

Algoritmo da Calculadora de Carreira Itamaraty

Loreta Guerra* Ricardo Semião† Fábيا Berlatto‡

10 de julho de 2025

Sumário

1	Introdução	2
2	Etapa 1: Previsão de Tempo para Promoção	2
2.1	A Base de Dados	2
2.2	Fundamentos da Modelagem	3
2.3	Especificidades do Modelo	5
2.4	Resultados do Modelo	10
3	Etapa 2: Verificação das Regras	11
3.1	Regras	11
3.2	Regra Limitante	11
3.3	Classe Máxima	12
4	Etapa 3: Previsões Alternativas	12
4.1	Erro do Modelo	12
4.2	Intervalo de Confiança de Previsão	13
4.3	Previsões Alternativas	13
5	Algoritmo no Website	13
5.1	Criação de Variáveis	13
5.2	Cálculo das Previsões Alternativas	14
6	Conclusão	14
	Apêndices	15
A	Dados	15
A.1	Construção da Base Original	15
A.2	Transformação dos Dados	15
B	Coefficientes	15
B.1	Coefficientes Fixos	15
B.2	Coefficientes Dependentes da Promoção	16
C	Detalhes Estatísticos	16
C.1	Pesos da Regressão	16
D	Algoritmo no Website	17
D.1	Setup	17
D.2	Calculadora	22
E	Contribuições dos Autores segundo a taxonomia CRediT	28

*Autora. Mestranda em Economia pela FGV-EESP (loretaguerra@hotmail.com).

†Autor. Mestrando em Economia pela FGV-EESP (ricardo.semiao@outlook.com/[ricardo-semiao.github.io](https://github.com/ricardo-semiao)).

‡Revisora. Pesquisadora de Pós-doutorado em Administração Pública e Governo pela FGV-EAESP, Múnus Social Data (fabia@munussocialdata.com.br/www.munussocialdata.com.br).

1 Introdução

Este documento expõe o processo de construção da calculadora de carreira dos diplomatas brasileiros. O instrumento foi concebido para que os diplomatas recebam uma estimativa do tempo de permanência em cada classe e o limite de alcance de suas carreiras.

O trabalho agrega: um modelo estatístico que prevê o tempo esperado entre cada promoção¹, condicionado às características pessoais de um diplomata; um algoritmo que retorna a classe máxima associada, bem como possíveis cenários alternativos; e uma visualização interativa dos resultados por meio de um website.

A calculadora baseia-se em um amplo conjunto de conhecimentos provenientes de diversas fontes: a análise de entrevistas com 60 diplomatas realizadas no âmbito da Pesquisa Perfil Sociográfico e Estudo da Carreira Diplomática Brasileira (2023), que permitiu mapear elementos informais na dinâmica do MRE; a análise da regulamentação das promoções, que trouxe os critérios formais; e a base de dados composta pelas trajetórias de carreira de cada diplomata ativo em 2022 – sendo as mais longas iniciadas em 1971 –, que permitiu a identificação de padrões históricos e tendências temporais associadas à carreira.

Esse conjunto de dados serviu de base para a construção de um modelo de regressão linear Bayesiana que retorna a direção e a magnitude do efeito médio de cada uma das várias variáveis de interesse presentes no banco. Entre elas, citam-se o sexo, a idade de entrada, o ano de ingresso, a passagem por Embaixadas, pelos gabinetes da Presidência da República (PR), do Ministro de Estado (ME) e da Secretaria Geral (SG), e por Missões Permanentes em Organismos Multilaterais. Assumindo que a atual conjuntura normativa seja mantida, o modelo é capaz de extrapolar para o futuro as tendências temporais encontradas no histórico das promoções. As estimativas temporais são, então, utilizadas para criar uma previsão da dinâmica de carreira individual do usuário, indicando quanto tempo passará em cada classe e o alcance de sua carreira, considerando as regras vigentes para promoção, aposentadoria compulsória e passagem ao Quadro Especial.

