

Управление моделями машинного обучения



Содержание

Зачем нужно управлять моделями?.....	1
Моделирование - неотъемлемая часть бизнеса	1
Регуляторные ожидания и последствия неэффективного управления модельным риском.....	2
Продвинутое управление моделями	3
1: Как вы определяете и классифицируете свои модели?	3
2: Почему был выбран этот метод, а не другой?	4
3: В каком контексте используется модель ML? Вы понимаете все потенциальные риски вашей модели ML?	5
4: Вы знаете, на каких данных работают ваши модели?	6
5: Можно ли объяснить результаты модели машинного обучения?	8
6: Как работают ваши модели ML?.....	10
7: Кем, когда и как используются модели машинного обучения?	11
8: Как калибруются модели машинного обучения?.....	12
9: Насколько эффективны ваши модели машинного обучения по сравнению со статистическими моделями? Разработали ли вы план на «черный» день?	12
10: Вы в состоянии быстро приспособиться и ответить на все изменения, которые диктует рынок?	12
Будущее управления модельными рисками	13
Узнать больше	14

Зачем нужно управлять моделями?

Модели использующие техники машинного обучения (ML) нуждаются в управлении так же, как и другие модели, и даже в большей степени. Особенно это важно для моделей, которые применяют алгоритмы самообучения и улучшаются автоматически, используя накопленные данные. Их способность «обучаться» не только обеспечивает наивысшую точность и предсказательную силу, но также может значительно увеличить модельный риск и привести к погрешностям в результатах. Поэтому важно установить строгие процессы управления, которые могут быстро определить, когда модель начинает ошибаться, в комплексе с операционными проверками для входных данных и результатов модели. Динамический характер моделей ML также означает, что они требуют более частого мониторинга производительности, постоянной проверки данных и бенчмаркинга, правильной инвентаризации моделей и заготовленного плана мероприятий на случай непредвиденных обстоятельств.

Наступил момент, когда пора внедрять эффективный механизм управления моделями машинного обучения, в противном случае сегодняшний многомерный рынок и огромные объемы данных перегрузят защитные барьеры традиционных подходов управления рисками.

Моделирование – неотъемлемая часть бизнеса

В настоящий момент все больше проявляется интерес к использованию AI/ML для преобразования больших объемов данных, включая неструктурированные, в новые выводы и информацию. В отличие от стандартных статистических моделей, модели ML не ограничены количеством измерений, к которым они могут эффективно обращаться. Модели ML могут потреблять огромные объемы неструктурированных данных, идентифицировать паттерны и переводить эти шаблоны в полезную информацию.

Предсказательная сила этих методов Предсказательная сила моделей, построенных с помощью таких методов, в сочетании с доступностью больших данных и увеличением вычислительной мощности будет и впредь оставаться источником конкурентного преимущества для “продвинутых” организаций. Те, кто окажется не способным внедрить машинное обучение в свой бизнес, столкнется с возрастающей конкуренцией и потенциальной неустойчивостью бизнеса.

«Использование искусственного интеллекта и машинного обучения рискует создать «черные ящики» в процессах принятия решений, которые могут породить большие проблемы, особенно для редких, но существенных событий»¹

¹ Financial Stability Board (FSB), Artificial intelligence and machine learning in financial services. Market developments and financial stability implications. Nov. 1, 2017.

Регуляторные ожидания и последствия неэффективного управления модельным риском

Преимущества моделирования связаны с новыми рисками и новыми правилами. В частности, существует много этических и юридических вопросов, касающихся ИИ и конфиденциальности данных. Анализ неструктурированных данных с использованием слабо интерпретируемых моделей машинного обучения (например, для более точных прогнозирования) также может вызвать серьезные финансовые, репутационные и регуляторные проблемы.

Учитывая скорость адаптации компаний к новым реалиям, государственные регулирующие органы усиливают разработку нормативов и правил по всем вопросам, связанным с конфиденциальностью данных (GDPR)² и управлением беспилотных автомобилей³ до многочисленных руководств по этике^{4 5} и специализированных фреймворков по управлению модельным риском.^{6 7}

Тем не менее, не существует единого подхода для всех. Обсуждения регуляторов о применении искусственного интеллекта чрезвычайно сильно различаются в зависимости от технологии и способа использования. Например, хоть

