



Da Análise de Dados à Performance em Pista: Otimizando a Estratégia de Charles Leclerc para um Resultado de Top 5 no GP da China de 2025 via Simulação

Lucas Ribeiro Alves Costa

Universidade Federal de Itajubá - UNIFEI

lucas.ribeirocosta@hotmail.com

Flavio Ricotta

Universidade Federal de Itajubá - UNIFEI

flavio.ricotta@gmail.com

Matheus Brendon Francisco

Universidade Federal de Itajubá - UNIFEI

matheus_brendon@yahoo.com.br

RESUMO

Estratégias de pit stop são decisivas na Fórmula 1, um esporte de alta tecnologia onde erros estratégicos ainda impactam resultados. Este estudo otimiza, via simulação baseada em dados, a estratégia de uma parada (Medium-Hard) de Charles Leclerc no GP da China de 2025, onde seu quinto lugar original foi perdido por desclassificação. Modelando a degradação linear dos pneus, comparamos a projeção para a estratégia M15->H41 (utilizada pelo piloto) com alternativas. O modelo identificou uma estratégia otimizada (M10->H46) como **3.904 segundos mais rápida**. Aplicando este ganho ao desempenho real de Leclerc, projeta-se que ele asseguraria a **quinta posição final**, somando pontos. O trabalho demonstra como modelos de simulação acessíveis podem fornecer insights estratégicos valiosos para maximizar a performance, mesmo em contextos tecnologicamente avançados onde a tomada de decisão permanece um desafio.

PALAVRAS CHAVE. Otimização de Estratégia (F1), Simulação de Corrida, Análise de Dados Esportivos.

Tópicos



Otimização Estratégica; Simulação Baseada em Dados ; Decisão em Alta Tecnologia.

ABSTRACT

Pit stop strategies are decisive in Formula 1, a high-technology sport where strategic errors still impact results. This study optimizes, via data-driven simulation, Charles Leclerc's one-stop (Medium-Hard) strategy at the 2025 Chinese GP, where his original fifth place was lost to disqualification. By modeling linear tire degradation, we compared the projection for the M15->H41 strategy (used by the driver) with alternatives. The model identified an optimized M10->H46 strategy as **3.904 seconds faster**. Applying this gain to Leclerc's actual race performance, it is projected that he would have secured fifth position, scoring points. This work demonstrates how accessible simulation models can provide valuable strategic insights to maximize performance, even in technologically advanced contexts where decision-making remains a challenge.

KEYWORDS. Strategy Optimization (F1), Race Simulation, Sports Data Analytics.

Paper topics

Strategic Optimization; Data-Driven Simulation ; Decision-Making in High-Tech Environments.

1. Introdução

A Fórmula 1 (F1) representa o pináculo do automobilismo, um ambiente de extrema competição onde a vanguarda tecnológica e a complexidade estratégica se encontram. As equipes investem massivamente em telemetria avançada e sofisticados softwares de simulação para otimizar cada aspecto da performance (Jenkins & Bearman, 2014). Paradoxalmente, mesmo neste cenário de alta tecnologia, erros de julgamento estratégico, especialmente no gerenciamento de pneus e no timing dos pit stops, continuam a ser fatores decisivos e, por vezes, fontes de resultados subótimos (O’Riordan & Tremeayne, 2019). Este estudo explora se modelos de simulação baseados em dados, mesmo com um grau de simplicidade acessível, podem oferecer insights valiosos para identificar e evitar tais erros, focando na otimização da estratégia de pneus.

O presente trabalho utiliza como estudo de caso o desempenho de Charles Leclerc, piloto da Ferrari, no Grande Prêmio da China de 2025. Nesta corrida específica, Leclerc alcançou inicialmente a quinta posição, um resultado que foi posteriormente perdido devido a uma desclassificação técnica, problema que a equipe associou, em parte, ao gerenciamento dos pneus sob uma estratégia de uma única parada. Este contexto oferece uma oportunidade relevante para investigar se uma estratégia alternativa de pit stop, identificada através de modelagem, poderia ter não apenas otimizado o tempo total de corrida, mas, crucialmente, assegurado um resultado que garantisse a soma de pontos no campeonato.

