

ANÁLISE ESTRATÉGICA DE CORRIDAS DE MOTORSPORT COM BASE EM DADOS REAIS E SIMULADOS

Isabela Pasin¹
Cátia Capeletto²
Euclésio Giuliani³
Paulo Miguel de Toni⁴

RESUMO

A análise estratégica no automobilismo moderno tornou-se um campo de investigação relevante pela combinação entre dados de corrida, modelagem computacional e tomada de decisão em tempo real. Este estudo analisa as estratégias adotadas nas edições de 2024 e 2025 do Grande Prêmio do Brasil, disputadas no Autódromo José Carlos Pace, a partir de dados reais extraídos via biblioteca FastF1 e de simulações baseadas em modelo matemático, buscando responder de que forma essa comparação pode contribuir para compreender, validar e explorar decisões estratégicas no *motorsport*. A pesquisa é qualitativa e comparativa, estruturada em três eixos: análise individual de cada corrida, comparação entre os dois anos e avaliação de cenários alternativos por simulação. Os resultados evidenciam que o *timing* das paradas exerce maior influência sobre o resultado final do que o ritmo absoluto de volta, padrão observado tanto em condições de chuva quanto em pista seca. A comparação entre dados reais e cenários simulados validou as decisões estratégicas adotadas pelas equipes, confirmando seu respaldo técnico, e permitiu explorar alternativas não executadas, descartando explicações baseadas exclusivamente em velocidade e revelando a posição em pista como variável determinante que modelos de tempo puro não capturam. Essa divergência entre simulado e real constitui um resultado analítico, não uma limitação, ao demonstrar que compreender o resultado de uma corrida exige analisar simultaneamente ritmo, degradação e posição. Como contribuição metodológica, o estudo demonstra que dados públicos aliados a modelos matemáticos acessíveis são suficientes para produzir análise estratégica consistente, com potencial de replicação em sistemas de engenharia que operem com decisão sob incerteza e múltiplas variáveis.

Palavras-chave: *Motorsport*. Estratégia de corrida. Análise de dados.

1 INTRODUÇÃO

A análise estratégica de corridas no *motorsport*, em especial na Fórmula 1, é a combinação de avaliação de dados reais e dados simulados que tem como intenção a otimização de decisões em tempo real e aprimorar o desempenho competitivo. Nas últimas décadas, o avanço tecnológico nesse setor ampliou significativamente a capacidade de coleta,

¹ Graduando (a) em Engenharia Mecânica (UCEFF, 2026). E-mail: belapasin@gmail.com

² Mestre em Ciências Ambientais – Universidade Comunitária da Região de Chapecó (UNOCHAPECÓ) - E-mail: catia@uceff.edu.br

³ Mestre em Projetos e Processos de Fabricação – Universidade de Passo Fundo (UPF) – E-mail: euclesio@uceff.edu.br.

⁴ Docente da UCEFF Faculdades.

processamento e interpretação de grandes volumes de dados, principalmente durante eventos esportivos de alto nível. Neste contexto, sensores de alta precisão, sistemas avançados de telemetria e *softwares* de simulação permitem que equipes transformem dados em vantagem competitiva e maior capacidade de orientação a decisões técnicas e estratégicas ao longo de uma corrida (Ekanem; Ikpe; Abia, 2024).

Nos veículos de competição, há centenas de sensores instalados para monitorar parâmetros mecânicos, como temperatura de pneus, pressão de freios e desempenho do motor, além de variáveis ambientais e padrões de pilotagem. Esses dados são transmitidos em tempo real para engenheiros e analistas, que utilizam ferramentas computacionais e modelos de análise para interpretar o comportamento do carro e antecipar cenários estratégicos, tudo em simultaneidade com a corrida em andamento. Dessa forma, decisões relacionadas a *pit stops*, gerenciamento de pneus ou ritmo de corrida podem ser tomadas com base em evidências quantitativas e simulações antecipadas (Delzell; McCabe; Mourad, 2019).

Essa crescente integração entre engenharia, ciência de dados e estratégia transformou o *motorsport* em um ambiente altamente orientado por informação. Neste âmbito, o automobilismo atual pode ser compreendido como um laboratório de inovação tecnológica, no qual dados históricos e simulados são utilizados para reduzir incertezas e aumentar a eficiência das definições estratégicas realizadas durante a corrida. (Patil *et al.*, 2023).

Diante desse cenário, este estudo propõe aprofundar como decisões estratégicas são tomadas no *motorsport* e de que forma a análise comparativa entre dados reais e simulados pode revelar padrões, tendências e oportunidades de otimização. O foco desta pesquisa recai sobre as edições de 2024 e 2025 do Grande Prêmio do Brasil, disputadas no Autódromo José Carlos Pace, em Interlagos. As duas edições ocorrem em contextos opostos, sendo uma disputada integralmente sob chuva e a outra completamente em pista seca. Dessa forma, a decisão de analisar corridas do mesmo circuito de eventos distintos, consegue compreender variáveis estruturais associadas ao *layout* do circuito, permitindo comparações consistentes. Ao manter constante o ambiente de competição é possível observar com maior clareza como os fatores de gerenciamento de pneus, momento das paradas de *box*, ritmo de corrida e condições de prova influenciam os resultados estratégicos.

Portanto, a questão central que orienta esta pesquisa é: **de que forma a comparação entre dados reais de corridas e cenários simulados pode contribuir para compreender, validar e explorar decisões estratégicas no *motorsport*?**

Para respondê-la, definem-se três objetivos específicos. O primeiro é analisar as estratégias de *pit stop* e utilização de compostos que influenciaram as edições de 2024 e 2025, a partir dos dados reais de corrida. O segundo é comparar como diferentes condições de pista influenciaram o comportamento estratégico e os resultados obtidos em cada prova. O terceiro é avaliar, por meio de simulação baseada em modelo matemático, cenários estratégicos alternativos aos observados nas corridas reais, confrontando os resultados simulados com as decisões efetivamente adotadas pelas equipes.