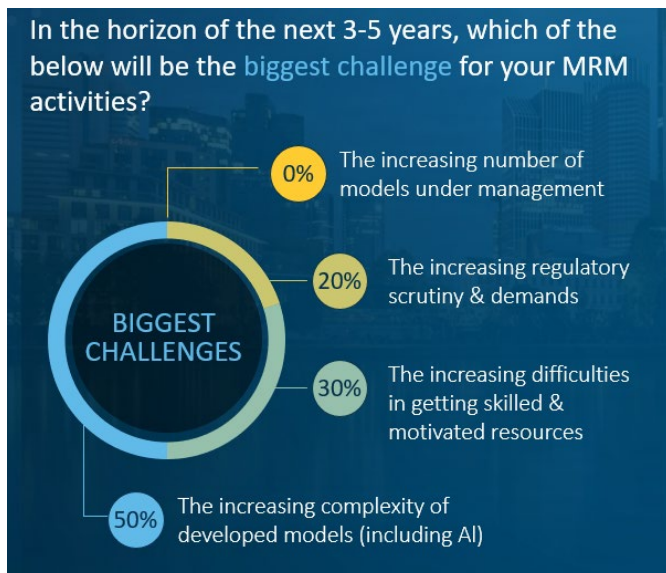


Рисунок 1: Самые большие проблемы, с которыми банки столкнутся в ближайшие три-пять лет в отношении модельного риска

«Чтобы упростить применение ИИ в сфере финансовых услуг для соответствующих организаций было бы важно создать надежные инфраструктуры для эффективного управления и контроля ответственности в случае непредвиденных обстоятельств, чтобы обеспечить доверие общественности к инновационным финансовым услугам»⁸

² <https://gdpr-info.eu/>

³ <https://www.nhtsa.gov/technology-innovation/automated-vehicles-safety>

⁴ High-Level Expert Group on Artificial Intelligence. European Commission.

⁵ <https://flia.org/notice-state-council-issuing-new-generation-artificial-intelligence-development-plan/>

⁶ <https://www.federalreserve.gov/supervisionreg/srletters/sr1107.htm>

⁷ <https://www.opengovasia.com/singapore-releases-first-artificial-intelligence-ai-governance-framework-in-asia/>

⁸ https://www.boj.or.jp/en/announcements/press/koen_2017/ko170413a.htm/

регулирующие органы активно продвигают использование технологий AI для повышения качества выявления мошенничества⁹, они в то же время обеспокоены тем, что это может привести к уклонению от кредитных санкций.

Почему же регулятор, руководители компаний и инвесторы стали больше обращать на это пристальное внимание? Потому что традиционные способы защиты и методы управления модельным риском, такие как ручное тестирование и ежегодный процесс актуализации моделей, недостаточны, чтобы отлавливать постоянные изменения в моделях ML в процессе их переобучения. Применение устаревших практик в конечном итоге приведет к росту числа «черных лебедей» - непредсказуемых событий, которые приводят к значительным последствиям и объясняются задним числом с учетом уже свершившегося факта.

Как показано в данной статье далее, лучший способ снизить риск – это использование интеллектуального управления и автоматизированных инструментов. «Банки должны обеспечить наличие эффективных структур управления и процессов риск-менеджмента, чтобы выявлять, управлять и отслеживать риски, связанные с использованием передовых технологий и появлением новых бизнес-моделей и участников в банковской системе, которые вызваны разработками FinTech...»¹¹

«Модельный риск возрастает с увеличением сложности модели, повышения неопределенности относительно исходных данных и допущений, более широкого использования и большего потенциального воздействия»¹⁰

Продвинутое управление моделями

Учитывая обеспокоенность в отношении прозрачности и потенциального неправильного использования моделей, использующих методы машинного обучения, крайне важно, чтобы организации внедрили надежную и современную систему управления моделями. В ответ на это продвинутые команды по управлению модельными рисками инвестируют значительное время и ресурсы, чтобы определить, как лучше управлять моделями.

При правильном управлении ваша организация сможет безопасно внедрять и использовать большие данные и методы моделирования ML, и при этом их легко масштабировать, сохраняя надлежащий контроль. Что немаловажно, это позволит также эффективнее их создавать и запускать. Все чаще компании узнают, что «разработка и развертывание систем ML относительно быстрая и дешевая, но при этом поддерживать их со временем становится сложнее и дороже». ¹²

Вы будете знать, что ваш процесс управления эффективен, когда он позволяет вам ответить на следующие вопросы.

1: Как вы определяете и классифицируете свои модели?

Давайте начнем с некоторых основных вопросов о моделях ML – Как вы определяете модели машинного обучения? Сколько моделей машинного обучения у вас в реестре? И для чего используются эти модели?

⁹ <https://www.federalreserve.gov/newsevents/speech/brainard20181113a.htm>

¹⁰ The Federal Reserve's "Guidance on Model Risk Management" (SR Letter 11-7).