Utilizando dados públicos de tempos de volta da corrida (via biblioteca **FastF1**), este estudo detalha o desenvolvimento de um modelo de simulação para estimar a degradação dos pneus Medium e Hard, simular a estratégia de uma parada (M15 -> H41) adotada por Leclerc para estabelecer uma projeção de referência, e explorar alternativas para identificar uma janela de parada ótima. O objetivo central é quantificar o ganho de tempo potencial de uma estratégia otimizada e projetar seu impacto na classificação final da corrida, demonstrando assim o valor prático da análise de dados e da simulação na busca por performance na Fórmula 1, mesmo quando confrontada com a complexidade e os vastos recursos tecnológicos do esporte. A estrutura do artigo segue com a fundamentação teórica, metodologia, apresentação dos resultados e conclusões.

2. Fundamentação Teórica

2.1. A Natureza Estratégica da Fórmula 1

A Fórmula 1 transcende a simples competição de velocidade, estabelecendo-se como um complexo desafio estratégico onde decisões tomadas em frações de segundo, sob imensa pressão, podem determinar o sucesso ou o fracasso (Riedl et al., 2021). A estratégia de corrida, englobando desde a configuração aerodinâmica do carro até a gestão em tempo real das paradas nos boxes, é um campo de estudo multidisciplinar que atrai o interesse de engenheiros, cientistas de dados e pesquisadores em otimização (Pitrik & Kacsuk, 2020). As equipes de F1 investem pesadamente em departamentos de estratégia, que utilizam modelos preditivos sofisticados e análise de dados em tempo real para informar suas escolhas, visando explorar as vulnerabilidades dos adversários e maximizar as próprias chances (O’Riordan & Tremeayne, 2019).

O regulamento técnico e desportivo da FIA (Fédération Internationale de l'Automobile) impõe restrições e oportunidades que moldam o cenário estratégico. Por exemplo, a obrigatoriedade do uso de múltiplos compostos de pneus em corridas secas e as limitações no número de unidades de potência por temporada são fatores que as equipes devem gerenciar cuidadosamente ao longo de um campeonato (FIA Formula 1 Sporting Regulations, edições anuais).

2.2. Dinâmica e Degradação de Pneus na Fórmula 1 Contemporânea

Na Fórmula 1 moderna, os pneus são, indiscutivelmente, o elemento mais crítico na definição da estratégia de corrida, especialmente desde a proibição do reabastecimento em 2010 (Collantine, 2020). A Pirelli, como única fornecedora desde 2011, desenvolve pneus com o objetivo explícito de promover múltiplas paradas nos boxes, introduzindo uma degradação controlada que obriga as equipes a planejar cuidadosamente a vida útil de cada composto (Pirelli & C. S.p.A., Comunicações Técnicas).

A performance de um pneu de F1 é uma função complexa de sua temperatura, pressão, e do desgaste acumulado. A degradação manifesta-se como uma perda gradual de aderência, resultando em tempos de volta mais lentos. Essa degradação pode ser classificada em:

- **Degradação por Desgaste (Wear):** A perda física de borracha devido à abrasão com a superfície da pista. É mais pronunciada em circuitos abrasivos e com pneus de composto mais macio.
- **Degradação Térmica:** Ocorre quando o pneu opera fora de sua janela ideal de temperatura. O superaquecimento pode levar a fenômenos como *blistering* (formação de bolhas na superfície) ou *graining* (desprendimento de pequenos pedaços de borracha), ambos prejudicando a aderência e a consistência (De Celis & Allou, 2022).

Modelar a degradação dos pneus é um desafio central. Embora modelos lineares simples, que assumem um incremento constante no tempo de volta por volta de uso, sejam frequentemente o ponto de partida para análises rápidas (como a adotada neste estudo), pesquisas mais avançadas buscam modelos não lineares que possam capturar com maior fidelidade as diferentes fases da vida de um pneu (Kelly & Frsberg, 2023). Fatores como a carga de combustível (que diminui ao longo da corrida, aliviando os pneus e melhorando os tempos de volta) e a evolução das

condições da pista (emborrachamento) interagem com a degradação intrínseca do pneu, complicando ainda mais a predição precisa (Fernández & López-Lázaro, 2021).

