

# Большие данные и квантильный риск-контроль на рынке цифровых активов

**Шеварев Максим Владимирович**

Студент

Московский политехнический университет, г. Москва, Российская Федерация

E-mail: shevarev.max@mail.ru

**Царькова Наталья Ивановна**

Кандидат педагогических наук, доцент

Московский политехнический университет, г. Москва, Российская Федерация

E-mail: tszrkovani@mail.ru

**Суворов Станислав Вадимович**

Кандидат экономических наук, доцент, профессор

Московский политехнический университет, г. Москва, Российская Федерация

E-mail: ssw1168@mail.ru

## КЛЮЧЕВЫЕ СЛОВА

большие данные;  
цифровые активы;  
квантильное  
прогнозирование; риск-  
контроль; Биткоин;  
Солана; волатильность;  
рынок капитала

## АННОТАЦИЯ

Статья посвящена теоретико-прикладному осмыслению роли больших данных в управлении риском цифровых активов. Предмет исследования составляют режимы риск-контроля, основанные на квантильном прогнозировании доходности Биткоина и Соланы как двух активов с разной структурой волатильности и разной степенью зрелости рынка. Цель работы состоит в том, чтобы показать, при каких условиях расширение информационной базы действительно создает экономический эффект, а не сводится к росту вычислительной сложности. Методическая схема объединяет теоретические положения об экономике неопределенности, квантильную регрессию, квантильный бустинг LightGBM, графовую модель непрерывного времени DG-Neural ODE, а также показатели pinball loss, покрытия интервалов, коэффициента Шарпа и максимальной просадки. Использование больших данных трактуется как соединение длинных временных рядов, разнотипных рыночных индикаторов, новостных сигналов и межрыночных зависимостей. Полученные результаты показывают, что статистическое качество прогноза и его экономическая полезность не совпадают: для Биткоина наилучший компромисс между доходностью и риском обеспечивает LightGBM, тогда как для Соланы дополнительный эффект дает DG-Neural ODE, лучше фиксирующая смену рыночного режима. Сделан вывод о том, что в теории риск-контроля на рынке цифровых активов ключевое значение имеет не максимальная сложность модели сама по себе, а связь между шириной прогнозного интервала, селективным участием в рынке и институциональными правилами ограничения позиции.

JEL codes: D81, C53, G17, G32, O33

DOI: <https://doi.org/10.52957/2221-3260-2026-7-214-226>

Для цитирования: Шеварев, М.В. Большие данные и квантильный риск-контроль на рынке цифровых активов / М.В. Шеварев, Н.И. Царькова, С.В. Суворов. – Текст : электронный // Теоретическая экономика. – 2026. – № 7. – С.214-226. – URL: <http://www.theoreticaleconomy.ru> (Дата публикации: 30.07.2026)

## Введение

Цифровые активы за короткий период превратились из технологической новации в самостоятельный сегмент мирового рынка капитала. Именно поэтому вопрос о пределах допустимого риска в операциях с такими активами перестал быть частным вопросом торговой техники и приобрел статус общей проблемы экономической координации в условиях неопределенности. Российские публикации по цифровым финансовым активам показывают, что для кредитных

организаций, эмитентов и инвесторов на первый план выходят процедуры ограничения убытков, правила распределения капитала и построение внутренних контуров риск-контроля [1-3]. Зарубежная литература, в свою очередь, подчеркивает, что рынок криптоактивов является не только площадкой спекулятивного обмена, но и новой формой экономической инфраструктуры, где доверие, ликвидность, информационные сигналы и сетевые эффекты взаимодействуют иначе, чем на традиционных финансовых рынках [5; 8; 17].

Для такой среды недостаточно модели, которая сообщает лишь ожидаемое направление движения цены. Экономическому субъекту важно знать, насколько широк диапазон вероятных исходов, как меняется структура риска при переходе от спокойного режима к стрессовому и когда сокращение позиции дает больший выигрыш, чем попытка сохранить участие в рынке. В этом смысле проблема имеет не только прикладной, но и теоретический характер: речь идет о выборе правила поведения в ситуации, когда распределение будущих результатов подвижно и зависит от объема доступной информации. Именно здесь большие данные начинают играть роль не как модный технологический ярлык, а как особый способ организации экономического знания о рынке [13; 16; 22].

Важным контекстом исследования является и изменение самой природы наблюдаемости финансового рынка. Для традиционных активов информационный поток относительно стабилен: корпоративная отчетность, макроэкономическая статистика, ставка центрального банка, биржевая история. Для цифровых активов к этому добавляются непрерывные сетевые сигналы, поведение участников в социальных медиа, on-chain активность, технологические обновления протоколов и мгновенные трансграничные переливы капитала. Поэтому рынок цифровых активов можно рассматривать как лабораторию теоретической экономики, в которой особенно ясно проявляется зависимость между формой информации и формой рационального решения. Если на таком рынке удастся показать, что большие данные приводят к лучшему правилу риск-контроля, то этот вывод имеет значение далеко за пределами криптовалютного сегмента.

