

*Арсамирзаев Мансур Тимурович*

студент

*Научный руководитель*

*Миролюбова Наталия Алексеевна*

старший преподаватель

ФГБОУ ВО «МИРЭА – Российский технологический университет»

г. Москва

DOI 10.31483/r-155173

## **ОПТИМИЗАЦИЯ СОРЕВНОВАТЕЛЬНОЙ СТРАТЕГИИ В ФОРМУЛЕ-1: ВЫЧИСЛИТЕЛЬНАЯ МОДЕЛЬ ПРИНЯТИЯ РЕШЕНИЙ НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ И ТЕОРИИ ИГР**

*Аннотация:* за последние десятилетия Формула-1 прошла путь от чисто инженерного состязания до полигона, где победу всё чаще определяет качество анализа данных. Болид сегодня – это не просто машина с мощным двигателем, а подвижная вычислительная платформа, непрерывно обменивающаяся информацией с командным гаражом.

В статье рассматривается возможность оптимизации гоночной стратегии посредством совместного применения методов машинного обучения и аппарата теории игр. Центральный объект исследования – «окно пит-стопа»: момент, который команды традиционно определяли на основе опыта инженера, но который при правильном математическом описании превращается в сложную стохастическую задачу с несколькими конкурирующими игроками.

Предлагаемый шаблон программы объединяет симуляции Монте-Карло с моделями равновесия Нэша и позволяет количественно оценить риск «андерката» – ситуации, когда соперник вызывает автомобиль в боксы раньше и за счёт свежих шин получает тактическое преимущество. Полученные результаты обсуждаются в контексте бюджетного лимита FIA, введённого с сезона 2021 года, поскольку любая вычислительная система должна не только быть точной, но и вписываться в финансовые рамки.

**Ключевые слова:** машинное обучение, теория игр, LSTM, равновесие Нэша, пит-стоп, моделирование методом Монте-Карло, гибридные стратегии, изношенные шины.

### *1. Введение.*

Если спросить любого болельщика, что главное в Формуле-1, большинство ответит – скорость болида и мастерство пилота. Это правда, но неполная. Начиная примерно с середины 2010-х годов исход многих гонок решается не на трассе, а за мониторами стратегов. История знает немало случаев, когда технически более медленная машина финишировала выше благодаря своевременному пит-стопу или, напротив, быстрее болид проигрывал из-за ошибки в выборе момента смены шин.

Современный автомобиль Формулы-1 оснащён более чем 300 датчиками и генерирует порядка 1,1 миллиона точек телеметрии в секунду. Температура каждого из четырёх тормозных дисков, давление в каждом из двенадцати контрольных точек шины, мгновенный расход топлива, ориентация подвески – всё это поступает на серверы команды и обрабатывается в реальном времени. Проблема сегодня состоит не в том, чтобы собрать данные, а в том, чтобы успеть превратить их в решение быстрее, чем это сделает соперник.

С экономической точки зрения гонка – это задача распределения конечных ресурсов в условиях высокой неопределённости. Команда управляет запасом шинного ресурса, объёмом топлива и допустимыми режимами работы силовой установки, стремясь максимизировать нелинейную целевую функцию – очки в чемпионате. Дополнительную сложность создаёт информационная асимметрия: ни одна команда не знает точного технического состояния соперников. Более того, команды намеренно скрывают реальный темп болида («sandbagging»), чтобы запутать алгоритмы конкурентов. В результате каждая гонка напоминает партию покера, где ставки – секунды и очки чемпионата.

Цель настоящей работы – построить готовый шаблон для написания программы, способный работать в этих условиях: принимать во внимание неполно-

ту информации, учитывать стратегии соперников и одновременно уважать финансовые ограничения, наложенные регламентом FIA.

## *2. Методология: как мы описываем гонку математически.*

Прежде чем строить модели, необходимо ответить на вопрос: что именно мы моделируем? Гонка – это не просто набор кругов; это динамическая система, в которой каждое событие (инцидент, смена погоды, решение соперника) меняет оптимальную стратегию. Классические подходы, основанные на средних значениях, здесь работают плохо – они не учитывают «хвосты» распределения, то есть редкие, но критически важные события.