2.3. Modelagem, Simulação e Otimização em Estratégias de Corrida

Diante da multiplicidade de variáveis e da natureza dinâmica das corridas, as equipes de Fórmula 1 dependem cada vez mais de ferramentas de modelagem e simulação para desenvolver e avaliar estratégias de pit stop. Essas ferramentas permitem explorar um vasto espaço de possibilidades e quantificar os riscos e benefícios de diferentes escolhas antes e durante um evento (Ding & Liu, 2023).

Os componentes típicos de um sistema de simulação de estratégia de corrida incluem:

- **Modelo de Performance do Carro/Piloto:** Estima o tempo de volta base que um piloto pode alcançar com um determinado carro e composto de pneu, frequentemente ajustado pela carga de combustível.
- **Modelo de Degradação de Pneus:** Prediz o aumento no tempo de volta à medida que os pneus se desgastam (conforme discutido anteriormente).
- **Modelo de Pit Stop:** Quantifica o tempo total perdido durante uma parada nos boxes, incluindo o trânsito pelo pit lane e o tempo de serviço.
- **Algoritmo de Otimização:** Utiliza os modelos acima para buscar a sequência de paradas e escolhas de pneus que minimiza o tempo total de corrida ou maximiza outra métrica de desempenho (por exemplo, posição final, considerando as ações dos adversários). Técnicas de programação dinâmica, heurísticas e, mais recentemente, aprendizado por reforço têm sido exploradas (Bertsimas et al., 2019; Fijos & Kacsuk, 2022).

A análise do "undercut" e do "overcut" é um exemplo clássico da aplicação desses modelos. O undercut, onde um piloto para antes de um rival direto para tentar ganhar posição com o benefício de pneus novos, e o overcut, onde se estende o stint esperando que a performance do rival caia ou que surja uma oportunidade (como um Safety Car), são táticas cujas eficácias dependem de uma avaliação precisa do ritmo relativo e da degradação (Hughes & Rendell, 2021).

Este estudo, embora utilize uma abordagem de otimização mais direta (simulação de diferentes janelas de parada para uma estratégia de uma única troca), baseia-se nos mesmos princípios de modelar a performance dos pneus e o custo das paradas para identificar uma estratégia potencialmente superior. A validação do modelo comparando os tempos simulados com os reais, mesmo que revele discrepâncias, é um passo importante para entender suas limitações e áreas de aprimoramento (Pascoal et al., 2023).

3. Metodologia

Esta seção detalha os procedimentos adotados para a coleta e análise dos dados, a modelagem da degradação dos pneus, o desenvolvimento do simulador de corrida e, finalmente, a otimização da estratégia de pit stop para Charles Leclerc no Grande Prêmio da China de 2025. A abordagem metodológica foi implementada utilizando a linguagem de programação Python e bibliotecas associadas para análise de dados e visualização..

3.1. Desenvolvimento do Modelo Preditivo de Desgaste da Ferramenta

Os dados primários para este estudo foram obtidos utilizando a biblioteca Python FastF1 (versão utilizada conforme logs de execução, por exemplo, v3.5.3), uma ferramenta de código aberto que permite o acesso programático a dados de telemetria e de cronometragem da Fórmula 1. O evento selecionado para análise foi a corrida (Sessão 'R') do Grande Prêmio da China de 2025 (identificado no sistema como 'Chinese Grand Prix', ano 2025). Foi configurado um diretório de cache local (fastf1_cache) para otimizar o acesso subsequente aos dados e minimizar requisições repetidas à API da F1.

Após o carregamento bem-sucedido dos dados da sessão, foram extraídas as informações completas de todas as voltas (session.laps) de todos os pilotos participantes. O foco da análise foi direcionado ao piloto Charles Leclerc, da equipe Ferrari, identificado no sistema pela sua abreviação oficial 'LEC' ou pelo número de carro '16'. As voltas correspondentes a Leclerc foram isoladas utilizando a funcionalidade pick_drivers() da biblioteca FastF1.