Este trabalho utiliza exclusivamente dados públicos de corridas da Fórmula 1, obtidos por meio da biblioteca FastF1, e dados simulados gerados pela autora. Não foram utilizadas informações proprietárias, de telemetria interna de equipes ou sob restrição de uso. A manipulação e apresentação dos dados seguem princípios de transparência e reprodutibilidade, conforme diretrizes éticas para pesquisas baseadas em dados abertos.

2 FUNDAMENTAÇÃO TEÓRICA

A compreensão das estratégias adotadas no *motorsport* exige a integração entre diferentes áreas do conhecimento, envolvendo desde conceitos associados à análise de dados até fenômenos mecânicos relacionados ao comportamento do veículo durante a corrida. No contexto da Fórmula 1, o desempenho não depende exclusivamente da capacidade do piloto ou da potência do carro, mas também da interpretação de informações em tempo real e da interação entre variáveis físicas, mecânicas e operacionais. Assim, esta fundamentação teórica apresenta os principais conceitos que sustentam a presente pesquisa, abordando inicialmente a utilização de dados na tomada de decisão estratégica, seguida pelos aspectos mecânicos relacionados ao comportamento dos pneus e consequentemente às tomadas de decisões e, por fim, pelos modelos computacionais empregados na análise de cenários de corrida.

2.1 DADOS E ESTRATÉGIA NO MOTORSPORT MODERNO

O automobilismo sempre esteve associado ao desenvolvimento tecnológico mecânico, mas nas últimas décadas a transformação mais significativa ocorreu na forma como as equipes utilizam e trabalham com dados para a tomada de decisões. Na Fórmula 1, cada carro gera centenas de *gigabytes* de informação por fim de semana, que são coletados por sensores que monitoram desde temperatura de pneus, pressão de freios, consumo de combustível ao comportamento mecânico completo em tempo real (Delzell; McCabe; Mourad, 2019). Essas

informações são cruciais para os engenheiros no *pit lane* e em centros remotos, servindo como base para a tomada de decisões estratégicas durante a corrida. Elas orientam desde a definição do momento ideal para uma parada nos boxes até o gerenciamento do ritmo de desgaste dos pneus em cada trecho (*stint*).

Ekanem, Ikpe e Abia (2024) compreendem que a Fórmula 1 se consolidou como um espaço de difusão tecnológica capaz de integrar sensores, sistemas de comunicação e *softwares* de modelagem em tempo real. Nesse ambiente, os dados deixam de ser um mero registro passivo do que aconteceu em pista e passam a ser um recurso ativo de precipitação e decisão. Estudos recentes demonstram que variáveis como posição de largada, número de *pit stops* e estratégia de pneus apresentam forte relação com o desempenho final (Patil *et al.*, 2023), e que a análise sistemática dessas variáveis permite reduzir incertezas e apoiar decisões que influenciam diretamente o resultado das provas.

Um dos fatores estratégicos mais relevantes é o gerenciamento de pneus. West e Limebeer (2020) demonstram em sua pesquisa que o monitoramento da temperatura, da degradação e da aderência permite identificar a janela de operação de cada composto, isto é, o intervalo de condições no qual o pneu entrega seu melhor desempenho. Compreender essa janela é essencial para definir o momento ideal de parada: uma troca antecipada pode desperdiçar potencial de ritmo do composto em uso, enquanto uma troca tardia pode comprometer o ritmo e expor o piloto à ultrapassagem por adversários com pneus frescos. Além disso, análises de telemetria evidenciam que pequenas diferenças na posição em pista podem gerar impactos significativos no resultado final, especialmente em circuitos com poucos pontos naturais de ultrapassagem, onde a recuperação de posições depende predominantemente de decisões estratégicas (Msakamali, 2024).

A democratização do acesso a dados do automobilismo, por meio de ferramentas como a biblioteca FastF1, ampliou as possibilidades de investigação acadêmica nesse campo. Pesquisadores independentes passaram a ter acesso a informações detalhadas sobre tempos de volta, *stints* de pneus e estratégias de *pit stop* (Msakamali, 2024), viabilizando estudos como o presente, que combinam análise de dados reais com modelagem computacional para investigar padrões estratégicos de forma sistemática e reproduzível.

2.2 PNEUS, COMPORTAMENTO MECÂNICO E CONCEITOS ESTRATÉGICOS NA FÓRMULA 1

Os pneus representam um dos componentes mais relevantes para o desempenho de veículos de competição, pois constituem o único ponto de contato entre o carro e a superfície da pista. Na Fórmula 1, além de influenciarem aceleração, frenagem e capacidade de contorno de curvas, os pneus exercem impacto direto sobre as decisões estratégicas adotadas durante a corrida, afetando o momento das paradas, a duração dos *stints* e a escolha dos compostos utilizados (West; Limebeer, 2020). Durante corridas realizadas em pista seca, por exemplo, a Fórmula 1 utiliza compostos *slick* classificados como Macio (*Soft*), Médio (*Medium*) e Duro (*Hard*). Já em condições de pista molhada, são empregados os compostos Intermediário (*Intermediate*) e *Full Wet*, e embora apresentem função estrutural semelhante, esses compostos diferenciam-se principalmente na composição da borracha e das propriedades mecânicas do material (Pirelli, 2025).

Tais diferenças entre compostos se associam às propriedades mecânicas e viscoelásticas da borracha. Compostos mais macios apresentam maior capacidade de deformação superficial sob carregamento, ampliando a área efetiva de contato com o asfalto e proporcionando maiores níveis de aderência. Entretanto, essa característica aumenta a dissipação de energia e a geração de calor, o que acelera o desgaste do material. Em contrapartida, compostos mais rígidos apresentam maior resistência térmica e menor degradação ao longo da corrida, porém, reduzem o potencial máximo de aderência (Callister; Rethwisch, 2016; Pacejka, 2006).

A aderência entre pneu e pista não depende exclusivamente do atrito superficial entre materiais, mas também da capacidade do composto em se deformar e adaptar às irregularidades microscópicas do asfalto. Além disso, fatores como carga aplicada, temperatura e distribuição de esforços influenciam diretamente o desempenho do conjunto pneu-pista (Pacejka, 2006). Dentro desse conjunto, existe uma faixa ideal de funcionamento conhecida como janela operacional, na qual ocorre equilíbrio entre aderência e desgaste. Quando o pneu opera fora dessa faixa, seu desempenho tende a diminuir devido a alterações nas propriedades mecânicas do composto, afetando sua capacidade de gerar aderência e manter desempenho consistente ao longo das voltas (West; Limebeer, 2020).