¹¹ "Implications of fintech developments for banks and bank supervisors - consultative document." BCBS, August 2017.

¹² "Hidden Technical Debt in Machine Learning Systems"
<https://papers.nips.cc/paper/5656-hidden-technical-debt-in-machine-learning-systems.pdf>

Это достаточно простые вопросы, но многие группы риск-менеджеров затрудняются ответить на них. Интеллектуальное и эффективное управление модельными рисками требует концентрации внимания в определенный момент времени на конкретных моделях. Важно знать, где вы применяете модели ML, как они используются и как они вписываются в вашу экосистему моделей.

Нужно прозрачно определить классификацию моделей, потому что машинное обучение и ИИ могут означать разные вещи в зависимости от отрасли и учреждения. Каждая организация должна разработать свои собственные определения и последовательно применять их в своем реестре моделей. Кроме того, важно понимать, какую бизнес-задачу решает модель ML (например, автоматизацию процессов или обнаружение мошенничества) и в рамках каких задач применяется (например, отбор информативных признаков, подготовка данных, бенчмаркинг или валидация). После того, как модели были должным образом идентифицированы и классифицированы в вашем реестре, вы можете обеспечить внимание, которое необходимо этим типам моделей.

2: Почему был выбран этот метод, а не другой?

Для всех моделей важно документировать обоснование использования выбранного подхода - будь то ML или что-то другое, включая его ключевые характеристики, доступные данные и связанные риски. Обоснование использования сложных ML моделей следует проводить в сравнении с традиционными статистическими методами; это поможет команде разработчиков обосновать использование более сложного и менее прозрачного подхода. В дополнение к этому, требуется учитывать потенциальный «риск заражения», который может повлиять на другие модели в пределах одной экосистемы, а также проработать способы снижения данного риска.

Обращение к первой и второй линиям защиты (разработчикам моделей и риск-менеджерам, соответственно) для обоснования их подхода к ML в сравнении с традиционными статистическими моделями однозначно повышает объемы работ. Эти затраты должны всегда учитываться при выборе между подходами. При этом вы можете упростить данную работу, внедрив систему управления моделями, которая позволит пользователям проверять причины и обоснования того, почему они использовали тот, а не иной метод моделирования. Причины выбора определенного подхода могут быть следующие:

- Включение обработки неструктурированных данных.
- Лучшая предсказуемость.
- Лучше всего подходит для этой проблемы.
- Модель с низкой чувствительностью к изменениям.

Обоснование использования ML техник должно быть задокументировано и одобрено владельцем модели и подразделением управления рисками или валидаторами для каждой модели. В идеальном случае решение использовать или нет продвинутой подход в моделировании должно быть

принято на самом раннем этапе жизненного цикла модели, чтобы предотвратить проблемы в дальнейшем. Это решение должно быть одобрено ключевыми заинтересованными сторонами. В некоторых дорогостоящих проектах уже после того, как команды разработали модель ML и прошли валидацию, которая работала как задумывалась и выдает высококачественные результаты, она так и не была внедрена в промышленную эксплуатацию, потому что подразделение рисков были не согласны с выбранным подходом в моделировании.

В качестве передовой практики стоит использовать настраиваемый рабочий процесс, чтобы обеспечить выполнение предварительных шагов утверждения в жизненном цикле в соответствии с принятой корпоративной политикой. Автоматизированные системы и процессы могут упростить эти шаги и обеспечить наибольшую прозрачность для разработчиков моделей и всех заинтересованных сторон.

3: В каком контексте используется модель ML? Вы понимаете все потенциальные риски вашей модели ML?

Модели не существуют изолированно. Как правило, данные, которые были получены преобразованием одной модели, являются входными для других. Например, если у вас есть модель, которая прогнозирует будущие процентные ставки, тогда выходные данные этой модели могут послужить входными для других с учетом полученных процентных ставок. Наличие этих связей может привести к непредвиденным последствиям – например, когда вышестоящие данные или модели изменяются, то нижестоящие модели могут стать неисправными. Обратите внимание, что:

Модельный риск возрастает с увеличением сложности модели, повышенной неопределенности относительно исходных данных и допущений, более широкого использования и увеличения потенциального воздействия. Банки должны учитывать риск по отдельным моделям и агрегировано.