Под большими данными в настоящей работе понимается не простой рост числа наблюдений, а объединение длительных временных рядов, показателей волатильности, новостных и социальных сигналов, а также информации о межрыночной связанности в единую систему принятия решений. Такая трактовка соотносится с работами, где криптовалютный рынок описывается как среда с высокой чувствительностью к информационным импульсам и внешним шокам [10; 13; 22; 25]. Если расширение информационного набора действительно уменьшает потери в неблагоприятных режимах, то возникает вопрос уже теоретической экономики: какова связь между информацией, неопределенностью и рациональным ограничением позиции на рынке цифровых активов.

Цель статьи состоит в разработке и эмпирической проверке теоретико-прикладной схемы, в которой большие данные рассматриваются как основание для квантильного риск-контроля на рынке цифровых активов. В качестве эмпирической иллюстрации выбраны Биткоин и Солана. Первый актив представляет относительно зрелый сегмент крипторынка и выполняет роль якоря для всей экосистемы. Второй, напротив, характеризуется большей чувствительностью к режимным сдвигам и сетевым переливам риска. Такое сопоставление позволяет показать, как меняется экономический эффект одной и той же информационной стратегии на активах с разной структурой рынка.

## Теория

Теоретической отправной точкой исследования является различие между точечным прогнозом и правилом поведения под неопределенностью. В логике неоклассического выбора решающему субъекту требуется не отдельная средняя оценка результата, а представление о распределении возможных состояний. Квантильный подход соответствует этой логике значительно лучше, чем прогноз среднего, поскольку задает не одну ожидаемую величину, а систему границ, в которой можно различить центральные и хвостовые сценарии. В работах по quantile regression и proper scoring rules это различие сформулировано как переход от ошибки среднего к оценке формы условного

распределения [11; 20]. Для финансового рынка это особенно важно, так как именно хвостовые отклонения определяют потребность в страховом запасе ликвидности, маржинальных ограничениях и экстренном сокращении позиции.

Стеоретико-экономической точки зрения большие данные меняют не просто точность прогноза, а саму архитектуру наблюдения за рынком. Когда модель использует лишь собственные лаги цены, она фактически исходит из узкой версии адаптивных ожиданий. Когда же в нее включаются индикаторы новостного фона, показатели рыночной турбулентности, сигналы социальных медиа и межрыночные связи, происходит переход к более насыщенной информационной среде, в которой участник рынка реагирует не только на собственную историю актива, но и на состояние всей цифровой экосистемы [10; 13; 16; 22; 25]. Следовательно, большие данные можно интерпретировать как расширение пространства наблюдаемых факторов, которое способно изменить как калибровку ожиданий, так и экономический результат правила принятия решения.

Однако расширение информации не гарантирует автоматического улучшения результата. Теория экономических ограничений блокчейн-инфраструктуры показывает, что стоимость доверия, уязвимость к атакам и сетевые эффекты делают рынок цифровых активов внутренне неоднородным [5; 8]. Чем сложнее актив и чем сильнее его зависимость от общего крипторезима, тем вероятнее ситуация, когда сложная модель оказывается полезной не потому, что она точнее предсказывает среднюю доходность, а потому, что раньше фиксирует смену режима. Отсюда вытекают три рабочие гипотезы. Во-первых, увеличение информационного набора повышает качество интервального описания рынка по сравнению с моделями, использующими только лаги доходности. Во-вторых, экономическая ценность прогноза определяется не только снижением средней ошибки, но и возможностью селективного участия в рынке. В-третьих, для зрелых активов преимущество получают более устойчивые и интерпретируемые модели, тогда как для высоковолатильных активов дополнительную полезность могут давать сложные нелинейные модели.

В этой логике квантильный риск-контроль понимается как институт локального ограничения риска. Модель не диктует субъекту, когда следует обязательно купить или продать актив, а задает правило допустимого участия: при чрезмерно широком прогнозном интервале позиция сокращается или закрывается, при умеренном интервале участие в рынке сохраняется. Таким образом, решение зависит от ширины допустимого коридора неопределенности, а не только от ожидаемого знака доходности. В теоретическом плане это сближает управление цифровыми активами с более общей задачей адаптивного регулирования поведения экономического агента в условиях неполной информации.

Теоретическая конструкция исследования также опирается на различие между информацией как общественным ресурсом и информацией как частным преимуществом. На традиционных финансовых рынках многие участники пользуются сходными статистическими наборами, из-за чего дополнительная информация быстро капитализируется в цене. На рынке цифровых активов это происходит не полностью: часть информации распадается на фрагменты новостного потока, сетевой активности, on-chain сигналов и межбиржевых различий. Отсюда вытекает ключевая особенность больших данных в криптоэкономике: они не просто увеличивают объем входной информации, а уменьшают фрагментацию наблюдения за рынком. Экономический агент получает возможность связывать частные сигналы в единую картину и тем самым раньше распознавать режимы напряженности или перегрева.