Destacamos que a calculadora se baseia na estrutura mais recente da carreira para identificar barreiras (ano de ingresso, idade ou tempo em cada classe, passagem por determinados postos etc.) que potencialmente impedem o diplomata de avançar na hierarquia. Também é importante ressaltar que a capacidade de previsão tem seus limites, pois toda previsão estatística tem uma margem de erro associada. Assim, essa calculadora indica tendências temporais e estimativas, não previsões certas, já que as variáveis que podem influenciar o futuro são diversas e mutáveis. Sempre existe um componente de incerteza na estimativa, tal como ocorre em previsões das ciências naturais, por exemplo. Contudo, é possível calcular também os desvios dos cenários principais resultantes do modelo. Para isso, observamos a média da diferença entre as previsões para estimar quão pior um cenário pode ser, o que informa a possibilidade de maiores atrasos na carreira. Portanto, a calculadora não é um instrumento preditivo perfeito, mas o esforço para sua construção é bem embasado tanto na qualidade dos dados empíricos, quanto em termos estatísticos. A parcimônia no momento de inferência das estimativas e previsões foi uma das maiores preocupações.

A Figura 1 apresenta o fluxo e as conexões entre as fases da construção da calculadora.

A modelagem estatística e a construção do algoritmo foram realizadas pelos economistas Loreta Guerra e Ricardo Semião, autores deste texto. A interface do instrumento foi desenvolvida em conjunto com a equipe de comunicação da ADB. Várias rodadas de validação ocorreram em reuniões entre os estatísticos, a consultoria Múnus Social Data e diplomatas de diferentes classes. Veja mais detalhes no Apêndice E.

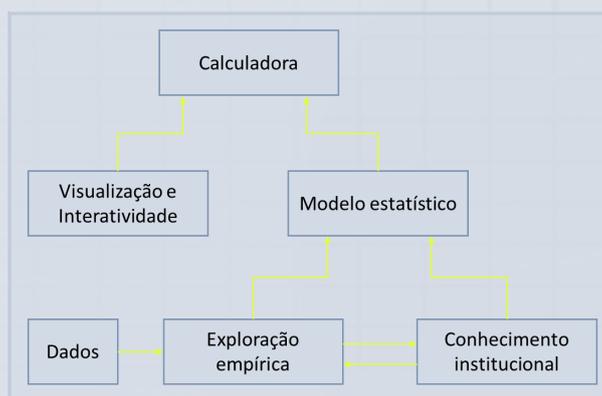
2 Etapa 1: Previsão de Tempo para Promoção

2.1 A Base de Dados

Os dados foram coletados em 2022 junto à administração do MRE. Essas informações foram sistematizadas em uma planilha Excel pela consultoria Múnus Social Data em conjunto com a Pythonic Café. Nela, todos os diplomatas ativos no ano de 2022 tiveram registradas as suas características pessoais e seu histórico no Itamaraty em uma única linha. A Tabela 1 apresenta esse modelo. Repare que cada linha

¹Terceiro Secretário (TS) para Segundo Secretário (SS), Segundo Secretário para Primeiro Secretário (PS), Primeiro Secretário para Conselheiro (C), Conselheiro para Ministro de Segunda Classe (MSC), Ministro de Segunda Classe para Ministro de Primeira Classe (MPC).

Figura 1: Insumos da calculadora



apresenta o tempo que a(o) diplomata permaneceu como ‘TS / SS / PS’ em colunas diferentes. Ou seja, cada diplomata é uma observação (uma linha).

Tabela 1: Esquema dos dados originais²

Diplomata	Classe atual	Tempo como TS	Tempo como SS	Tempo como PS	Sexo
Pessoa A	C	10	12	16	M
Pessoa B	PS	8	14	NA	F
Pessoa C	SS	8	NA	NA	F
Pessoa D	TS	NA	NA	NA	M

Foi necessário fazer uma transformação na planilha. A Tabela 2 mostra o novo modelo. Nele, cada promoção abre uma nova linha para o mesmo diplomata. Ou seja, uma(um) diplomata que recebeu três promoções (de TS a C) ganha três linhas. Isso é necessário porque os diplomatas diferem entre si no número de promoções que já receberam. Mais informações sobre a origem e natureza dos dados, bem como sobre as transformações realizadas na estruturação da planilha, podem ser encontradas no Apêndice A.