Агрегированный модельный зависит от взаимодействия и зависимостей между моделями; опирается на общие предположения, данные или методологию; и любые другие факторы, которые могут одновременно неблагоприятно повлиять на несколько моделей и их результаты. После того, как выявлены источники и оценена величина модельного риска, следующий шаг – правильное управление им.¹³

«...разработка полного перечня моделей для всей компании и выявление взаимосвязей между ними, повысили осведомленность о модельных рисках которые возникают не только на уровне одной модели, а также в связи с теми рисками, которые существуют между моделями и за их пределами, что в совокупности представляет собой экосистему моделей»¹⁴

¹³ The Federal Reserve's "Guidance on Model Risk Management" (SR Letter 11-7)

¹⁴ "The top 14 challenges for today's model risk managers: Has the time come to think about going beyond SR11-7," Journal of Risk Management in Financial Institutions

Как показано на рисунке 2, визуализация связей между данными и моделями может помочь менеджерам по управлению рисками поставить модель в соответствующий контекст и понять ее влияние на другие модели. Такая визуализация связей между моделями и данными крайне важна для всех типов моделей, но потребность в них возникает при использовании методов машинного обучения, поскольку они обладают более высоким уровнем риска и динамичностью использования разных переменных и источников данных. При помощи построения диаграммы связей можно выявить менее прозрачные и более динамичные модели в системе, которым следует уделить пристальное внимание.




Рисунок 2: Диаграмма связей моделей и данных помогают визуализировать агрегированный риск.

4: Вы знаете, на каких данных работают ваши модели?

Сегодня существует большой интерес к использованию машинного обучения для превращения огромных объемов данных - включая неструктурированные - в новые идеи и информацию. В отличие от традиционных статистических моделей, которые ограничены в количестве измерений, к которым они могут обращаться, модели ML преодолевают это. Модели ML могут обрабатывать огромное количество неструктурированных данных, выявлять закономерности и преобразовывать их в практическую информацию.

Модели ML также могут принимать данные из неструктурированных источников данных в различных форматах. Например, в отчете Казначейства США за июнь 2018 года выделены некоторые альтернативные источники данных, используемые сегодня в рамках продвинутых моделей кредитования. В частности, в документе отмечено, что «новые модели и данные также могут произвольно увеличивать риск получения результатов, которые, например, нарушают законы о справедливом кредитовании, тогда Федеральная Торговая Комиссия или Бюро финансовой защиты потребителей могут признать их использование нарушением UDAP и UDAAP (практики в банковском регулировании США), соответственно.¹⁵

«Учитывая большие наборы данных вместе с большинством AI подходов, жизненно важно иметь контроль над различными аспектами данных, включая качество и соответствие требованиям»¹⁶

¹⁵ Financial System That Creates Economic Opportunities: Nonbank Financials, Fintech, and Innovation. US Federal Reserve report, p. 137. 2018. <https://home.treasury.gov/sites/default/files/2018-07/A-Financial-System-that-Creates-Economic-Opportunities---Nonbank-Financi....pdf>

¹⁶ Fed Board of Governors speech 2018: What Are We Learning About Artificial Intelligence in Financial Services? <https://www.federalreserve.gov/newsevents/speech/brainard20181113a.htm>

Управление моделями и данными часто пересекаются. Однако, учитывая непрозрачный характер многих методов ML, их способность использовать многомерные измерения и неструктурированные наборы данных, а также необходимость более частой перекалибровки моделей ML, бремя управления переместилось на данные.

Хотя повышенная зависимость от данных может повысить точность модели, она также может привести к ошибкам и неточностям. Рассмотрим влияние погрешностей на соблюдение требований кредитования. Правила «справедливого кредитования» предназначены для защиты потребителей от недобросовестной или дискриминационной практики кредитования - частично путем ограничения типов данных, которые банк может использовать для определения необходимости предоставления кредита. Например, банк не может отклонить заявку на кредит из-за возраста заявителя, расы, пола, почтового индекса, религии, семейного положения и т.д. Однако, если банк использует альтернативные источники данных и методы ML для принятия решений о кредитовании, возможна ситуация, что его модели непреднамеренно используют входные данные, которые прямо указывают на защищенный класс. Модель ML могла бы идентифицировать взаимосвязи между людьми, которые слушают радио станции с рок-музыкой, и их процентные ставки по умолчанию. Такая модель может стать причиной подачи жалобы в связи с нарушением прав потребителей. Как показывает приведенный пример, модели машинного обучения могут неявно выводить закономерности и корреляции из полей, которые первоначально не наблюдались, поэтому необходимо тщательно и постоянно наблюдать за поведением своих моделей.

Кроме того, модели ML, как известно, вносят необоснованное смещение, переобучаясь на тренировочных данных. Классическим примером является модель, которую создал Amazon между 2014 и 2017 годами, для скрининга резюме и генерации предложений для потенциально новых сотрудников. Amazon использовала данные о найме и производительности труда за 10 лет для обучения модели. К сожалению, данные имели отрицательное смещение в отношении женщин и оценили возможных кандидатов-женщин ниже. Из-за гендерного разделения рабочей силы в Amazon, использованный набор данных больше соответствовал модели для поиска кандидатов мужского пола.