No contexto estratégico, um conceito que é frequentemente utilizado é o *stint*, o qual é definido como: o período compreendido entre duas paradas consecutivas nos boxes. Durante esse intervalo, o desempenho do veículo sofre influência direta da degradação dos pneus, das

condições da pista e do tráfego em corrida. O desgaste progressivo modifica o comportamento do composto ao longo do tempo, alterando características de aderência e estabilidade de desempenho (West; Limebeer, 2020; Perantoni; Limebeer, 2014). Outro conceito relevante é o tráfego, situação em que um piloto permanece atrás de outros veículos. Nessas condições, fatores aerodinâmicos podem reduzir a eficiência do veículo devido ao fluxo turbulento de ar, conhecido como *dirty air*, e assim, compromete a carga aerodinâmica disponível e dificultando a aproximação em curvas e manobras de ultrapassagem (Katz, 1995).

Para as estratégias de parada, frequentemente se utiliza mecanismos conhecidos como *undercut* e *overcut*. O *undercut* consiste na realização antecipada da parada para obtenção da vantagem proporcionada por pneus novos, enquanto o *overcut* procura prolongar a permanência em pista explorando desempenho residual do composto ou condições favoráveis de corrida. Essas estratégias baseiam-se diretamente na variação do desempenho dos pneus ao longo do *stint* e na influência das condições de pista sobre os tempos de volta (West; Limebeer, 2020; Perantoni; Limebeer, 2014).

Com isso, evidencia-se que decisões estratégicas em competições automobilísticas não dependem apenas de análises estatísticas ou posicionamento em pista, mas representam a consequência de fenômenos mecânicos, térmicos e operacionais que atuam simultaneamente sobre o desempenho do veículo (Pacejka, 2006; Perantoni; Limebeer, 2014).

2.3 SIMULAÇÃO COMPUTACIONAL E MODELOS ESTRATÉGICOS

A simulação computacional tornou-se uma ferramenta central no desenvolvimento estratégico do motorsport. Modelos matemáticos baseados em dados já coletados e parâmetros físicos do veículo permitem representar variáveis como degradação de pneus, consumo energético e dinâmica de corrida, possibilitando que equipes testem diferentes configurações estratégicas antes da prova e avaliem o impacto de decisões em condições controladas (Perantoni; Limebeer, 2014). Essa capacidade de antecipar cenários é especialmente valiosa em corridas onde a janela de decisão é estreita e os custos de uma escolha errada são imediatos.

Urdhwareshe (2025) argumenta que modelos computacionais no *motorsport* são mais úteis quando utilizados para testar hipóteses específicas do que para replicar corridas completas, pois a replicação integral exigiria um volume de variáveis que ultrapassa a capacidade de controle de qualquer modelo existente. Dessa forma, a simulação por cenários se configura como uma abordagem metodologicamente apropriada para analisar o impacto das decisões de

pit stop e da escolha de compostos de maneira detalhada. Isso ocorre porque cada configuração isola uma variável estratégica específica, permitindo uma investigação focada. Komov (2024) reforça que esse tipo de abordagem é amplamente adotado por equipes de Fórmula 1 para avaliar estratégias e prever comportamentos em diferentes condições de corrida, sendo reconhecida tanto em ambientes profissionais quanto acadêmicos como uma legítima ferramenta de análise estratégica.

A integração entre dados reais e simulações oferece, no contexto acadêmico, uma oportunidade importante para comparar os resultados simulados com os dados reais. Essa comparação permite identificar tanto o acordo do modelo com a realidade, onde válida-se as estratégias observadas, quanto a sua divergência, evidenciando a influência de variáveis não modeladas, como interações entre carros, *Safety Car* e decisões de equipes adversárias. Essa lógica de confronto entre simulado e real constitui o eixo metodológico central deste estudo e é o que permite responder à pergunta problema proposta.

3 MATERIAIS E MÉTODOS

Esta pesquisa caracteriza-se como qualitativa, de natureza aplicada e com abordagem comparativa. Conforme Köche (2015), a pesquisa aplicada tem como finalidade gerar conhecimento voltado à resolução de problemas concretos. No presente estudo, essa aplicação ocorre na análise e interpretação de estratégias no *motorsport*, com foco na compreensão das decisões adotadas por equipes em condições distintas de corrida e na avaliação de cenários alternativos por meio de simulação.

Para a obtenção e processamento dos dados reais de corrida foi utilizada a biblioteca FastF1, empregada para acesso a informações históricas referentes aos Grandes Prêmios analisados, incluindo tempos de volta, estratégias de pneus, número de paradas, duração dos *stints* e demais variáveis relacionadas ao desempenho em corrida. Os dados utilizados correspondem a eventos efetivamente realizados nas temporadas selecionadas - Grande Prêmio do Brasil de 2024 e 2025 -, sendo posteriormente organizados e tratados para análise e desenvolvimento dos cenários simulados.

Após a coleta, os dados passaram por um tratamento que incluiu a remoção de voltas não representativas, como tempos de entrada e saída de *pit stop*, períodos sob *Safety Car* e valores atípicos, sendo posteriormente padronizadas para serem integradas na simulação. As métricas derivadas construídas - ritmo médio por *stint*, degradação de pneus ao longo da vida

útil e variação de desempenho entre estratégias - foram definidas com base na literatura, a qual ressalta a importância da análise quantitativa para a compreensão do desempenho no automobilismo. (Patil *et al.*, 2023; West; Limebeer, 2020).