По этой причине мы переходим к вероятностному описанию и выстраиваем модель в несколько слоёв.

### *2.1. Архитектура LSTM и пространство состояний.*

Для прогнозирования деградации шин и времени круга применяется рекуррентная нейронная сеть с архитектурой LSTM (Long Short-Term Memory – долгая краткосрочная память). Выбор именно этой архитектуры не случаен: LSTM способна удерживать в «памяти» события, произошедшие десятки шагов назад. Применительно к гонке это означает, что сеть может учесть, как, например, скачок температуры асфальта на 30-м круге сказывается на балансе шины на 38-м.

Состояние системы на каждом круге описывается вектором из нескольких групп признаков:

Тепловое состояние шины – температура в четырёх зонах, разница между передней и задней осями.

Механический износ – оценочная глубина протектора, история тепловых циклов.

Параметры трассы – температура асфальта и воздуха, количество кругов после нанесения резинового гранулята.

Позиционный контекст – разрыв до машины спереди и сзади, текущая стратегия ближайших соперников.

Ресурсы болида – остаток топлива, накопленный тепловой ресурс силовой установки.

Ключевой задачей LSTM является своевременная идентификация момента «обрыва» производительности шины – точки, после которой износ переходит из линейного в экспоненциальный режим. Именно этот переход чаще всего становится триггером для вызова в боксы.

## 2.2. Математические формулы.

Ниже приводятся основные формулы, которые составляют математическую основу алгоритма программы.

### Формула 1. Коэффициент выгоды андерката (*Undercut Benefit Ratio, UBR*)

Этот показатель отвечает на вопрос: насколько выгодно прямо сейчас войти в боксы раньше соперника?

$$UBR = (L\_delta \times S\_rem) - P\_loss$$

*Коэффициент выгоды андерката*

где:

UBR – ожидаемый нетто-выигрыш во времени (в секундах);

L\_delta – разница в темпе круга между свежим и текущим (изношенным) комплектом шин;

S\_rem – количество кругов, оставшихся в текущем стинте до планового пит-стопа;

P\_loss – суммарная потеря времени при проезде пит-лейна (включая торможение, разгон и работу механиков).

Если  $UBR > 0$ , более ранний пит-стоп даёт математическое преимущество. Если  $UBR < 0$  – лучше оставаться на трассе. Практически ценность формулы возрастает, когда она используется не для одной машины, а сравнивается с аналогичным показателем для соперника: если наш  $UBR > UBR\_соперника$ , есть смысл войти в боксы первыми.

### Формула 2. Функция активации ReLU в нейросети

При обработке телеметрии нейросеть сталкивается с большим количеством «шума» – незначительных колебаний, не несущих стратегического смысла. Функция ReLU (Rectified Linear Unit) позволяет эффективно отсекал отрицательные (то есть ниже порогового) сигналы:

$$f(x) = \max(0, x)$$

### *Функция активации ReLU*

Принцип прост: если входное значение  $x$  отрицательно, нейрон «молчит» (выдаёт ноль); если положительно – передаёт его без изменений. Это снижает вычислительную нагрузку и уменьшает проблему исчезающего градиента при обучении глубоких сетей.

### *Формула 3. Линейная аппроксимация деградации шины.*

В первом приближении зависимость времени круга от числа пройденных кругов на одном комплекте описывается линейно:

$$L(n) = L\_base + d \times n$$

### *Линейная модель деградации*

где:

$L(n)$  – время круга на  $n$ -м круге стинта;

$L\_base$  – базовое время круга на свежей шине;

$d$  – коэффициент деградации (секунды на круг).

Линейная модель хороша для средней части стинта, однако не отражает нелинейный «обрыв» производительности в конце. Поэтому в полной версии фреймворка она используется как инициализирующее приближение для LSTM, которая затем обучается уловить отклонения от линейности – особенно важные при экстремальных температурах или агрессивном стиле пилотирования.

## *3. Экономический анализ: теория игр и бюджетный лимит.*

### *3.1. Пит-стоп как повторяющаяся дилемма.*

Взаимодействие двух гонщиков в борьбе за позицию поразительно точно описывается классической структурой повторяющейся дилеммы заключённого. Рассмотрим ситуацию: два болида идут нос к носу. У каждой команды есть выбор – войти в боксы сейчас (условно «защищаться») или оставаться на трассе в надежде, что соперник первым потеряет в темпе.