В этой связи квантильный риск-контроль можно рассматривать как частный случай адаптивного института самоограничения. На уровне отдельного инвестора или внутреннего подразделения финансовой организации это правило задает границу допустимого риска; на уровне системы оно снижает вероятность проциклического наращивания позиции в моменты, когда сама рыночная среда становится информационно нестабильной. Тем самым большие данные влияют не только на качество прогноза, но и на дисциплину участия в рынке. Подобное понимание соответствует

современной литературе по финансовому моделированию и управлению риском инструментов с высокой волатильностью, где подчеркивается необходимость соединять статистическую оценку с экономическим правилом действия [16-17].

На уровне гипотез это позволяет уточнить рабочую схему исследования. Первая гипотеза утверждает, что расширенный информационный набор улучшает калибровку распределения за счет включения факторов, которые не наблюдаются в модели на одних только ценовых лагах. Вторая гипотеза предполагает, что экономический эффект выражается прежде всего в сокращении глубины просадки, а не обязательно в росте средней доходности. Третья гипотеза предполагает неодинаковую отдачу от модельной сложности на разных активах: чем сильнее сетевые эффекты и режимные переливы, тем выше полезность архитектур, учитывающих взаимодействие между узлами системы.

### Данные и методы

Эмпирическая база включает суточные котировки Биткоина и Соланы за 2013-2025 гг. Для сопоставимости ценовые ряды преобразованы в логарифмические доходности. В набор объясняющих переменных включены лаговые значения доходности, показатели скользящей волатильности, индикаторы общего рыночного режима и сигналы новостного фона. Такой состав данных соответствует трактовке больших данных как сочетания объема, разнообразия и скорости обновления информации. Подходы, в которых для прогноза криптовалют сочетаются внутренние и внешние детерминанты, уже показали преимущество над узкими однофакторными спецификациями [7; 15; 24].

Доходность актива рассчитывалась по стандартной формуле логарифмической доходности:

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad (1)$$

Логарифмическая доходность рассчитывалась по стандартной формуле. Ее использование позволяет корректно сопоставлять относительные изменения цены на активах с разным уровнем котировки и избегать искажений, возникающих при работе с абсолютными приростами. Для оценки качества прогноза применялась функция потерь pinball loss, поскольку она соответствует квантильной постановке задачи и различает цену недооценки и переоценки хвостовых состояний [11; 20]. Экономический эффект модели оценивался через коэффициент Шарпа и максимальную просадку, то есть через показатели, непосредственно связанные с выбором правила распределения капитала.

При эмпирическом сопоставлении использовались три группы моделей. Первая - линейная квантильная регрессия как базовый и интерпретируемый инструмент. Вторая - квантильный бустинг LightGBM, способный извлекать нелинейные зависимости на табличных данных и уже показавший устойчивые результаты при прогнозировании криптовалют [6; 18]. Третья - графовая модель DG-Neural ODE, предназначенная для описания системы взаимосвязанных активов и пригодная для случаев, когда важны режимные переключения и сетевые переливы волатильности. Выбор именно такого трио моделей позволяет проверить, где проходит граница между интерпретируемостью, статистической точностью и экономической полезностью.

Качество квантильных оценок определялось по функции потерь pinball loss:

$$L_\tau(y_t, q_\tau, t) = (\tau - I(y_t < q_\tau, t)) (y_t - q_\tau, t) \quad (2)$$

где  $\tau$  - уровень квантиля,  $y_t$  - фактическая доходность,  $q_{\tau,t}$  - прогнозный квантиль. Метрика удобна тем, что асимметрично штрафует ошибки в хвостах распределения и потому соответствует задачам риск-контроля.

Экономическая полезность стратегии измерялась через коэффициент Шарпа:

$$SR = \frac{(r_m - r_f)}{\sigma_p} \quad (3)$$

где  $r_m$  - средняя доходность стратегии,  $r_f$  - безрисковая ставка,  $\sigma_p$  - стандартное отклонение

доходности портфеля.

Выборка была разделена на обучающий, валидационный и тестовый периоды. Обучение проводилось на данных до конца 2021 г., 2022 г. использовался для подбора гиперпараметров, а итоговая проверка выполнялась на интервале 2023-2025 гг. Такой дизайн позволяет отделить настройку алгоритмов от реальной проверки их устойчивости на новых режимах рынка. Для Биткойна и Соланы — это принципиально важно, поскольку их динамика на разных участках выборки существенно различается и включает эпизоды резкого роста, коррекции и смены рыночной ликвидности.

Информационный набор был построен по блоковому принципу. Первый блок включал собственные лаговые доходности и их преобразования. Второй блок состоял из показателей текущей и реализованной волатильности, которые отражают инерцию рынка. Третий блок содержал агрегированные внешние сигналы: индексы новостного давления, настроение рынка и показатели межрыночного режима. Четвертый блок описывал связанность активов, то есть совместное движение Биткойна и Соланы в периоды стрессов и восстановления. Такая композиция отражает предпосылку о том, что цифровой рынок формируется не только локальной динамикой цены, но и внешней информационной средой.

