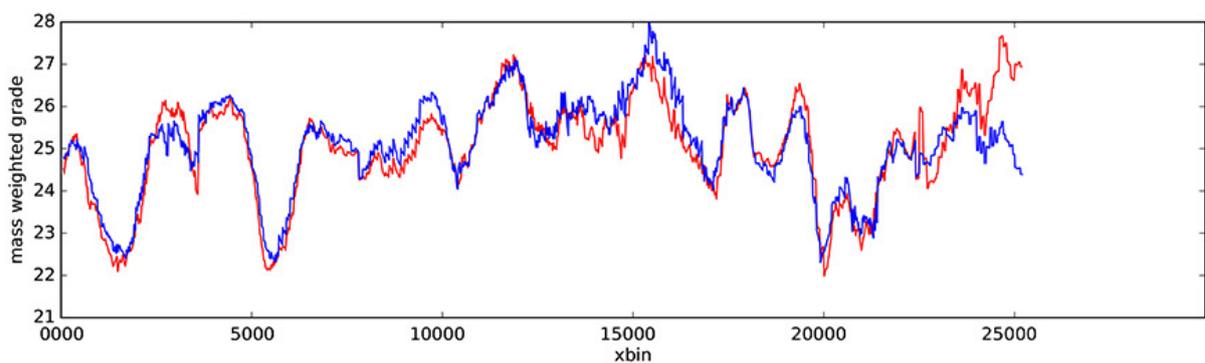


РИС. 7 – График валидации сечения Восток-Запад кумулятивных содержаний Fe вдоль линии сечения 25 км, показывающий красным цветом содержания Fe обычным кригингом и синим - оценки Fe углубленным обучением.

Начальные результаты метода Углубленного Обучения в высшей степени сопоставимы с оценкой крикинга — очень положительный результат. На статистическом уровне данные хорошо сравниваются, а на геологическом уровне Глубокое Обучение очень близко к имитации ручной модели рудного тела — с некоторыми возможностями для улучшения стратификации.

Первоначальные результаты MVP Углубленного Обучения были очень обнадеживающими, однако изменения никогда не бывают гладким или простым процессом, и ключевым следующим шагом в получении более широкого признания в отрасли будет продемонстрированное применение Углубленного Обучения к нескольким стилям рудных тел, работа над которыми уже ведется, а также получение очень обнадеживающих результатов.

ВЫВОДЫ

После более чем двухлетних исследований и разработок решение Углубленное Обучение MVP было успешно применено для моделирования железорудного месторождения Roy Hill, а также использовано для оценки нескольких других месторождений и типов месторождений.

Следующие шаги для Roy Hill состоят в работе с Maptek для дальнейшего повышения способности метода генерировать стратиграфические слои, а также определения того, где метод может быть использован немедленно с наибольшим эффектом.

Несмотря на то, что Добыча Жизнеспособного Продукта (MVP) все еще имеет некоторые ограничения, непосредственная ценность может быть получена за счет применения этого метода в следующих областях:

- валидация и расширение рутинных процессов моделирования рудных тел
- оперативная оценка других ресурсов и проектов
- краткосрочное геологическое моделирование и контроль содержания
- Измерение Во Время Бурения (MWD) производной оценки параметров взрыва
- определение геологических рисков, связанных с расстоянием между скважинами и их конфигурацией
- улучшенная оценка несуммируемых (например, геометаллургических) переменных.

Сотрудничество с Roy Hill в этом проекте привело к тому, что все участники стали больше ценить творческие способности друг друга и способность отказаться от прочно укоренившихся убеждений. Это требовало большой гибкости и способности поворачиваться по мере развития проекта, а также постоянной потребности смотреть на более широкую картину вместо того, чтобы сосредотачиваться на отдельных процессах или системах.

В настоящее время идет расширение применения Углубленного обучения на гораздо более широкий спектр геологических стилей, и Maptek работает над тем, чтобы сделать коммерческую сборку решения Углубленного обучения доступной для более широкого горного сообщества к концу 2020 года.

В конечном счете, эти технологии обладают потенциалом для того, чтобы довольно глубоко изменить то, что, как и почему происходит в горнодобывающей промышленности. Ключевая причина, по которой Roy Hill заключает соглашения о совместном использовании IP со своими поставщиками, заключается в том, чтобы обеспечить, чтобы такие проекты получали выгоду от более широкой обратной связи технического сообщества, и есть надежда, что коммерциализация вызовет много споров и нового мышления.

БЛАГОДАРНОСТЬ

Авторы благодарят своих соответствующих работодателей за то, что они дали время и одобрение на подготовку и представление этой статьи.

СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ

Batchelor, J., 2019. Искусственный интеллект в горнодобывающей и металлургической промышленности, с тематическими исследованиями: обработка горных пород и минералов в качестве объектов данных с использованием искусственного интеллекта и иммерсивной визуализации. Представлено на выставке Digital Mines: Building Fully Autonomous Mines from Pit to Port, Перт, Австралия, 10-12 апреля 2019 года.

Vox, G. E. P. 1976, Science and statistics, Journal of the American Statistical Association, 71: 791–799, doi:10.1080/01621459.1976.10480949.

Dutta, Sridhar & Vandopadhyay, Sukumar & Ganguli, Rajive & Misra, Debasmita. (2010). Алгоритмы машинного обучения и их применение для оценки запасов руды по разреженным и неточным данным. JILSA. 2. 86-96. 10.4236/jilsa.2010.22012.

Nezamolhosseini, S. A., Mojtahedzadeh, S. H. and Gholamnejad, J., 2017. Применение искусственных нейронных сетей для оценки запасов руды на Чогартском железорудном месторождении. Аналитические и численные методы в горном деле, Том 6, Специальный выпуск, с. 73-83.

Ortiz, J. M., Leuangthong, O., and Deutsch, C. V., 2004. Мультигауссовский подход к оценке неопределенности блочного содержания. CIM Conference and Exhibition, Edmonton 2004, May 9 to 12, 10 p., 2004.

Sullivan, S. J., 2018. Maptek Forge декабрь 2018 года, Достигнув цели быстрого моделирования.