Um DataFrame específico, denominado dados_relevantes_leclerc, foi então construído, contendo as colunas consideradas essenciais para a análise estratégica e de degradação. Estas incluíram, mas não se limitaram a: LapNumber (Número da Volta), Stint (Número do Stint), Compound (Composto do Pneu utilizado), TyreLife (Idade do Pneu em número de voltas no início de cada volta), LapTime (Tempo da Volta no formato timedelta), PitInTime (Timestamp da entrada no pit lane, se ocorrido) e PitOutTime (Timestamp da saída do pit lane, se ocorrido). A coluna LapTime foi subsequentemente convertida para um formato numérico em segundos (LapTimeSeconds) para facilitar os cálculos de performance. A análise inicial destes dados confirmou que Charles Leclerc utilizou uma estratégia de uma única parada durante a corrida, iniciando com pneus do composto Medium e, posteriormente, trocando para o composto Hard.

3.2. Modelagem da Degradação dos Pneus

A modelagem da degradação dos pneus foi um passo fundamental para a simulação de diferentes estratégias. O processo foi conduzido para os dois compostos de pneus utilizados por Leclerc (Medium e Hard):

- Isolamento dos Dados por Stint: Os dados de LapTimeSeconds e TyreLife foram agrupados para cada um dos dois stints de Leclerc.
- Exclusão de Voltas Atípicas: Para obter uma estimativa mais pura da degradação do pneu em condições normais de corrida, a volta de entrada no pit (última volta do primeiro stint) e a volta de saída do pit (primeira volta do segundo stint) foram excluídas da

análise de regressão. Estas voltas possuem tempos de volta influenciados pelo trânsito no pit lane e pela aceleração/desaceleração, não refletindo a performance consistente do pneu.

- **Regressão Linear:** Uma análise de regressão linear simples foi aplicada aos dados de LapTimeSeconds (variável dependente) em função de TyreLife (variável independente) para cada stint "limpo". A função linregress da biblioteca scipy.stats do Python foi utilizada para este cálculo. O intercepto da regressão forneceu uma estimativa do tempo de volta base teórico (para TyreLife = 0), e a inclinação (slope) representou a taxa de degradação inicial (em segundos por volta de uso do pneu).
- **Ajuste dos Parâmetros de Degradação para Simulação:** Observou-se que a regressão linear simples resultou em taxas de degradação negativas, um fenômeno atribuído à influência de fatores como a progressiva redução da carga de combustível do carro e a evolução das condições da pista, que podem mascarar ou superar a degradação intrínseca do pneu em modelos lineares simples, especialmente com os baixos coeficientes de determinação (R^2) obtidos. Para assegurar que a simulação refletisse o comportamento esperado de perda de performance dos pneus com o uso, as taxas de degradação foram ajustadas para valores positivos e plausíveis, baseados em conhecimento geral do comportamento dos pneus na F1 e nas estimativas iniciais, mantendo-se os tempos de volta base (para TyreLife = 1) derivados da regressão. Os valores finais utilizados na simulação foram:
 - Pneu MEDIUM: Tempo Base (1ª volta útil) = 99.011s, Taxa de Degradação = +0.070 s/volta.
 - Pneu HARD: Tempo Base (1ª volta útil) = 97.350s, Taxa de Degradação = +0.040 s/volta.

3.3. Desenvolvimento do Simulador de Corrida

Foi desenvolvida uma função em Python, denominada `simular_tempo_corrida`, para calcular o tempo total de corrida projetado para uma determinada estratégia de pit stop. Esta função considerou os seguintes inputs:

- `estrategia_pitstops`: Uma lista de tuplas, onde cada tupla especifica um stint na forma (composto_do_pneu, numero_de_voltas_no_stint).
- `total_voltas_corrida`: O número total de voltas da corrida em questão (56 voltas para o GP da China de 2025).
- `parametros_pneus`: Um dicionário contendo os parâmetros de simulação para cada composto de pneu, especificamente o tempo_base_primeira_volta e a taxa_degradação_por_volta (ajustada).
- `tempo_de_parada_s`: Um valor fixo representando o tempo total perdido em cada parada nos boxes. Este valor foi calculado em **22.282 segundos** com base na diferença entre os timestamps PitOutTime e PitInTime da parada real de Leclerc.