Пороговое правило участия в рынке задавалось одинаково для всех моделей, чтобы отделить влияние алгоритма от влияния торгового дизайна. Если ширина 90%-интервала превышала установленную границу, позиция не открывалась либо закрывалась. В противном случае сохранялась длинная позиция. Подобный подход принципиально отличается от стратегий, основанных на бинарном прогнозе роста или снижения цены. Здесь субъект принимает решение не о направлении, а о степени допустимости участия. Благодаря этому экономический смысл прогнозной модели становится прозрачнее: она ценится постольку, поскольку позволяет отличать приемлемую неопределенность от неприемлемой.

Для обеспечения сопоставимости все модели оценивались на одинаковой временной сетке и на одном и том же наборе выходных квантилей. Линейная квантильная регрессия обучалась отдельно для уровней 0,05, 0,50 и 0,95. LightGBM использовал квантильную функцию потерь и нелинейное разбиение пространства признаков. DG-Neural ODE рассматривалась как система взаимосвязанных уравнений в скрытом пространстве, где Биткойн и Солана представлены узлами одной динамической структуры. В этой постановке модель особенно полезна тогда, когда шок в одном активе быстро меняет распределение ожидаемых исходов в другом.

Методическая значимость такого дизайна состоит в том, что он соединяет теоретическую логику и воспроизводимую эмпирику. Теория задает интерпретацию информации как фактора экономического выбора, а эмпирическая часть проверяет, в какой мере разная архитектура обработки этой информации отражается на ширине интервала, коэффициенте Шарпа и максимальной просадке. Иными словами, исследование строится на переходе от информационной структуры к институциональному правилу поведения и далее к наблюдаемому финансовому результату.

### Модель

Логика модели строится вокруг предположения, что экономически полезный прогноз должен описывать не точку, а коридор возможных исходов. Линейная квантильная регрессия задает этот коридор через условные квантили доходности и позволяет интерпретировать влияние факторов напрямую. Квантильный бустинг решает ту же задачу, но уже в нелинейном пространстве признаков. DG-Neural ODE добавляет к этому описанию структуру взаимосвязанного движения активов, где изменения в одном узле могут быстро передаваться другим узлам системы. Именно на этом этапе проявляется теоретический смысл больших данных: рынок рассматривается не как набор независимых временных рядов, а как сеть взаимозависимых сигналов.

Формально для каждого момента времени оценивались нижний, центральный и верхний квантили распределения следующей суточной доходности. Ширина интервала использовалась как

индикатор неопределенности. Если интервал расширялся сверх заранее заданного порога, участие в рынке сокращалось до нуля; если интервал оставался умеренным, длинная позиция сохранялась. Такая логика переводит статистическую процедуру прогноза в режим экономического правила. В отличие от обычной торговли по знаку ожидаемой доходности субъект принимает решение об участии только тогда, когда распределение исходов не указывает на чрезмерный риск. Подобный подход согласуется с исследованиями, где практическая ценность моделей определяется их способностью отделять периоды приемлемой и неприемлемой неопределенности [17; 19; 23].

Для Биткойна и Соланы это различие особенно существенно. Первый актив обладает большей глубиной рынка и более устойчивым набором участников, поэтому чрезмерно сложная модель может не давать выигрыша, если базовый нелинейный бустинг уже хорошо отражает его волатильность. Второй актив более чувствителен к сетевым и информационным импульсам, что делает оправданным использование модели, учитывающей взаимосвязанную динамику и изменение режима. Отсюда вытекает проверяемое предположение: сложность модели экономически оправдана только тогда, когда она добавляет ценность в виде более своевременного ограничения риска.

Квантильная постановка играет здесь роль моста между экономической теорией неопределенности и вычислительной частью исследования. В отличие от стандартной MSE-логики она допускает асимметрию стоимости ошибки. Для риск-менеджмента это принципиально: недооценка нижнего хвоста распределения обычно обходится субъекту дороже, чем симметричная ошибка в центре распределения. Поэтому quantile-based подход не только удобен статистически, но и ближе к реальной экономике принятия решений.

LightGBM в этой схеме можно рассматривать как инструмент выявления скрытых нелинейностей между признаками, которые трудно зафиксировать в линейной регрессии. Его полезность особенно велика в тех случаях, когда поведение рынка определяется сочетанием нескольких факторов небольшой силы. DG-Neural ODE, напротив, служит средством фиксации структурной связанности. Если LightGBM отвечает на вопрос о форме зависимости между признаками и целевой переменной, то графовая модель отвечает на вопрос о совместной эволюции нескольких активов в одной системе. В терминах теоретической экономики это различие можно описать как отличие между нелинейной аппроксимацией частной функции и моделированием сетевой координат.

Именно поэтому в статье намеренно не ставится задача найти одну универсальную победившую модель. Сравниваются не столько алгоритмы как таковые, сколько экономические режимы их применения. Если одна модель дает меньшую среднюю ошибку, а другая обеспечивает меньшую просадку при близкой доходности, то с позиции практической рациональности их нельзя упорядочить вне контекста актива и выбранного институционального правила. Такой вывод соответствует литературе по машинному обучению для криптовалют, где часто обнаруживается разрыв между статистическим лидерством и торговой полезностью [6; 12; 23; 25].