Излишняя подгонка к вашему набору обучающих данных может привести к необоснованному смещению и является серьезным затруднением при валидации и управлении ML. Такие методы, как локально интерпретируемые объяснения, не зависящие от устройства модели (LIME), синтетическое построение тестовых данных и оценка относительной важности переменных, могут быть использованы для уменьшения смещения. Поэтому в рамках управления моделью очень важно оценить источники данных и переменные, доступные для использования методы моделирования ML, чтобы вы могли ответить на следующие вопросы:

«В прошлом ошибки допускались очень часто, когда финансисты слишком увлекались каким-то новым, сложным способом ведения дел. ИИ и машинное обучение не должны быть добавлены в список финансовых проблем, где руководители допустили риски, на которые пошли их аналитики, опережая свои способности понимать и контролировать происходящее»¹⁷

¹⁷ ECB Supervisory Board member speech 2018, "The digitalisation of banking – supervisory implications." <https://www.bankingsupervision.europa.eu/press/speeches/date/2018/html/ssm.sp180606.en.html>

- Какие данные доступны для модели?
- Довольны ли вы тем, что модель принимает решения на основе этих данных?
- Смогли бы вы сообщить клиенту, что решение было принято из-за этих данных?
- Нарушают ли входные данные прямо или косвенно какие-либо правила регулятора? (например, справедливое кредитование)?
- Как вы уменьшили смещение модели?
- Как часто появляются новые поля в данных?

Эти вопросы уместны, потому что модели машинного обучения часто подгоняются под тренировочные данные, вносят необоснованное смещение и быстро ухудшаются по мере изменения данных. Из-за этого модельного риска целесообразно сравнивать разницу между данными, используемыми для обучения и тестирования модели ML, и данными, на которых она применяется в промышленной эксплуатации. Когда форма и структура фактических данных слишком отличаются от тренировочных данных, модель следует пересмотреть.

С точки зрения управления моделями все эти действия должны быть задокументированы и рассмотрены на этапе обоснования методологии. Учитывая сложность этой работы, многие компании используют современные системы управления моделями для документирования того, какие источники данных доступны для каждой модели, а также для обеспечения ранних предупреждающих сигналов при изменениях данных за допустимые пределы. Мониторинг производительности ваших входных данных модели ML обеспечит дополнительную прозрачность, необходимую для принятия обоснованных решений о ее точности и пригодности для заданной цели.

5: Можно ли объяснить результаты модели машинного обучения?

Требования регуляторов, в том числе SR 11-7 и OCC 2011-12, классифицируют алгоритмы с использованием техник машинного обучения так же, как и традиционные алгоритмы, а именно с помощью моделей. Глобальные регуляторы требуют от пользователей моделей понимания ограничений, целей и результатов каждой из используемых ими. Таким образом, ваши модели машинного обучения должны быть объяснимыми. Во многих случаях регуляторы также вынуждают сотрудников кредитного подразделения объяснить простыми словами, почему было принято то или иное решение. Процедуры банковского контроля за справедливым кредитованием должны соответствующим образом помечать классификации смещения. Это требование является прекрасным примером почему выходные данные модели ML / AI должны быть интерпретируемыми и объяснимыми.

¹⁸ <https://www.federalreserve.gov/supervisionreg/srletters/sr1518.htm>. Federal Reserve, Attachment SR 15-18

Некоторые методы машинного обучения не дают представления о том, что движет предсказание модели. Отсутствие прозрачности является серьезной проблемой, как объяснил член Наблюдательного совета ЕЦБ в 2018 году:

«Алгоритмы, лежащие в основе ИИ, должны быть тщательно спроектированы, а решения, принимаемые на основе результатов этих алгоритмов, должны быть хорошо объяснимы как руководителями банков, так и надзорными органами».¹⁸

Ограничения «интерпретируемости» машинного обучения не позволили многим банкам воспользоваться новыми инновационными источниками данных.

Это ограничивает предсказательную силу моделей ML. Исследования показывают, что, если они не используют новые источники данных, модели машинного обучения часто не могут превзойти исторически используемые статистические модели. Организации должны определить, стоит ли переходить от хорошо понятных и интерпретируемых моделей к более сложным и менее прозрачным моделям машинного обучения.