Internamente, a função `simular_tempo_corrida` utiliza uma função auxiliar, `calcular_tempo_stint`, para determinar o tempo total gasto em cada stint. O tempo de uma volta v (onde v varia de 1 até o número de voltas no stint) dentro de um stint é calculado pela fórmula: $\text{TempoVolta}(v) = \text{TempoBaseComposto} + (v-1) * \text{TaxaDegradaçãoComposto}$. O tempo total de corrida simulado é, então, a soma dos tempos de todos os stints mais o produto do número de paradas (número de stints menos um) pelo `tempo_de_parada_s`.

3.4. Otimização da Estratégia

O processo de otimização teve como foco identificar a janela de pit stop ideal para uma estratégia de uma única troca de pneus (Medium para Hard) que minimizasse o tempo total de corrida simulado. Esta otimização foi realizada através de uma busca exaustiva:

1. Definiu-se uma faixa de voltas plausíveis para a realização da primeira (e única) parada, variando a duração do stint inicial com pneus Medium (de 10 a 28 voltas).
2. Para cada volta de parada potencial dentro desta faixa, a estratégia correspondente (ex: $M[x] \rightarrow H[56-x]$) foi construída.
3. A função `simular_tempo_corrida` foi utilizada para calcular o tempo total de corrida projetado para cada uma dessas estratégias alternativas.
4. Os tempos totais de corrida simulados para todas as estratégias candidatas foram coletados e comparados. A estratégia que resultou no menor tempo total foi identificada como a "ótima" dentro das premissas do modelo.

A estratégia efetivamente utilizada por Leclerc (M15 $\rightarrow$ H41) foi também simulada utilizando a mesma função, servindo como a estratégia de referência para quantificar o ganho potencial da otimização. A análise subsequente envolveu a comparação do tempo da estratégia otimizada com os tempos reais dos demais competidores para projetar o impacto na classificação final da corrida.


4. Resultados

Esta seção apresenta os principais resultados obtidos a partir da aplicação da metodologia descrita, incluindo a análise da estratégia de referência de Charles Leclerc, a estimação dos parâmetros de degradação dos pneus utilizados na simulação, os resultados da otimização que levaram à identificação de uma estratégia com ganho de tempo, e a projeção do impacto dessa otimização na classificação final da corrida.

4.1. Estratégia de Referência e Parâmetros de Simulação Utilizados

A estratégia de uma parada utilizada por Leclerc no GP da China de 2025 (M15 -> H41: 15 voltas em pneus Medium, seguidas por 41 voltas em pneus Hard, com uma parada de 22.282s) foi estabelecida como referência. O modelo de simulação, após análise inicial da degradação dos pneus (ilustrada na **Figura 1**), utilizou os seguintes parâmetros ajustados:

Figura 1 - Análise de Degradação dos Pneus




- **Pneu MEDIUM:** Tempo Base (1ª volta útil) = 99.011s; Taxa de Degradação = +0.070 s/volta.
- **Pneu HARD:** Tempo Base (1ª volta útil) = 97.350s; Taxa de Degradação = +0.040 s/volta.

Com estes parâmetros, o tempo total de corrida **projetado pelo modelo para a estratégia de referência M15 -> H41** foi de **5538.964 segundos**.

4.2. Otimização da Estratégia e Ganho Identificado

A exploração de janelas alternativas para a única parada (Medium -> Hard), variando a duração do primeiro stint, revelou que uma parada mais cedo seria benéfica segundo o modelo. A **Figura 2** ilustra como o tempo total de corrida simulado varia com a volta da parada.

Figura 2 - Tempo de Corrida Simulado vs. Volta da Parada




A estratégia ótima identificada pelo modelo foi **M(10) -> H(46)** (10 voltas de Medium, 46 de Hard), resultando em um tempo total simulado de **5535.060 segundos**. Isso representa um ganho de **3.904 segundos** em comparação com o tempo projetado pelo modelo para a estratégia de referência M15 -> H41.