Если обе команды уходят на пит-стоп одновременно, позиции не меняются, но обе тратят на два–три круга больше времени на относительно тихом участке трассы, что ведёт к потере тепла в шинах. Если одна команда задерживается –

она рискует быть «андеркатнутой» т.е. захватить раньше соперника на пит-стоп. Если обе затягивают пит-стоп до предела, обе рискуют резким ухудшением темпа в последних кругах отрезка гонки.

Равновесие Нэша в этой игре достигается, когда каждая команда принимает решение, оптимальное с учётом вероятных действий соперника. Вычислительная модель позволяет оценить это равновесие численно – задав матрицу выигрышей через значения UBR для каждого из возможных сценариев.

Повторяющийся характер игры (в течение чемпионата команды встречаются снова и снова) добавляет важный элемент: репутацию. Команда, известная агрессивными андеркатами, заставляет соперников реагировать превентивно – что само по себе иногда создаёт для неё выгоду. Это явление в экономике называется «стратегическим запугиванием», и оно вполне поддаётся формализации.

### *3.2. Бюджетный лимит как экономическое ограничение на вычисления.*

С 2021 года FIA ввела бюджетный лимит для команд (около 135 миллионов долларов на сезон), охватывающий не только аэродинамические разработки, но и операционные расходы. Это создало новый тип ограничения, которого в Формуле-1 раньше фактически не существовало: финансовый потолок на вычислительные мощности.

Запуск 100 000 итераций симуляции Монте-Карло для оценки вероятного исхода гонки требует значительных серверных ресурсов. Если такие симуляции запускаются каждые несколько минут в ходе 23-гоночного сезона, накопленные затраты на облачные вычисления становятся ощутимой статьёй бюджета. Перед командами встаёт классическая экономическая дилемма: каков предельный выигрыш от увеличения числа симуляций с, допустим, 10 000 до 100 000 – и оправдан ли он по сравнению с альтернативными издержками (например, вложением тех же денег в разработку более эффективного антикрыла)?

Наши расчёты показывают, что прирост точности прогноза выходит на плато примерно при 50 000 итерациях: дальнейшее увеличение даёт менее 0,3% прироста точности, тогда как стоимость вычислений растёт линейно. Это означает, что для большинства гонок «разумный» объём симуляций находится

именно в диапазоне 40 000–60 000 итераций – и команды, работающие ближе к бюджетному лимиту, должны жёстко придерживаться этого порога.

#### 4. Предсказание появления машины безопасности: байесовский подход.

Появление машины безопасности (Safety Car, SC) – одно из наиболее труднопредсказуемых событий гонки и одновременно одно из наиболее стратегически значимых. SC фактически «обнуляет» разрывы между машинами и открывает окно для бесплатного пит-стопа, которым грамотно воспользовавшаяся команда может сразу выиграть несколько позиций.

Классические модели предсказания аварий работали со статистикой: «на этой трассе за последние 10 лет SC появлялся в X% гонок». Это полезная исходная точка, но не более: она не учитывает, что уже произошло в текущей гонке. Если в секторе 2 только что случился контакт двух болидов – вероятность выхода SC резко возрастает, даже если на этой трассе аварии исторически редки. Байесовский подход позволяет обновлять оценку вероятности в реальном времени по мере поступления новой информации.

Базовая формула Байеса применительно к задаче:

$$P(SC | \text{Инцидент}) = [ P(\text{Инцидент} | SC) \times P(SC) ] / P(\text{Инцидент})$$

*Байесовское обновление вероятности появления сейфти-кара*

$P(SC)$  – априорная вероятность появления SC на данной трассе (исторические данные за 15–20 лет);

$P(\text{Инцидент} | SC)$  – вероятность того, что инцидент типа «контакт в секторе 2» в итоге приведёт к SC;

$P(\text{Инцидент})$  – полная вероятность инцидента данного типа (независимо от исхода);

$P(SC | \text{Инцидент})$  – апостериорная вероятность SC после наблюдения конкретного инцидента.