Com base nos dados extraídos e tratados das corridas, foram construídas curvas de degradação para os compostos utilizados, calculadas a partir da mediana dos tempos de volta em função da vida útil dos pneus. Essas curvas representam matematicamente a perda gradual de desempenho ao longo dos *stints* e serviram como base para o modelo matemático de simulação desenvolvido neste trabalho. Para padronização da representação das estratégias ao longo das análises e simulações, foram adotadas as nomenclaturas M (*Medium*), S (*Soft*), H (*Hard*), INT (*Intermediate*) e WET (*Full Wet*), correspondentes aos compostos disponibilizados pela Fórmula 1 nos eventos analisados. Essas siglas foram utilizadas para representação dos cenários estratégicos e identificação das sequências de pneus adotadas ao longo dos *stints*.

O modelo foi implementado em linguagem *Python*, com uso das bibliotecas *Pandas*, *NumPy*, *SciPy* e *Matplotlib*, e teve como objetivo estimar o tempo total de corrida para diferentes estratégias de *pit stop*. O cálculo é realizado pela soma dos tempos estimados de cada volta, os quais foram obtidos diretamente das curvas de degradação, acrescida do tempo perdido em cada parada nos boxes. Essa estrutura é representada pela expressão:

$$T_{corrida} = \sum_{i=1}^N t_{volta}(i) + n_{paradas} \times t_{pit}$$

Em que $t_{volta}(i)$ corresponde ao tempo estimado para cada volta pela curva de degradação do composto em uso, N representa o número total de voltas da corrida, $n_{paradas}$ representa o número de *pit stops* realizados e t_{pit} corresponde ao tempo médio perdido em cada parada, estimado em 22 segundos com base nos dados reais da corrida de 2025, a qual foi selecionada por apresentar maior estabilidade operacional e menor interferência de fatores externos.

Para aproximar o modelo das condições reais de competição, foi introduzido um fator de variabilidade nos tempos simulados por meio da aplicação de uma distribuição normal com desvio-padrão de 0,3 segundos por volta. O valor adotado foi definido a partir da dispersão observada nos dados tratados das corridas analisadas, buscando representar pequenas oscilações naturais de desempenho entre voltas consecutivas. Esse procedimento permite reproduzir variações associadas a fatores como pequenas diferenças de ritmo, degradação progressiva e condições dinâmicas da corrida, sem introduzir níveis de ruído capazes de comprometer a comparação entre os cenários simulados. A aleatoriedade foi mantida constante em todos os cenários para garantir a reprodutibilidade dos resultados.

A partir dessa estrutura, foram definidos cinco cenários estratégicos: (i) a estratégia de referência utilizada pelo vencedor da corrida de 2025 ($M \rightarrow S \rightarrow M$, com paradas nas voltas 30 e 50); (ii) uma estratégia com parada antecipada em cinco voltas (V25); (iii) uma estratégia com parada tardia em cinco voltas (V35); (iv) uma abertura com pneu Macio ($S \rightarrow M \rightarrow M$); e (v) uma estratégia de parada única ($M \rightarrow M$). Os cenários foram comparados entre si com base no tempo total estimado, no ritmo médio por *stint* e na consistência de desempenho ao longo da prova, e posteriormente confrontados com os dados reais das corridas.

Ferramentas computacionais e de inteligência artificial generativa foram utilizadas como recursos auxiliares durante o desenvolvimento desta pesquisa. O ambiente *Google Colab* foi empregado para implementação, execução e validação do modelo matemático desenvolvido em linguagem *Python*. Além disso, ferramentas de inteligência artificial, incluindo *ChatGPT* (*OpenAI*) e *Claude* (*Anthropic*), foram utilizadas como suporte em atividades relacionadas à organização estrutural do trabalho, apoio à programação dos modelos simulados e auxílio na análise exploratória dos dados. Entretanto, todas as definições metodológicas, critérios de seleção dos dados, decisões analíticas, interpretações técnicas e conclusões apresentadas foram desenvolvidas pela autora, sendo tais ferramentas utilizadas exclusivamente como instrumentos de apoio ao processo de desenvolvimento acadêmico.

A integração entre dados reais e simulações oferece, no contexto acadêmico, uma oportunidade importante para comparar os resultados simulados com os dados reais. Essa comparação permite identificar tanto o grau de concordância do modelo com a realidade, na qual ocorre a validação das estratégias observadas, quanto suas divergências, evidenciando a influência de variáveis não modeladas, como interações entre carros, *Safety Car* e decisões de equipes adversárias. Os resultados obtidos são apresentados e confrontados com os dados reais na seção seguinte.

4 RESULTADOS E DISCUSSÕES

Esta seção apresenta os resultados obtidos a partir da análise dos dados reais extraídos via *FastF1* para as edições de 2024 e 2025 do Grande Prêmio do Brasil, disputados no Autódromo José Carlos Pace, em Interlagos/SP. A estrutura segue os três objetivos específicos do estudo, respondendo em sequência à questão central da pesquisa: de que forma a comparação

entre dados reais e cenários simulados pode contribuir para compreender, validar e explorar decisões estratégicas no *motorsport*.

4.1 ANÁLISE DAS CORRIDAS REAIS

4.1.1 Grande Prêmio do Brasil 2024

O Grande Prêmio do Brasil de 2024 foi disputado integralmente sob chuva, com utilização exclusiva dos compostos Intermediário (INT) e *Full Wet* (WET) da Pirelli. As condições de pista molhada alteraram significativamente a dinâmica estratégica da corrida. Diferentemente de corridas realizadas em pista seca, nas quais a gestão da degradação térmica dos pneus frequentemente representa o principal fator estratégico, condições de pista molhada tornam a corrida mais dependente da evolução da superfície do asfalto ao longo da prova e da capacidade dos compostos manterem desempenho dentro de sua janela operacional (West; Limebeer, 2020).

Nesse cenário, o desempenho dos pneus esteve diretamente relacionado ao nível de umidade presente na pista. O composto INT apresentou melhor rendimento enquanto a superfície permaneceu suficientemente molhada, condição em que seus sulcos conseguiram remover a água e manter contato efetivo entre pneu e asfalto. Entretanto, à medida que a pista começou a secar parcialmente, ocorreu aumento progressivo do atrito e da energia dissipada na interface pneu-pista, elevando a temperatura do composto e promovendo superaquecimento gradual (Pacejka, 2006; Callister; Rethwisch, 2016). Essa condição aumentou significativamente a complexidade das decisões estratégicas, pois as equipes passaram a depender continuamente da interpretação de informações climáticas, dados de telemetria e *feedback* dos pilotos para identificar o momento mais adequado para a realização das paradas.