Tabela 2: Esquema dos dados transformados²

Diplomata	Promoção	Tempo	Sexo
Pessoa A	TS a SS	10	M
Pessoa A	SS a PS	12	M
Pessoa A	PS a C	16	M
Pessoa B	TS a SS	8	F
Pessoa B	SS a PS	14	F
Pessoa C	TS a SS	8	F

2.2 Fundamentos da Modelagem

Nessa seção, apresentamos o modelo de forma mais teórica, com os conceitos da estatística elementar que o embasam. Destacamos que a base do modelo, uma a regressão linear, é um constructo comum e fundamental da modelagem estatística.

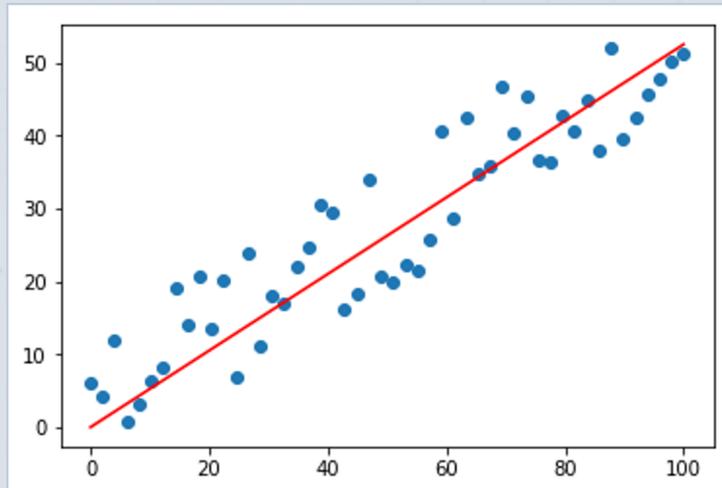
Com a base de dados estruturada como na Tabela 2, já é possível estimar um modelo de previsão simples. Por exemplo, selecionar apenas observações associadas às promoções de ‘TS a SS’ e realizar uma regressão linear³, relacionando ‘Tempo’ (variável dependente) com ‘Idade’ (variável explicativa). Isso nos daria uma previsão do tempo que um diplomata levará para receber a promoção de TS a SS condicional à sua idade.

²“Tempo” medido em semestres. Valores NA significam “não aplicável”, indicando que a(o) diplomata não recebeu aquela promoção ainda.

³A regressão linear é o modelo mais elementar da estatística, veja mais detalhes [na Wikipedia](#).

Veja a Figura 2, imagine que o eixo Y é tempo de promoção e X, a idade. O modelo de regressão assume que o tempo de promoção é uma função linear da idade, uma reta. A estimação do modelo é uma cálculo matemática que encontra a melhor reta possível que se ajuste ao conjunto de dados considerado - mais precisamente, os melhores coeficientes associados a essa reta/função linear que reduzem a distância média dos dados pontuais até ela.

Figura 2: Regressão linear⁴



Nosso modelo é mais sofisticado que uma regressão linear simples univariada. Primeiro porque utilizamos muitas variáveis, embora isso não mude o conceito básico de ‘procurar’ a melhor função linear. Mas especialmente porque não fazemos uma regressão separada para cada promoção. Para explicar nossa modelagem, introduziremos a notação matemática necessária:

$$Tempo_i = \beta_0 + \beta_{Prom}Prom_i + \beta_{VarA}VarA_i + \beta_{VarB}VarB_i + \dots + \epsilon_i$$

Onde:

- i denota cada observação em nossa base, isto é, cada promoção. Imagine que i receba valores como “Pessoa A, TS a SS”, “Pessoa A, SS a PS”, etc. Isto é, temos uma equação para cada promoção.
- Em cada equação, $Tempo_i$ é o tempo que a promoção i levou para ser recebida, $Prom_i$ denota qual é a promoção associada à observação i (ex: “TS a SS”), e $VarA_i$, $VarB_i$, ... são outras variáveis incluídas no modelo.
- ϵ_i é o erro do modelo. Estamos dizendo que o tempo que cada promoção leva pode ser explicado por um cálculo – mais especificamente, por uma combinação linear de variáveis. Contudo, a realidade é mais complexa, e há fatores que não conseguimos medir; esses fatores são capturados pelo erro ϵ_i .
- Os coeficientes β são os parâmetros do modelo, os valores que queremos ‘descobrir’. São valores que indicam qual é o efeito, positivo ou negativo e sua magnitude, de cada variável no tempo médio de promoção.
 - β_0 é o intercepto/constante, ele captura o tempo ‘base’ que todas as promoções demoram. Ele é o tempo médio quando todas as outras variáveis são zero.
 - β_{VarA} é o coeficiente associado à variável $VarA$. Note que β_{Prom} está em negrito, isso será explicado a seguir.