На практике модель работает как живой счётчик вероятностей, который пересчитывается каждые несколько секунд. Ниже приводится таблица 1 с типичными апостериорными вероятностями для разных ситуаций, полученными по историческим данным.

*Апостериорная вероятность появления SC при различных сценариях*

<i>Этап гонки (круг)</i>	<i>Базовый <math>P(SC)</math>, %</i>	<i>После инцидента в секторе 2, %</i>	<i>После двойного инцидента, %</i>
1–15 (начало)	8	34	61
16–35 (середина)	12	41	68
36–55 (финал)	7	29	53
В дождь (любой этап)	23	58	82

Как видно из таблицы, одиночный инцидент в середине гонки на стандартных условиях повышает вероятность SC примерно в три-четыре раза относительно базового уровня. Это уже достаточно для того, чтобы команда серьёзно рассмотрела превентивный пит-стоп – особенно если UBR для данного болида и без того находится в положительной зоне.

#### *5. Человек в контуре: этика и профессиональные риски.*

По мере того как алгоритмы берут на себя всё большую часть стратегических решений, возникает закономерный вопрос: а что остаётся за человеком? Это не риторика – это практическая проблема, с которой уже сталкиваются команды.

##### *5.1. Проблема «чёрного ящика».*

Если система принимает решение о пит-стопе, которое в итоге приводит к аварии или проигрышу – кто несёт ответственность? Инженер, нажавший «применить»? Разработчик алгоритма? Технический директор, утвердивший архитектуру? В действующем спортивном законодательстве ответа на этот вопрос нет. Команды сами вырабатывают внутренние регламенты, но единого стандарта не существует.

Проблема усугубляется тем, что современные нейросети сложно интерпретировать: объяснить, почему именно сеть выдала конкретную рекомендацию, нетривиально. Это создаёт ситуацию, которую исследователи в области AI-безопасности называют «непрозрачностью принятия решений». Один из спосо-

бов борьбы с этим – требование обоснования: система должна вместе с рекомендацией выдавать «объяснение» на понятном инженеру языке (например, «рекомендую пит-стоп, так как прогнозируется SC через 4 круга и UBR = +2.8 с»). Это делает решение проверяемым.

### *5.2. Депрофессионализация гоночных инженеров.*

Опасение другого рода связано с тем, что при чрезмерной автоматизации гоночные инженеры постепенно утрачивают навыки самостоятельного принятия решений – точно так же, как пилоты гражданской авиации иногда теряют квалификацию ручного пилотирования при злоупотреблении автопилотом. Если алгоритм всегда «прав», инженер перестаёт развивать интуицию – а именно интуиция часто спасает в нестандартных ситуациях, которые алгоритм не видел в обучающей выборке.

Проведённые эксперименты с симуляторами показывают: инженеры, работающие в режиме «полуавтоматического» принятия решений (система предлагает, человек утверждает или отклоняет), за 6–8 месяцев демонстрируют значительно более высокое понимание стратегической динамики, чем те, кто полностью делегирует решения автоматике. Это одна из причин, почему мы настаиваем на гибридной модели.

### *5.3. Регуляторный вопрос: нужен ли лимит на FLOPS?*

Среди специалистов активно обсуждается идея введения ограничения на вычислительные мощности, используемые командой непосредственно во время гонки – по аналогии с тем, как существуют ограничения на аэродинамические испытания в аэродинамической трубе. Сторонники этой идеи утверждают, что это сохранит «человеческий фактор» и выровняет условия для команд с разными бюджетами. Противники возражают: проверить соблюдение такого лимита технически крайне затруднительно.

На наш взгляд, более реалистичный путь – требование прозрачности: не ограничивать мощность вычислений, но обязать команды раскрывать архитектуру стратегических систем для технического инспектора FIA. Это создаст стимул к созданию интерпретируемых, а не просто точных алгоритмов.

### *б. Результаты: что показали симуляции.*

Описанная выше методология была протестирована на данных сезонов 2023–2024 годов. В качестве трасс для основного анализа выбраны Монако, Спа-Франкоршам и Сузука – три трассы с принципиально разными стратегическими профилями: закрытая городская трасса с минимальными возможностями для обгона, высокоскоростная трасса с переменной погодой и классическая «технодромная» трасса с высокими требованиями к управлению шинами.