В попытках повысить интерпретируемость аналитики часто выходят за рамки соответствия нормативным требованиям. Потребляя большие объемы данных при использовании моделей машинного обучения, пользователи должны понимать и быть готовы объяснить результаты, чтобы лица принимающие решения могли им доверять. Проблема интерпретируемости моделей сильнее возрастает при работе со сложными моделями, представляющие собой черный ящик, например, глубокие нейронные сети. В таких случаях бизнес-пользователям, командам разработки, валидаторам, аудиторам и регуляторам требуется прозрачность, чтобы понимать и доверять результатам моделей.

Такие методы, как построение графиков частичной зависимости (Partial Dependence Plots, PDP), SHAP, графики индивидуальных условных ожиданий (Individual Conditional Expectation, ICE), оценки важности переменных и LIME, уже используются повсеместно и дают некоторое представление о важных особенностях моделей машинного обучения и их чувствительности к определенным переменным. Индустрия продолжает совершенствовать способы интерпретации, но их пока недостаточно, чтобы полностью раскрыть тайну моделей машинного обучения.

В свете данных проблем каждая модель ML должна иметь документированный подход к интерпретации. В идеальном случае, компании должны обеспечить централизованное хранение информации и поддерживать ее с течением времени, в том числе, данные о следующих фактах:

- Бизнес-контексте применения модели
- Выбранной технике интерпретации.
- Обоснование выбора такого метода.
- Ограничения подхода и другое

¹⁸ ECB Supervisory Board member speech 2018, "The digitalisation of banking – supervisory implications." <https://www.bankingsupervision.europa.eu/press/speeches/date/2018/html/ssm.sp180606.en.html>

6: Как работают ваши модели ML?

По данным Федеральной резервной системы: «Фирма должна использовать меры для оценки эффективности модели, которые соответствуют типу используемой модели». ¹⁹ Мониторинг эффективности позволяет понять, насколько хорошо ваши модели могут прогнозировать относительно фактических результатов. Данные о производительности часто используются в аудиторских отчетах в качестве сигналов раннего предупреждения, позволяющих выполнить надлежащие планы действий в чрезвычайных ситуациях, и в качестве руководящих принципов для перекалибровки моделей или вывода их из эксплуатации. Как правило, пороговые значения для этих сигналов обсуждаются между несколькими сторонами, включая группу управления модельными рисками, разработчиков, владельца модели и валидаторов. Эти ограничения должны быть задокументированы и подписаны в соответствии с принятыми политиками управления моделями. Программное обеспечение для управления моделями может помочь автоматизировать этот процесс и документировать утверждения.

Традиционно периодичность проведения этих количественных тестов устанавливается в соответствии с существенностью модели и доступностью ресурсов. Динамический характер некоторых методов машинного обучения (например, обучение с подкреплением) требует более частого мониторинга производительности. С помощью программного обеспечения для управления моделями, которое автоматизирует эту работу, вы сможете запускать мониторинг производительности в соответствии с тем регламентом, который примете у себя, например, еженедельно, ежедневно или даже несколько раз в день. В идеальном варианте результаты генерируются систематически и автоматически передаются через систему управления модельными рисками, которая сравнивает их с ранее согласованными пороговыми значениями и выдает предупреждения, в случае их превышения. Обратите внимание, что в условиях небольшого объема бизнеса слишком частое формирование таких отчетов будет давать нестабильные результаты. Таким образом, эти отчеты должны запускаться так часто, как того требует объем бизнеса.

Динамический характер некоторых методов машинного обучения (например, обучение с подкреплением) требует более частого мониторинга производительности.

¹⁹ <https://www.federalreserve.gov/supervisionreg/srletters/sr1518.htm>. Federal Reserve, Attachment SR 15-18

7: Кем, когда и как используются модели машинного обучения?

Большинство организаций не располагают полными и актуальными данными о том, какие модели используются, а также как, где и кем. В большинстве случаев эти данные собираются вручную или, в лучшем случае, неструктурированным образом. Это находится в прямом противоречии с передовой практикой и нормативными руководящими принципами, в которых говорится, что «масштабы и сложность функций управления банком должны соответствовать масштабам и сложности использования моделей».²⁰

Проще говоря, без надлежащих данных об использовании модели вы не сможете ответить даже на простые вопросы о вашем текущем инвентаре моделей. Продвинутой подход к управлению модельными рисками предполагает накопление информации об использовании посредством автоматизированных систем.