## Результаты

Статистическое сопоставление моделей показывает, что квантильный бустинг обеспечивает наименьшие значения pinball loss и наиболее узкий интервал при приемлемом покрытии. Линейная квантильная регрессия уступает по точности, но формирует более консервативный диапазон колебаний. DG-Neural ODE проигрывает по средним метрикам ошибки, однако демонстрирует большую чувствительность к смене режима на высоковолатильном активе. В теоретическом плане этот результат означает, что статистическое лидерство не равно лидерству институциональному: модель, которая минимизирует среднюю ошибку, не обязательно лучше всех обслуживает правило ограничения позиции.

Таблица 1 – Статистические характеристики квантильных прогнозов

| Модель                         | Pinball loss 0,05 | Pinball loss 0,50 | Pinball loss 0,95 | Покрытие 90%-интервала | Средняя ширина |
|--------------------------------|-------------------|-------------------|-------------------|------------------------|----------------|
| Линейная квантильная регрессия | 0,0048            | 0,0133            | 0,0054            | 0,953                  | 0,1847         |
| LightGBM (квантильный бустинг) | 0,0041            | 0,0136            | 0,0050            | 0,9207                 | 0,1492         |
| DG-Neural ODE                  | 0,0060            | 0,0160            | 0,0062            | 0,8284                 | 0,1713         |

Источник: составлено авторами по результатам исследования.

Для Биткоина наилучшее сочетание коэффициента Шарпа и глубины просадки дает стратегия на основе LightGBM. Это соответствует предположению о том, что для зрелого актива большую роль играет не предельная сложность алгоритма, а устойчивое выявление нелинейностей при умеренных вычислительных затратах. Для Соланы наибольший выигрыш по отношению доходности к риску показывает DG-Neural ODE. Здесь сложная модель оказывается полезной именно как инструмент распознавания режима, а не как средство минимизации средней ошибки. Следовательно, экономический эффект больших данных проявляется через способность модели вовремя изменить правило участия в рынке, а не через абстрактное улучшение прогноза в среднем.

Полученные результаты согласуются с более широкой литературой по волатильности криптовалют и машинному обучению. Работы по прогнозированию цен и волатильности показывают, что градиентный бустинг и глубокие модели часто превосходят традиционные спецификации по статистическим метрикам [6; 12; 14; 15; 18; 24]. Одновременно исследования новостного фона и внешних шоков подтверждают, что экономическая ценность информации возникает в моменты, когда рынок быстро переходит из одного режима в другой [9-10; 22]. Наш результат уточняет этот вывод: большие данные создают выигрыш не сами по себе, а тогда, когда они встроены в правило селективного участия в рынке.

С практической точки зрения это означает следующее. Для цифровых активов недостаточно выбрать модель с минимальной ошибкой на историческом наборе. Необходимо сопоставлять качество калибровки интервалов, устойчивость ширины коридора неопределенности и итоговую просадку стратегии. Внутренние процедуры риск-контроля должны опираться не на универсальный алгоритм, а на тип актива и характер его включенности в рыночную сеть. Биткоин допускает более компактное и устойчивое решение, тогда как для Соланы оправдано использование модели, способной улавливать сетевые и режимные эффекты быстрее базовых методов [4; 7; 21].

Таблица 1 показывает, что LightGBM занимает лидирующую позицию по значениям pinball loss на нижнем и верхнем квантилях и одновременно формирует самый компактный 90%-интервал. Это означает, что модель хорошо использует расширенный набор признаков для описания локальной нелинейности рынка. Линейная квантильная регрессия дает более широкий интервал, фактически перестраховываясь относительно хвостовых отклонений. Для внутреннего риск-контроля это не обязательно недостаток: более широкий интервал может уменьшать вероятность пропуска неблагоприятного режима, хотя и делает модель менее экономичной с точки зрения участия в рынке.

DG-Neural ODE проигрывает по средней статистической метрике, но этот результат нельзя трактовать как неэффективность модели вообще. Ее преимущество проявляется в тех отрезках, где изменяется структура связи между активами. На Солане такие участки встречаются чаще, поэтому модель, которая строит распределение на основе динамической сети, получает дополнительную ценность. Иными словами, экономическая функция DG-Neural ODE состоит не в повсеместном

повышении точности, а в более чувствительном реагировании на эпизоды системного сдвига.

Таблица 2 демонстрирует, что стратегия buy-and-hold на Биткоине остается сильной по коэффициенту Шарпа, но сопровождается глубокой просадкой. LightGBM заметно сокращает эту просадку и при этом сохраняет высокий уровень риск-скорректированной доходности. Линейная модель дает еще более мягкий профиль риска, но достигает этого ценой большего отказа от участия в рынке. Для Соланы баланс смещается: пассивное удержание становится слишком рискованным, и именно DG-Neural ODE дает наилучшее соотношение доходности к риску. В теоретическом плане это подтверждает гипотезу о том, что сложность модели оправдана на тех активах, где режимная нестабильность является системным свойством, а не редким отклонением.