A prova foi encerrada em 69 voltas e apresentou tempo mediano de 84,79s por volta, valor aproximadamente 13% superior ao registrado na edição de 2025 em condições secas. Essa diferença evidencia o impacto direto das condições climáticas sobre o desempenho dos veículos e sobre a dinâmica estratégica da corrida. Em pista molhada, a redução dos níveis de aderência modifica o comportamento longitudinal e lateral dos pneus, limitando acelerações, frenagens e velocidades de contorno de curva (Pacejka, 2006).

A maior parte das paradas ocorreu próxima da volta 27, indicando convergência estratégica entre as equipes quanto ao limite operacional do composto INT naquele estágio da

corrida. A deterioração progressiva das condições de aderência, associada ao aumento do superaquecimento dos pneus, levou diferentes equipes a realizarem decisões semelhantes em intervalo reduzido de voltas. Essa concentração estratégica foi intensificada pela entrada do *Safety Car* entre as voltas 28 e 33. Durante períodos de neutralização, a redução da velocidade média do pelotão diminui o tempo relativo perdido em uma parada nos *boxes*, tornando a realização do *pit stop* mais vantajosa do ponto de vista estratégico. Como consequência, equipes que ainda não haviam realizado paradas foram incentivadas a antecipar suas decisões, ampliando o efeito de convergência observado naquele momento da corrida. Entre as voltas 39 e 42, ocorreu um segundo *Safety Car* provocando nova reorganização do pelotão e influenciando novamente as decisões estratégicas (FastF1, 2026).

Durante o período de maior intensidade de chuva, cinco pilotos utilizaram temporariamente o composto WET. Entretanto, os tempos médios registrados com esse pneu foram próximos de 120s por volta, aproximadamente 42% superiores aos obtidos com o INT. Embora o composto WET apresenta maior capacidade de drenagem de água devido à profundidade e geometria dos sulcos, sua utilização mostrou-se limitada devido à rápida evolução das condições da pista. Em situações de menor volume de água disponível, o aumento do contato direto entre borracha e asfalto tende a elevar rapidamente a temperatura do pneu, reduzindo sua eficiência operacional (Pirelli, 2025).

A análise dos resultados apresentados na Tabela 1 demonstra que o resultado final da corrida não esteve associado exclusivamente ao ritmo médio dos pilotos. Em condições de pista molhada e períodos de neutralização, fatores estratégicos como o momento das paradas e o posicionamento em relação ao *Safety Car* exerceram influência decisiva sobre o resultado da prova.

Tabela 1 - Resumo de estratégias e resultados GP Brasil 2024

Piloto	Equipe	Paradas	Sequência	Ritmo médio (s)	Pos. final
VER	Red Bull Racing	1	INT → INT	86,12	1º
OCO	Alpine	1	INT → INT	88,26	2º
GAS	Alpine	1	INT → INT	88,31	3º
RUS	Mercedes	2	INT → INT → INT	87,45	4º
LEC	Ferrari	2	INT → INT → INT	87,82	5º
NOR	McLaren	2	INT → INT → INT	87,66	6º
PIA	McLaren	2	INT → INT → INT	87,73	7º

Piloto	Equipe	Paradas	Sequência	Ritmo médio (s)	Pos. final
TSU	RB F1 Team	2	INT → WET → INT	89,54	8º
LAW	RB F1 Team	2	INT → WET → INT	89,61	9º
HAM	Mercedes	2	INT → INT → INT	87,95	10º

Fonte: Elaborado pela autora com base em dados FastF1 (2026).

Legenda:

INT – Intermediário (Intermediate);

WET – Chuva extrema (*Full Wet*);

Os pilotos OCO e GAS, da Alpine, finalizaram a corrida na segunda e terceira posições mesmo apresentando ritmos médios superiores aos de competidores do pelotão principal. Esse comportamento evidencia que o desempenho absoluto do carro não foi o único fator determinante do resultado, reforçando a influência do posicionamento estratégico e do momento das neutralizações. O vencedor da prova, VER, apresentou simultaneamente o melhor ritmo médio e a melhor posição final. Sua estratégia foi favorecida pela capacidade de manter o composto Intermediário dentro de uma faixa mais estável de desempenho ao longo de stints prolongados, especialmente após a segunda neutralização (FastF1, 2026).

A análise do comportamento do composto INT demonstrou degradação relativamente lenta entre aproximadamente 15 e 27 voltas de utilização, permitindo estratégias mais extensas sem perdas significativas de desempenho. Dessa forma, os resultados indicam que os principais fatores estratégicos observados na corrida de 2024 estiveram relacionados ao *timing* das paradas em relação ao *Safety Car* e ao gerenciamento da janela operacional do composto INT, exercendo influência superior ao ritmo bruto isoladamente.

4.1.2 Grande Prêmio do Brasil 2025

A edição de 2025 do Grande Prêmio do Brasil apresentou condições contrastantes em relação ao ano anterior, sendo disputada integralmente em pista seca ao longo de 71 voltas, com utilização dos compostos *slick* Duro (H), Médio (M) e Macio (S) disponibilizados pela Pirelli. As voltas iniciais foram influenciadas por um período de *Safety Car* entre as voltas 3 e 8, durante o qual os tempos de volta ultrapassaram 100s e atingiram valores próximos de 123s. Após a relargada, os tempos retornaram gradualmente ao padrão competitivo esperado para condições secas.

Com a estabilização das condições da pista, a corrida retomou a dinâmica estratégica típica de provas em pista seca, baseada principalmente no gerenciamento da degradação térmica

e mecânica dos pneus e na definição do momento ideal das paradas de *box* (West; Limebeer, 2020). Diferentemente das condições observadas em 2024, em condições secas o desempenho passa a depender principalmente da capacidade dos compostos manterem aderência e estabilidade térmica ao longo dos *stints*.