«Неутешительная правда заключается в том, что в настоящий момент большинство финансовых фирм не могут претендовать на наличие полного и точного перечня всех своих действующих моделей, несмотря на то, что это является нормативным требованием, которое все чаще подвергается проверке в условиях возрастающего контроля со стороны регулятора. Еще более неприятен тот факт, что эти фирмы не могут ответить с большой точностью на такие вопросы: «сколько раз эта модель фактически использовалась в течение последнего года?» или «какие модели имеют чувствительность к сезонности» или «в каких географических регионах или юридических лицах используется эта модель?» или «есть ли в вашем реестре проверенные модели с активным статусом, которые не были применены ни разу с прошлого года?»²¹

С появлением методов машинного обучения значительно возросло количество моделей, используемых организациями. Однако без централизованной системы управления моделями, организации не смогут должным образом управлять рисками, которые несут с собой модели. Постоянное накопление данных об использовании дает дополнительную информацию о состоянии вашего реестра моделей. Эти данные в сочетании с другими качественными и количественными оценками станут основой для использования методов машинного обучения.

²⁰ The Federal Reserve's "Guidance on Model Risk Management" (SR Letter 11-7)

²¹ Source: Hill, J. R. (2018) "Shouldn't a model 'know' its own ID?" The Journal of Structured Finance, Fall, pp.89-98.

8: Как калибруются модели машинного обучения?

Как и в случае других, модели машинного обучения должны быть периодически перекалиброваны, и каждая калибровка может существенно изменить их производительность. Чтобы контролировать и понимать эти изменения, нужен способ, позволяющий четко и последовательно определять, проверять и утверждать план повторной калибровки для каждой модели. Все изменения, которые производятся в моделях в рамках данного плана, должны контролироваться аналогичным образом. Поскольку такие средства управления сложно реализовывать и отслеживать вручную, рекомендуется их автоматизировать.

9: Насколько эффективны ваши модели машинного обучения по сравнению со статистическими моделями? Разработали ли вы план на «черный» день?

Для моделей ML с высокой материальностью и низкой прозрачностью лучше всего назначить статистическую версию в качестве эталона или чемпиона, чтобы вы могли отслеживать ее производительность относительно другой. Как указано ФРС в SR 15-18, «для более эффективной калибровки окончательных результатов оценок, компании могут независимо использовать выходные данные бэнчмарк-модели. Например, компания может использовать результаты этих моделей для обоснования выбора, с учетом всех рисков и преимуществ, которые есть у первоначальной и эталонной моделей».²²

«Наиболее эффективными модели-претенденты/ эталоны являются те, которые реализуют методологию, отличную от методологии модели-чемпиона»²³

Бенчмаркинг позволяет сравнивать и оценивать результаты и производительность модели ML со статистическими моделями. Если производительность ухудшается, вы можете заменить ее лучшей версией среди статических. План на случай чрезвычайных обстоятельств всегда должен быть четко определен и утвержден в рамках ваших политик процесса управления жизненным циклом моделей. В рамках каждого такого плана должны быть указаны критерии, которые нужно соблюдать для прозрачного объяснения перехода. Для упрощения выстраивания таких методов контроля, быструю подготовку и вывод в промышленную эксплуатацию моделей для замены, рекомендуется использовать специализированные системы по управлению моделями.

10: Вы в состоянии быстро приспособиться и ответить на все изменения, которые диктует рынок?

Бизнес, рыночные и регуляторные требования со временем изменятся - это неоспоримый факт. Вопрос в том, насколько быстро и эффективно организации смогут адаптироваться к этим изменениям? Все большее распространение использования техник машинного обучения ставит

²² <https://www.federalreserve.gov/supervisionreg/srletters/sr1518.htm>. Federal Reserve, Attachment SR 15-18

²³ The top 14 challenges for today's model risk managers: Has the time come to think about going beyond SR11-7, Journal of Risk Management in Financial Institutions

под сомнение существующие политики и системы управления. Сегодня многие данные о модельных рисках хранятся в электронных письмах, на локальных дисках, в «разговорах» в коридоре и на бумажных носителях.

Учитывая такую скорость изменений, важно иметь инструменты и ресурсы для преобразования огромных объемов данных, которые теперь доступны бизнесу, в своевременное понимание как улучшить управление вашими моделями. Вооружившись этой информацией, ваша организация может развернуть итерационные методы управления модельными рисками с помощью подхода, основанного на данных, для оценки рисков модели, выявления пробелов, анализа и обновления политик и точной настройки процессов. Принятие машины увеличит скорость изменения модели управления, необходимую для успешного прослушивания и адаптации к вашим данным.

Будущее управления модельными рисками: модели проверяют модели

Достаточно ли вы подготовлены, чтобы ответить на все эти вопросы о ваших моделях ML? Сможете ли вы своевременно адаптироваться, так как использование машинного обучения в вашей организации увеличивается?