Полученный результат можно трактовать как частный закон различения информационной и вычислительной эффективности. Информационная эффективность модели определяется тем, насколько полно она использует доступные сигналы. Вычислительная эффективность отражает стоимость такой обработки. Экономически предпочтительной становится не обязательно самая информированная модель, а та, у которой дополнительная информация преобразуется в выигрыш по риску быстрее, чем растут сложность и нестабильность оценки. Биткоин и Солана демонстрируют разные области действия этого закона.

Таким образом, эмпирические результаты поддерживают теоретическую идею о том, что большие данные на рынке цифровых активов работают через изменение режима принятия решения. Модель нужна не для того, чтобы каждый день угадывать знак доходности, а для того, чтобы выстраивать дисциплинированный контур участия в рынке. Там, где распределение будущих исходов резко расширяется, рациональное поведение заключается в сокращении позиции. Там, где неопределенность остается управляемой, участие оправдано. Именно это и задает экономический смысл квантильного риск-контроля.

### Обсуждение

Представленная схема позволяет по-новому интерпретировать место больших данных в экономической теории финансового риска. В традиционной постановке дополнительная информация рассматривается как средство уточнения ожиданий. На рынке цифровых активов этого уже недостаточно. Здесь информация меняет не только ожидание, но и выбор институциональной стратегии: оставаться в рынке, сокращать позицию, накапливать запас ликвидности или временно отказываться от участия. Следовательно, экономическая ценность больших данных проявляется через изменение набора доступных правил поведения, а не через один только прирост точности. Такая постановка сближает риск-менеджмент цифровых активов с более общими вопросами теории фирмы и финансового посредничества, где информационное преимущество оценивается по качеству принимаемого решения, а не по статистической элегантности модели.

**Таблица 2** – Показатели стратегий риск-контроля

| Стратегия / модель             | Sharpe (BTC) | Sharpe (SOL) | Макс. просадка BTC | Макс. просадка SOL |
|--------------------------------|--------------|--------------|--------------------|--------------------|
| Buy-and-hold                   | 1,02         | 0,83         | -33,1 %            | -66,5 %            |
| Линейная квантильная регрессия | 0,73         | 0,49         | -17,4 %            | 0,0 %              |
| LightGBM                       | 0,95         | 0,64         | -27,3 %            | -18,5 %            |
| DG-Neural ODE                  | 0,90         | 1,04         | -27,4 %            | -26,6 %            |

Источник: составлено авторами по результатам исследования.

Важное значение имеет и различие между зрелыми и незрелыми цифровыми активами. Биткоин в исследовании выступает активом с относительно устойчивой структурой рынка, высокой

ликвидностью и значительной глубиной торгов. Здесь избыточная сложность модели не всегда приводит к дополнительному экономическому результату, потому что базовые нелинейные методы уже отражают ключевые свойства динамики. Солана, напротив, демонстрирует более высокий уровень чувствительности к внешним импульсам и внутренним сетевым переливам. Поэтому на ней проявляется выгода от моделей, которые учитывают связанность и режимные переключения. В более широком плане это означает, что цифровой рынок нельзя описывать одной универсальной моделью рациональности: тип актива задает собственный режим сочетания информации, неопределенности и допустимой сложности аналитического инструмента.

Полученные выводы можно перенести и на уровень внутренних процедур финансовых организаций. Если цифровые активы рассматриваются как элемент портфеля, то большие данные должны быть встроены не только в блок прогнозирования, но и в регламент ограничения риска. Практическая архитектура такого режима может включать три уровня. Первый уровень - статистическая калибровка распределения. Второй - выбор порога участия в рынке. Третий - периодическая проверка того, сохраняется ли экономический выигрыш после учета просадки, частоты выхода из позиции и устойчивости результата на разных окнах данных. Именно такая многоуровневая логика делает применение больших данных содержательным для экономической теории и финансовой практики одновременно.

У исследования имеются и ограничения. Во-первых, использованная стратегия риск-контроля ориентирована на длинную позицию и не учитывает более сложные комбинации хеджирования. Во-вторых, в расчет не включены транзакционные издержки, которые могут уменьшать выигрыш от частого изменения режима участия в рынке. В-третьих, анализ сосредоточен на двух активах, что позволяет увидеть различие между зрелым и более турбулентным рынком, но не исчерпывает всей структуры цифровой экосистемы. Тем не менее именно эта ограниченность помогает яснее показать главный механизм: большие данные дают экономический эффект тогда, когда помогают различать управляемую и неуправляемую неопределенность.

С точки зрения дальнейшего развития теории представляется перспективным переход к портфельной постановке задачи, где правило участия формируется не отдельно для каждого актива, а для набора активов с учетом перекрестных корреляций, общего лимита риска и требований к ликвидности. Не менее важно сопоставить режимы риск-контроля в различных институциональных средах - от частного инвестора до банка или платформы цифровых активов. Такой шаг позволил бы расширить выводы работы от уровня инструмента к уровню модели поведения экономических агентов в цифровой экономике.