A estratégia predominante foi a de duas paradas, adotada pela maior parte do pelotão. As sequências M→S→M e S→M→M foram as configurações mais utilizadas pelas equipes. Estratégias iniciadas com o composto M favoreceram *stints* iniciais mais longos e estáveis devido ao equilíbrio entre aderência e resistência ao desgaste. Em contraste, estratégias iniciadas com o composto S priorizaram ganho imediato de desempenho, porém com maior sensibilidade ao aumento de temperatura e à degradação inicial, especialmente em situações de tráfego intenso (Pacejka, 2006; West; Limebeer, 2020).

A análise dos resultados apresentados na Tabela 2 demonstra que o ritmo médio isolado não foi suficiente para determinar o resultado final da corrida. O piloto VER, da Red Bull Racing, registrou o melhor ritmo médio da prova (76,34s por volta) e concentrou parte significativa das voltas mais rápidas da corrida. Entretanto, finalizou apenas na terceira posição após realizar três paradas e perder tempo em situações de tráfego durante momentos importantes da prova.

Tabela 2 - Resumo de estratégias e resultados GP Brasil 2025

Piloto	Equipe	Paradas	Sequência	Ritmo médio (s)	Pos. final
NOR	McLaren	2	M → S → M	77,41	1º
ANT	Mercedes	2	S → M → M	77,32	2º
VER	Red Bull Racing	3	H → M → M → S	76,34	3º
RUS	Mercedes	2	M → S → M	77,47	4º
PIA	McLaren	2	M → S → M	77,56	5º
BEA	Haas	2	S → M → M	77,45	6º
LAW	RB F1 Team	1	S → M	77,83	7º
HAD	RB F1 Team	2	S → M → M	77,86	8º
HUL	Kick Sauber	1	M → S	77,91	9º
GAS	Alpine	2	S → M → M	77,78	10º

Fonte: Elaborado pela autora com base em dados FastF1 (2026).

Legenda:

M – Médio (*Medium*);

S – Macio (*Soft*);

H – Duro (*Hard*);

Esse comportamento evidencia a importância do posicionamento em pista e do *timing* dos *pit stops* em Interlagos, especialmente em condições nas quais o tráfego limita oportunidades de ultrapassagem (Katz, 1995). Em contraste, NOR venceu a corrida utilizando estratégia de duas paradas com sequência M→S→M e menor perda de tempo em disputas de posição ao longo dos *stints*.

Os resultados indicam que, em condições secas, estratégias associadas à manutenção de posição e à execução eficiente das paradas apresentaram maior impacto sobre o resultado final do que o ritmo médio isoladamente.

4.2 COMPARAÇÃO ENTRE OS ANOS

A análise comparativa entre as edições de 2024 e 2025 do Grande Prêmio do Brasil evidencia como diferentes condições de pista alteram diretamente a lógica estratégica da corrida. Em 2024, a prova foi disputada integralmente sob chuva, com utilização dos compostos Intermediário (INT) e *Full Wet* (WET), enquanto em 2025 ocorreu em pista seca, com os três compostos *slick* disponíveis. Embora as condições climáticas sejam distintas, a comparação permanece relevante por manter constantes fatores como circuito, equipes e estrutura da prova, permitindo observar como diferentes cenários modificam o comportamento estratégico dos times.

Em 2024, a chuva elevou significativamente os tempos de volta, com mediana de 84,79s, aproximadamente 13% superior ao registrado em 2025. Nesse contexto, observou-se forte convergência estratégica, com a maioria das paradas concentrada em torno de uma volta em comum. As neutralizações exerceram papel central na corrida, reduzindo o tempo perdido nos *boxes* e favorecendo equipes que conseguiram alinhar suas paradas aos períodos de *Safety Car*. Além disso, a degradação relativamente controlada do composto INT permitiu *stints* mais longos, tornando a manutenção de posição em pista um fator estratégico relevante.

Em contraste, a corrida de 2025 apresentou maior dispersão das janelas de parada e maior variedade estratégica ao longo da prova. Com três compostos *slick* disponíveis, as equipes passaram a explorar diferentes combinações de pneus e ritmos de corrida de acordo com a degradação, tráfego e posicionamento em pista. Nessas condições, estratégias de *undercut* tornaram-se mais relevantes devido à diferença de desempenho entre pneus novos e

degradados, especialmente em situações nas quais ultrapassagens diretas eram limitadas pelo equilíbrio competitivo entre os carros (West; Limebeer, 2020).

A Tabela 3 evidencia diferenças relevantes entre os dois cenários analisados.

Tabela 3 - Comparação de ritmo médio por tipo de estratégia GPs 2024 e 2025

Ano	Estratégia	Ritmo médio (s/volta)	Melhor volta (s)	Posição média final	Nº de pilotos
2024	1 parada	88,53	82,21	7,2	5
2024	2 paradas	88,65	82,27	10,2	12
2024	3+ paradas	89,67	83,06	15,0	1
2025	1 parada	77,87	73,75	14,5	2
2025	2 paradas	77,59	73,17	10,8	11
2025	3+ paradas	77,43	73,02	6,0	3

Fonte: Elaborado pela autora com base em dados FastF1 (2026).

Legenda:

M – Médio (*Medium*);

S – Macio (*Soft*);

H – Duro (*Hard*);

Em 2024, estratégias de uma parada apresentaram melhor posição média final, enquanto em 2025 os melhores resultados médios estiveram associados a estratégias com maior número de paradas. Esses resultados indicam que as condições de pista modificaram diretamente a eficiência estratégica das equipes em cada edição da corrida.

4.3 SIMULAÇÕES ESTRATÉGICAS E TOMADA DE DECISÃO

4.3.1 Resultados da simulação

Os cenários simulados foram definidos a partir de diferentes combinações de compostos e janelas de parada, utilizando como referência a estratégia vencedora do GP do Brasil de 2025. A Tabela 4 apresenta os objetivos estratégicos de cada cenário analisado, enquanto a Tabela 5 resume os resultados obtidos pelo modelo de simulação.