Если нет, то не переживайте, вы не единственные. В опросе пользователей MRM, который проводился SAS в 2018 году, мы спросили: «Каково, на ваш взгляд, будет влияние искусственного интеллекта на управление модельными рисками?». Как показано на рисунке 3, 60% респондентов ответили, что модели AI значительно усложнят их работу, в то время как 30% считают, что «модели искусственного интеллекта можно использовать для улучшения или автоматизации деятельности по управлению модельными рисками»²⁴

Сможете ли вы своевременно подстроиться к новым реалиям, ведь использование моделей ML в вашей компании быстро возрастает?

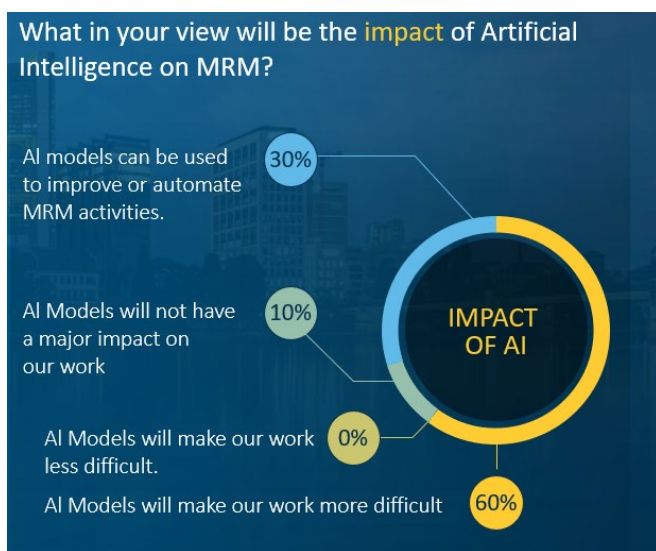


Рисунок 3: Ожидаемое влияние AI на MRM.

²⁴ SAS' 2018 SAS MRM Customer Survey

Поскольку применение машинного обучения становится нормой, ваш бизнес, вероятно, будет использовать тысячи моделей одновременно; на самом деле, в некоторых крупных предприятиях уже так. Таким образом, вопрос состоит в том, как вы можете реализовать и масштабировать строгое управление моделями?

Ответом может быть использование «умных» моделей ML, созданных для проверки и управления моделями машинного обучения.

Это вполне осуществимо и логично с использованием модернизированной платформы управления модельными рисками, которая будет собирать и хранить множество данных и информации MRM, включая:

- Правильная классификация и построение иерархии моделей.
- Постоянный мониторинг производительности количественных данных.
- Проведение сравнения контрольных показателей.
- Данные об использовании моделей.
- Диаграмма связей моделей, переменных, данных и т.д.
- Информация по интерпретируемости моделей, чувствительности переменных
- Метрики качества входных данных.
- Согласованная документация.
- Метаданные моделей.
- Высококвалифицированные результаты проверки.
- И многое другое.

SAS предполагает, что автоматизированного управления моделями, которое основано на анализе данных, сыграет значительную роль в валидации отдельных моделей машинного обучения и даже целого реестра моделей. Конечно, с наличием модели, валидирующей другие модели, возрастают риски сохранения некорректно работающих моделей, однако, это предоставляет возможность автоматизировать процессы валидации, а также идентификации рисков, выявить которые человеку может быть не под силу.

Узнать больше

Поскольку ваша компания серьезно рассматривает вопрос о замене понятных статистических моделей на сложные модели AI / ML, пришло время подумать о том, как вы будете внедрять и масштабировать комплексное управление моделями. Модели ML обещают лучшие прогнозы, но они могут вводить в неизвестные этические предубеждения и повышать уровень модельного риска. Специалисты по управлению модельным риском занимаются решением, как наилучшим образом снизить этот риск с помощью автоматизации, технологий и лучших практик. Используя передовой опыт, рассмотренный выше - обоснование использования, визуализация связей, управление данными, мониторинг производительности, перекалибровка, интерпретация, бенчмаркинг и подготовка планов на случай непредвиденных обстоятельств - финансовые организации смогут лучше удовлетворять возросшие нормативные требования при внедрении мощной, надежной и автоматизированной инфраструктуры управления моделями машинного обучения.

Чтобы узнать больше о том, как SAS может помочь реализовать эти лучшие практики, посетите sas.com/mrm.

Чтобы связаться с местным офисом SAS, посетите: sas.com/offices



SAS и все другие названия продуктов или услуг SAS Institute Inc. являются зарегистрированными товарными знаками или товарными знаками SAS Institute Inc. в США и других странах. ® указывает на регистрацию в США. Другие торговые марки и названия продуктов являются товарными знаками соответствующих компаний. Copyright © 2019, SAS Institute Inc. Все права защищены.