4.3. Dinâmica Comparativa da Estratégia Otimizada

A análise da diferença acumulada de tempo entre a estratégia otimizada pelo modelo (M10/H46) e a projeção para a estratégia de referência M15/H41 (ilustrada na **Figura 3**) demonstrou que o ganho de tempo foi construído principalmente no intervalo entre as voltas 11 e 15. Durante este período, a estratégia otimizada já utilizava pneus Hard novos, enquanto a estratégia de referência ainda estava em pneus Medium mais desgastados, permitindo à M10->H46 não só compensar o tempo da sua parada mais cedo, mas também construir uma vantagem decisiva.

Figura 3 - Diferença Acumulada de Tempo:



4.4. Projeção do Impacto na Classificação Final da Corrida

Considerando o tempo de corrida original de Charles Leclerc no GP da China de 2025 (5478.237 segundos, que lhe rendeu o 5º lugar antes da desclassificação), e aplicando o ganho de **3.904 segundos** identificado pela otimização, seu tempo de corrida hipotético com a estratégia otimizada M10 -> H46 seria de **5474.333 segundos**. Ao comparar este tempo hipotético com os tempos reais dos demais competidores, projeta-se que Charles Leclerc teria terminado a corrida na **5ª posição**, mantendo sua colocação original e somando pontos importantes para o campeonato.



5. Agradecimentos

Os autores gostariam de expressar sua gratidão à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Universidade Federal de Itajubá (UNIFEI) pelo apoio fundamental à realização deste trabalho.

6. Referências

- Bertsimas, D., Farias, V. F., & Trichakis, N. (2019). The approximability of sequential decision problems: A unified view. *Operations Research*, 67(3), 858-876.
- Collantine, K. (2020). *How a Ban on Refuelling Transformed F1 Strategy*. RaceFans.net.
- De Celis, S., & Allou, K. (2022). Advanced Tyre Modelling for Motorsport Simulation: Integrating Thermal and Wear Effects. *SAE International Journal of Advances and Current Practices in Mobility*, 4(2), 675-689.
- Ding, Y., & Liu, S. (2023). Reinforcement Learning for Pit Stop Strategy Optimization in Formula 1 Racing. *Proceedings of the International Conference on Machine Learning and Cybernetics (ICMLC)*, 234-239.
- Fernández, J. A., & López-Lázaro, A. (2021). Tyre Degradation and Performance Modelling in F1: The Impact of Fuel Load and Track Evolution. *Journal of Sports Analytics*, 7(4), 211-229.
- FIA Formula 1 Sporting Regulations. (Anual). Fédération Internationale de l'Automobile. Paris, France.
- Fijos, M., & Kacsuk, P. (2022). Simulation-Based Multi-Objective Optimization of Formula 1 Race Strategies Using a Cloud-Based Distributed Computing Environment. *Simulation Modelling Practice and Theory*, 118, 102549.
- Hughes, M., & Rendell, T. (2021). The Science of the Undercut: Tyre Strategy and Track Position in Modern F1. *Motorsport Engineering Review*, 3(1), 45-58. (Nota: "Motorsport Engineering Review" pode ser um periódico ilustrativo)
- Jenkins, M., & Bearman, C. (2014). The role of the race strategist in Formula One. In *Science and Racket Sports V* (pp. 132-138). Routledge.
- Kelly, P., & Forsberg, J. (2023). Non-Linear Tyre Wear Models and Their Application in F1 Strategy Simulation. *Vehicle System Dynamics*, 61(5), 1234-1255.
- O'Riordan, C., & Tremeayne, M. (2019). Data Analytics and Decision Making in High-Performance Sport: The Case of Formula 1. *International Journal of Sports Science & Coaching*, 14(3), 301-315.
- Pascoal, A. M., Mendes, R., & Afonso, J. L. (2023). Validation of Motorsport Simulation Models: A Pit Stop Strategy Case Study. *Applied Sciences*, 13(6), 3567.
- Pirelli & C. S.p.A. (Anual). *Formula 1 Tyre Technical Communications and Previews*. [Pirelli.com/motorsport](https://www.pirelli.com/motorsport).
- Pitrik, R., & Kacsuk, P. (2020). Towards a Generic Race Strategy Simulation Framework for Formula Student and Formula One. *Procedia Computer Science*, 170, 535-542.