Tabela 4 - Cenários de simulação: configuração e questão estratégica

Cenário	Sequência	1ª parada	2ª parada	Objetivo estratégico
C1 — Referência	M → S → M	V30	V50	Estratégia vencedora utilizada como linha de base
C2 — Parada antecipada	M → S → M	V25	V48	Avaliar o impacto de um undercut antecipado
C3 — Parada tardia	M → S → M	V35	V52	Avaliar o efeito da extensão do primeiro <i>stint</i>
C4 — Abertura em Macio	S → M → M	V20	V47	Analisar o ganho inicial de desempenho com pneus macios
C5 — Uma parada	M → M	V36	—	Verificar a viabilidade estratégica de uma única parada

Fonte: elaborado pela autora com base em dados FastF1 (2025).

Legenda:

M – Médio (*Medium*);

S – Macio (*Soft*);

H – Duro (*Hard*);

A partir da definição dos cenários, o modelo matemático foi utilizado para estimar o desempenho de cada estratégia em termos de tempo total de corrida, ritmo médio e variabilidade de desempenho. A Tabela 5 apresenta os resultados obtidos para cada cenário simulado em termos de tempo total de corrida, ritmo médio por volta e variabilidade de desempenho. O parâmetro σ (desvio-padrão) representa a dispersão dos tempos de volta ao longo da simulação, sendo utilizado como indicador de consistência de ritmo durante a corrida. Já o parâmetro Δ vs C1 corresponde à diferença de tempo total em relação ao cenário de referência, permitindo comparar diretamente o desempenho estratégico de cada configuração simulada.

Tabela 5 - Cenários de simulação: configuração e questão estratégica

Cenário	Sequência	Paradas	Tempo total (s)	Ritmo médio (s/v)	σ (s)	Δ vs C1 (s)
C1 - Referência	M→S→M	2	5.332,7	74,489	0,543	ref.
C2 - Parada antecipada	M →S→M	2	5.333,6	74,501	0,596	+0,9
C3 - Parada tardia	M→S→M	2	5.333,4	74,498	0,591	+0,7
C4 - Abertura em Macio	S→ M→M	2	5.331,4	74,471	0,485	-1,3

C5 - Uma parada	M→M	1	5.323,4	74,667	0,525	-9,3
-----------------	-----	---	---------	--------	-------	------

Fonte: elaborado pela autora com base em dados FastF1 (2025).

Legenda:

M – Médio (*Medium*);

S – Macio (*Soft*);

H – Duro (*Hard*);

Os resultados da simulação revelam três padrões estratégicos distintos, cada um com implicação direta para a compreensão das decisões observadas na corrida real.

O primeiro comportamento refere-se ao impacto do momento da primeira parada. Os cenários C2 e C3, que anteciparam e postergaram o primeiro *pit stop* em cinco voltas em relação ao cenário de referência, apresentaram diferença inferior a 1s no tempo total da corrida. Esse resultado indica que o composto M operou em uma faixa relativamente estável de degradação entre as voltas analisadas, permitindo pequena flexibilidade estratégica sem perdas significativas de desempenho.

O segundo comportamento está relacionado à sequência de compostos utilizada. O cenário C4, correspondente à estratégia S→M→M, apresentou o melhor resultado entre as estratégias de duas paradas, registrando tempo total 1,3s inferior ao cenário de referência. O desempenho superior está associado ao ganho inicial de aderência proporcionado pelo composto S das primeiras voltas do *stint*, favorecendo ritmos mais competitivos no início da corrida. A convergência entre o resultado simulado e o desempenho observado na corrida real, na qual o piloto ANT finalizou na segunda posição utilizando estratégia semelhante, reforça a capacidade do modelo em representar padrões estratégicos observados em pista.

O terceiro comportamento corresponde ao cenário C5, de parada única, que apresentou o menor tempo total da simulação, com vantagem de 9,3s em relação ao cenário de referência. O resultado foi favorecido principalmente pela redução do tempo acumulado em *pit stops*. Entretanto, essa eficiência não se refletiu na corrida real, na qual estratégias de uma parada apresentaram desempenho competitivo inferior em termos de posição final.

A divergência observada não representa uma falha do modelo, mas uma limitação inerente à abordagem adotada. O modelo matemático considera o tempo acumulado de corrida, porém não incorpora variáveis associadas à dinâmica de posição em pista, como tráfego, dificuldade de ultrapassagem e perda de desempenho em disputas diretas. Em condições reais,

stints prolongados com pneus degradados tornam os pilotos mais vulneráveis a adversários utilizando compostos mais novos e com maior aderência.

Dessa forma, os resultados indicam que, em circuitos como Interlagos, a posição relativa em pista pode exercer influência estratégica equivalente ou superior ao ritmo bruto de corrida. Além disso, a comparação entre dados simulados e dados reais evidencia que modelos baseados exclusivamente em tempo tendem a subestimar o impacto competitivo associado à degradação dos pneus e à perda de posição ao longo da prova.

5 CONSIDERAÇÕES FINAIS

Este estudo analisou as estratégias adotadas nas edições de 2024 e 2025 do Grande Prêmio do Brasil de Fórmula 1, combinando dados reais obtidos via FastF1 com simulações baseadas em modelo matemático. O objetivo foi responder à seguinte pergunta norteadora: de que forma a comparação entre dados reais de corridas e cenários simulados pode contribuir para compreender, validar e explorar decisões estratégicas no motorsport?

A análise dos dados reais permitiu compreender que o fator determinante do resultado, em ambas as edições, não foi exclusivamente o ritmo absoluto dos carros, mas principalmente a qualidade das decisões tomadas na janela de *pit stops*, padrão que foi presente tanto nas condições de chuva de 2024 quanto na pista seca de 2025, sustentado por mecanismos distintos, mas pela mesma lógica competitiva. É precisamente nesse ponto que a comparação entre dados reais e cenários simulados demonstra sua contribuição: ela não apenas descreve o que aconteceu, mas permite questionar, testar e interpretar por que aconteceu.

Ao confrontar os dados reais com os cenários simulados, foi possível validar que as estratégias adotadas pelas equipes estavam entre as alternativas mais eficientes disponíveis para cada contexto, e confirmando que suas decisões tinham respaldo técnico e não eram resultado de acaso. Ao mesmo tempo, os cenários alternativos permitiram explorar escolhas que não foram feitas, revelando que algumas estratégias teoricamente superiores em tempo puro não se sustentariam nas condições reais de corrida, justamente por ignorarem a posição em pista como variável competitiva.