### **Заключение**

Проведенное исследование позволяет сформулировать несколько выводов для теории и практики. Во-первых, большие данные на рынке цифровых активов следует трактовать как институционально значимую форму расширения информации, а не как нейтральное накопление наблюдений. Экономический эффект появляется только в том случае, если расширенный набор сигналов используется для изменения правила поведения при росте неопределенности. Во-вторых, квантильный подход оказывается более содержательным для риск-контроля, чем точечный прогноз, поскольку связывает прогнозирование с распределением возможных исходов.

Во-третьих, выявлено различие между зрелыми и более турбулентными цифровыми активами. Для Биткойна достаточный экономический результат дает LightGBM, совмещающий устойчивость и приемлемую вычислительную стоимость. Для Соланы дополнительную ценность создает DG-Neural ODE, лучше отражающая сетевые переливы и режимные переключения. Тем самым подтверждается исходная гипотеза: сложность модели оправдана не всегда, а только при наличии структурной нестабильности, которую нельзя удовлетворительно описать более простыми средствами.

Наконец, для теоретической экономики важен более общий вывод. Рынок цифровых активов показывает, что рациональность в условиях больших данных нельзя сводить к поиску

наиболее точной средней оценки. Рациональным становится такое правило, которое связывает информационную насыщенность модели с институциональным ограничением участия в рынке. Дальнейшие исследования целесообразно направить на включение транзакционных издержек, портфельных ограничений и сравнение различных режимов регулирования в мировой экономике цифровых активов.

## СПИСОК ЛИТЕРАТУРЫ

1. Заров И.К. Основные направления оценки рисков кредитных организаций при осуществлении вложений в цифровые финансовые активы // Экономика и управление: проблемы, решения. 2025. Т. 3. № 7 (160). С. 197-204. DOI: 10.36871/ek.up.p.r.2025.07.03.020.
2. Сидоров А.А., Бурцева Т.А., Дарда Е.С., Параскевопуло О.Р. Математическое моделирование аномальных доходностей криптовалют под воздействием инфоповодов // Московский экономический журнал. 2026. № 2. С. 204-241. DOI: 10.55186/2413046X\_2026\_11\_2\_27.
3. Шувалова Е.Б., Заров И.К. Цифровые финансовые активы на денежные требования: управление рисками и использование для секьюритизации кредитных требований банков // Экономика и управление: проблемы, решения. 2023. Т. 1. № 9 (139). С. 184-194. DOI: 10.36871/ek.up.p.r.2023.09.01.021.
4. Bergsli L.O., Lind A.F., Molnar P., Polasik M. Forecasting volatility of Bitcoin // Research in International Business and Finance. 2022. Vol. 59. Art. 101540. DOI: 10.1016/j.ribaf.2021.101540.
5. Biais B., Capponi A., Cong L.W., Gaur V., Giesecke K. Advances in blockchain and crypto economics // Management Science. 2023. Vol. 69. No. 11. P. 6417-6426. DOI: 10.1287/mnsc.2023.intro.v69.n11.
6. Bouteska A., Abedin M.Z., Hajek P., Yuan K. Cryptocurrency price forecasting - a comparative analysis of ensemble learning and deep learning methods // International Review of Financial Analysis. 2024. Vol. 92. Art. 103055. DOI: 10.1016/j.irfa.2023.103055.
7. Brauneis A., Sahiner M. Crypto volatility forecasting: mounting a HAR, sentiment, and machine learning horserace // Asia-Pacific Financial Markets. 2026. Vol. 33. No. 1. P. 379-411. DOI: 10.1007/s10690-024-09510-6.
8. Budish E. Trust at scale: the economic limits of cryptocurrencies and blockchains // The Quarterly Journal of Economics. 2025. Vol. 140. No. 1. P. 1-62. DOI: 10.1093/qje/qjae033.
9. Chen Z. From disruption to integration: cryptocurrency prices, financial fluctuations, and macroeconomy // Journal of Risk and Financial Management. 2025. Vol. 18. No. 7. Art. 360. DOI: 10.3390/jrfm18070360.
10. Coulter K.A. The impact of news media on Bitcoin prices: modelling data driven discourses in the crypto-economy with natural language processing // Royal Society Open Science. 2022. Vol. 9. No. 4. Art. 220276. DOI: 10.1098/rsos.220276.
11. Gneiting T., Raftery A.E. Strictly proper scoring rules, prediction, and estimation // Journal of the American Statistical Association. 2007. Vol. 102. No. 477. P. 359-378. DOI: 10.1198/016214506000001437.
12. Golnari A., Komeili M.H., Azizi Z. Probabilistic deep learning and transfer learning for robust cryptocurrency price prediction // Expert Systems with Applications. 2024. Vol. 255. Art. 124404. DOI: 10.1016/j.eswa.2024.124404.
13. Hassani H., Huang X., Silva E. Big-Crypto: big data, blockchain and cryptocurrency // Big Data and Cognitive Computing. 2018. Vol. 2. No. 4. Art. 34. DOI: 10.3390/bdcc2040034.
14. Hong S., An S., Jeon J.J. Cryptocurrency price forecasting using variational autoencoder with versatile quantile modeling // Proceedings of the 33rd ACM International Conference on Information and Knowledge Management. 2024. P. 4530-4537. DOI: 10.1145/3627673.3680027.
15. Huang Z.-C., Sangiorgi I., Urquhart A. Forecasting Bitcoin volatility using machine learning techniques // Journal of International Financial Markets, Institutions and Money. 2024. Vol. 97. Art. 102064. DOI: 10.1016/j.intfin.2024.102064.
16. Huynh T.L.D., Shahbaz M., Nasir M.A., Ullah S. Financial modelling, risk management of energy instruments and the role of cryptocurrencies // Annals of Operations Research. 2022. Vol. 313. No. 1. P. 47-75. DOI: 10.1007/s10479-020-03680-y.
17. Janjua L.R., Gigaouri I., Wojcik-Czerniawska A., Pohulak-Zoledowska E. Risk management in the area of Bitcoin market development: example from the USA // Risks. 2024. Vol. 12. No. 4. Art. 67. DOI: 10.3390/risks12040067.
18. Kehinde T.O., Adedokun O.J., Joseph A., Kabirat K.M., Akano H.A., Olanrewaju O.A. Helformer: an