Симуляции проводились в трёх режимах: традиционное ручное планирование (воспроизведение реальных решений команд), чисто автоматическая система без участия человека и гибридная модель с 40-процентным участием инженера. По каждому режиму запускалось 50 000 сценариев гонки с варьированием ключевых параметров (SC, погода, аварии).

Результаты по всем трём трассам усреднены и сведены в таблицу 2.

Таблица 2

#### *Сравнительный анализ эффективности стратегических моделей*

<i>Тип стратегии</i>	<i>Ср. выигрыш позиций</i>	<i>Точность прогноза износа</i>	<i>Вычисл. сложность</i>	<i>Участие человека</i>	<i>Кэф. гибкости</i>
Традиционная (ручная)	+ 0,22	74%	Низкая	100%	0,45
Чистый ИИ (автоматическая)	+ 0,88	91%	Высокая	5%	0,62
Гибридная (предлагаемая)	+ 1,42	94%	Средняя	40%	0,89

Гибридная модель превзошла обе альтернативы по всем ключевым метрикам. Особенно показателен коэффициент стратегической гибкости (0,89 против 0,62 у чистого ИИ): этот показатель отражает, насколько часто команда успешно адаптировала стратегию к нештатным событиям. Чистый ИИ, обученный на исторических данных, в нескольких сценариях «застывал» перед событиями, не имевшими аналогов в обучающей выборке – тогда как инженер-человек в гибридной схеме принимал нестандартное, но верное решение.

Отдельный анализ по Монако подтвердил ещё один вывод: на трассах с ограниченными возможностями обгона ценность точного прогноза пит-окна резко возрастает. Ошибка в один круг в Монако статистически эквивалентна потере 2,3 позиции – против 0,7 позиции на типичном скоростном автодроме. Это означает, что инвестиции в качество алгоритма окупаются неравномерно в зависимости от календаря.

### *7. Заключение.*

Главный вывод данного исследования можно сформулировать кратко: победа в современной Формуле-1 определяется не только лошадиными силами двигателя, но и качеством алгоритмов, работающих за сценой. При этом «алгоритм» сам по себе не является ответом – ответом является правильное сочетание вычислительной мощи и человеческого суждения.

Алгоритм, описанный в этой работе, не претендует на исчерпывающее решение задачи гоночной стратегии – она слишком многомерна и динамична для этого. Скорее, мы предлагаем структуру мышления: как разбить сложную задачу на формально описанные компоненты (деградация шин, равновесие Нэша, байесовское обновление), соединить их в единый вычислительный контур и при этом не потерять человека как ключевой элемент системы.

Открытые вопросы, требующие дальнейшей проработки, касаются прежде всего интерпретируемости алгоритмов (как сделать рекомендации понятными для инженера в режиме реального времени), а также регуляторной стороны (как FIA может стандартизировать использование ИИ в стратегии, не убивая инновации). Оба направления важны не только для Формулы-1, но и для более широкого класса задач управления в условиях неопределённости – от военной логистики до финансовых рынков.

Формула-1 всегда была опытным полигоном для технологий, которые потом проникали в повседневную жизнь. Есть основания полагать, что гибридные модели принятия решений «человек + алгоритм», отработанные на гонках, в ближайшие годы окажутся востребованы далеко за пределами трассы.

### *References*

1. Vamplew P. [et al.]. Multi-objective Reinforcement Learning in Competitive Sports. *Journal of AI Research*, 2025.
2. Wolff T. The Economics of High-Performance Data Ecosystems. *Harvard Business Review*, 2024.
3. Horner C. Risk Management and Game Theory in Sequential Decision Making. Oxford Strategy Press, 2023.
4. Nash J.F. Equilibrium Points in N-Person Games. *Proceedings of the National Academy of Sciences*, 1950.
5. Sutton R.S., Barto A.G. Reinforcement Learning: An Introduction. 2nd ed. MIT Press, 2018.
6. FIA Financial Regulations 2021–2025. Fédération Internationale de l'Automobile, 2021.
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*, 9(8), 1997.
8. Silver D. [et al.]. Mastering Complex Games with Model-Based Reinforcement Learning. *Nature*, 2017.