Essa divergência entre simulado e real não invalida o modelo, ao contrário; o torna mais informativo, pois indica com precisão onde o tempo puro deixa de ser suficiente para explicar o resultado e onde a dinâmica de posição passa a ser determinante. A comparação, portanto, contribui ao transformar dados em interpretação, descartando explicações simplistas baseadas

apenas em velocidade, e validando decisões estratégicas com base em evidência e ainda prova que compreender o resultado de uma corrida exige analisar simultaneamente ritmo, degradação e posição - três variáveis que se isoladas não são capazes de explicar o que aconteceu.

Os resultados também apontam para uma contribuição que ultrapassa o contexto do automobilismo. A abordagem metodológica adotada neste estudo, baseada na extração de padrões a partir de dados reais, utilização de ferramentas modernas como auxílio, construção de modelos matemáticos e simulação de cenários controlados, pode ser aplicada a diferentes sistemas de engenharia que operam sob pressão temporal, múltiplas variáveis e condições dinâmicas. Contextos como manutenção preditiva de equipamentos, gestão logística e planejamento operacional em tempo real compartilham a necessidade de interpretar dados continuamente, reduzir incertezas e antecipar possíveis cenários antes da tomada de decisão.

Além disso, o estudo demonstra que esse tipo de análise pode ser desenvolvido com dados públicos, ferramentas abertas e modelos matematicamente acessíveis, sem dependência de infraestrutura proprietária ou sistemas especializados de alto custo. Sob essa perspectiva, o *motorsport* funciona e funcionou como um laboratório de alta complexidade, caracterizado por grande volume de dados e decisões de alto impacto em tempo real, oferecendo condições adequadas para demonstrar o potencial da engenharia orientada por dados como suporte à tomada de decisão.

Como perspectiva de desenvolvimento futuro, o modelo pode ser ampliado para incorporar dinâmica de posição em pista, interação entre carros e variáveis externas, aproximando progressivamente os resultados simulados das condições reais de corrida, quando se refere ao *motorsport*. Em um horizonte mais amplo, a mesma estrutura metodológica pode ser adaptada para outros domínios da engenharia contemporânea, abrindo caminho para estudos que integrem análise de dados operacionais e simulação de cenários como ferramentas de apoio estratégico. Este trabalho constitui, antes de tudo, uma demonstração de método e métodos, que diferentemente de resultados isolados, podem ser reproduzidos, adaptados e ampliados para diferentes contextos da engenharia.

REFERÊNCIAS

ANTHROPIC. Claude. **Modelo de inteligência artificial generativa**. San Francisco, 2026. Disponível em: <https://claude.ai>

AUTO ACTION. **McLaren strategy backfires as Verstappen rescues title hopes**. Disponível em: <https://autoaction.com.au/2025/12/01/mclaren-strategy-backfires-as-verstappen-rescues-title-hopes>

CALLISTER, W. D.; RETHWISCH, D. G. **Ciência e engenharia de materiais: uma introdução**. 9. ed. Rio de Janeiro: LTC, 2016.

DELZELL, P.; MCCABE, P.; MOURAD, A. **Automation of data analysis in Formula 1**. California Polytechnic State University, 2019.

EKANEM, I. I.; IKPE, A. E.; ABIA, E. S. **Evolution of Formula One (F1) motorsports and its top-notch advancement in engineering innovations across the racing industry**. Proceedings of the ATLAS 11th International Congress on Advanced Scientific Studies and Interdisciplinary Research, 2024. Disponível em: <https://www.researchgate.net/publication/378040222>.

FORMULA 1. **Verstappen wins chaotic Sao Paulo Grand Prix after stunning recovery from P17**. Disponível em: <https://www.formula1.com/en/latest/article/verstappen-wins-chaotic-sao-paulo-grand-prix-after-stunning-recovery-from.1DIc8pzRmGbC3jHJmvtBi1>

GOOGLE. Google Colaboratory. **Ambiente computacional para execução de códigos em nuvem**. Mountain View, 2026.

KATZ, J. **Race car aerodynamics: designing for speed**. 3. ed. Warrendale: Bentley Publishers, 1995.

KOMOV, D. **The role of software in Formula 1 racing**. 2024. Bachelor's thesis – Lappeenranta–Lahti University of Technology, Lappeenranta, 2024.

MSAKAMALI, B. **F1 data analysis and tactical insights: Exploring Formula 1 race performance strategies**. 2024. Bachelor's thesis – Tampere University of Applied Sciences, Tampere, 2024.

OPENAI. ChatGPT. **Modelo de linguagem baseado em inteligência artificial**. San Francisco, 2026. Disponível em: <https://chat.openai.com>

PACEJKA, H. B. **Tire and vehicle dynamics**. 2. ed. Oxford: Butterworth-Heinemann, 2006.

PATIL, A.; JAIN, N.; AGRAHARI, R.; HOSSARI, M.; ORLANDI, F.; DEV, S. **A data-driven analysis of Formula 1 car races outcome**. In: LONGO, L.; O'REILLY, R. (Eds.). Artificial Intelligence and Cognitive Science. Cham: Springer, 2023. p. 134–146. DOI: https://doi.org/10.1007/978-3-031-26438-2_11.

PERANTONI, G.; LIMEBEER, D. J. N. **Optimal control for a Formula One car with variable parameters**. Oxford: University of Oxford, 2014.

PIRELLI MOTORSPORT. **Formula 1 tyres and compounds guide**. Milão, 2025.

URDHWARESHE, A. **The use of machine learning in predicting Formula 1 race outcomes**. Preprints.org, 2025. DOI: <https://doi.org/10.20944/preprints202504.1471.v1>.

WEST, W. J.; LIMEBEER, D. J. N. **Optimal tyre management of a Formula One car**. IFAC PapersOnLine, v. 53, n. 2, p. 14456–14461, 2020. DOI: <https://doi.org/10.1016/j.ifacol.2020.12.1446>.