attention-based deep learning model for cryptocurrency price forecasting // *Journal of Big Data*. 2025. Vol. 12. Art. 81. DOI: 10.1186/s40537-025-01135-4.

19. Khan F.U., Khan F., Shaikh P.A. Forecasting returns volatility of cryptocurrency by applying machine learning technique // *Future Business Journal*. 2023. Vol. 9. No. 1. Art. 40. DOI: 10.1186/s43093-023-00200-9.

20. Koenker R., Hallock K.F. Quantile regression // *Journal of Economic Perspectives*. 2001. Vol. 15. No. 4. P. 143-156. DOI: 10.1257/jep.15.4.143.

21. Korkusuz B. Volatility transmission in digital assets: Ethereum's rising influence // *Journal of Risk and Financial Management*. 2025. Vol. 18. No. 3. Art. 111. DOI: 10.3390/jrfm18030111.

22. Kyriazis N., Papadamou S., Tzeremes P., Corbet S. The differential influence of social media sentiment on cryptocurrency returns and volatility during COVID-19 // *The Quarterly Review of Economics and Finance*. 2023. Vol. 89. P. 307-317. DOI: 10.1016/j.qref.2022.09.004.

23. Rahmani Cherati M., Haeri A., Ghannadpour S.F. Cryptocurrency direction forecasting using deep learning algorithms // *Journal of Statistical Computation and Simulation*. 2021. Vol. 91. No. 12. P. 2475-2489. DOI: 10.1080/00949655.2021.1899179.

24. Wang Y., Andreeva G., Martin-Barragan B. Machine learning approaches to forecasting cryptocurrency volatility: considering internal and external determinants // *International Review of Financial Analysis*. 2023. Vol. 90. Art. 102914. DOI: 10.1016/j.irfa.2023.102914.

25. Zhang J., Cai K., Wen J. A survey of deep learning applications in cryptocurrency // *iScience*. 2024. Vol. 27. No. 1. Art. 108509. DOI: 10.1016/j.isci.2023.108509.

# Big data and quantile risk control in digital asset markets

**Shevarev Maxim Vladimirovich**

Student

Moscow Polytechnic University, Moscow, Russian Federation

E-mail: shevarev.max@mail.ru

**Tsarkova Natalya Ivanovna**

Candidate of Pedagogical Sciences, Associate Professor

Moscow Polytechnic University, Moscow, Russian Federation

E-mail: tszrkovani@mail.ru

**Suvorov Stanislav Vadimovich**

Candidate of Economic Sciences, Associate Professor, Professor

Moscow Polytechnic University, Moscow, Russian Federation

E-mail: ssw1168@mail.ru

---

## KEYWORDS

big data; digital assets;  
quantile forecasting; risk  
control; Bitcoin; Solana;  
volatility; capital market

---

## ABSTRACT

The paper develops a theoretical and empirical interpretation of the role of big data in digital asset risk management. The subject of the study is risk-control regimes based on quantile forecasts of Bitcoin and Solana returns as two assets with different volatility structures and different degrees of market maturity. The purpose is to show under which conditions a broader information set creates an economic effect rather than merely increasing computational complexity. The methodological design combines the economics of uncertainty, quantile regression, LightGBM quantile boosting, the continuous-time graph model DG-Neural ODE, and the indicators of pinball loss, interval coverage, Sharpe ratio, and maximum drawdown. Big data are interpreted as an integrated information system that joins long return series, heterogeneous market indicators, news-related signals, and inter-market dependencies. The results demonstrate that statistical forecast quality and economic usefulness are not identical: for Bitcoin, the best balance between return and risk is delivered by LightGBM, whereas for Solana an additional effect is generated by DG-Neural ODE because it captures regime shifts more effectively. The paper concludes that the core issue in the theory of risk control in digital asset markets is not model complexity itself, but the relation between interval width, selective market participation, and institutional rules of position limitation.

---