2.2.1 Obtendo Previsão de Cada Promoção

A variável $Prom_i$ é categórica, isto é, pode receber um de cinco valores possíveis, um para cada promoção. No modelo de regressão esse tipo de variável é chamada *dummy*, e temos uma para cada promoção. Cada *dummy* recebe valor 1 quando a linha corresponde àquela categoria de promoção e 0 em todos os outros casos. Portanto, β_{Prom} é um vetor de coeficientes:

$$\beta_{Prom}Prom_i = \beta_{TSaSS}\{Prom_i = TSaSS\} + \dots + \beta_{MSCaMPC}\{Prom_i = MSCaMPC\}$$

⁴Fonte: ML Explained

Essa prática é padrão em modelos de regressão. É a melhor maneira de incluir variáveis categóricas. Com base nisso, para cada diplomata, podemos calcular o tempo esperado que levará para ele receber a promoção analisada, ativando uma variável *dummy* por vez. Isto é, para uma(um) diplomata com dados valores de $VarA$, $VarB$, etc., os cinco tempos esperados são:

$$\begin{array}{l} \beta_0 + \beta_{TSaSS} \cdot 1 + \beta_{VarA} VarA + \beta_{VarB} VarB + \dots + \epsilon_i \\ \beta_0 + \beta_{SSaPS} \cdot 1 + \beta_{VarA} VarA + \beta_{VarB} VarB + \dots + \epsilon_i \\ \beta_0 + \beta_{PSaC} \cdot 1 + \beta_{VarA} VarA + \beta_{VarB} VarB + \dots + \epsilon_i \\ \beta_0 + \beta_{CaMSC} \cdot 1 + \beta_{VarA} VarA + \beta_{VarB} VarB + \dots + \epsilon_i \\ \beta_0 + \beta_{MSCaMPC} \cdot 1 + \beta_{VarA} VarA + \beta_{VarB} VarB + \dots + \epsilon_i \end{array}$$

Com esse modelo básico, temos apenas uma regressão que estima o tempo esperado das cinco promoções, o que é muito mais prático do que fazer cinco regressões separadas. Gera-se coeficientes e previsões muito mais eficientes⁵.

2.2.2 Estimação do Modelo

Falta apenas entender como ‘descobrimos’ os valores dos coeficientes β . Fazemos um cálculo padrão na estatística. Mais detalhes podem ser encontrados na [Wikipédia](#) ou outras fontes, mas abaixo explicamos de forma simplificada.

Organizamos todos os parâmetros em um vetor β , e todas as variáveis em uma matriz X (ou seja, ‘empilhamos’ todas as equações), de modo que o modelo pode ser reescrito de maneira matricial:

$$\begin{array}{l} Tempo = X\beta + \epsilon \\ \beta := (\beta_0, \beta_{Prom}, \beta_{VarA}, \beta_{VarB}, \dots)' \\ X := \begin{bmatrix} 1 & Prom_{PessoaA,TSaSS} & VarA_{PessoaA,TSaSS} & VarB_{PessoaA,TSaSS} & \dots \\ 1 & Prom_{PessoaA,SSaPS} & VarA_{PessoaA,SSaPS} & VarB_{PessoaA,SSaPS} & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & Prom_{PessoaC,TSaSS} & VarA_{PessoaC,TSaSS} & VarB_{PessoaC,TSaSS} & \dots \end{bmatrix} \end{array}$$

Então realizamos um cálculo matricial específico, que gera os coeficientes que melhor aproximam $Tempo$ como uma combinação linear de X . É o mesmo cálculo que encontrava a reta na Figura 2, mas agora em versão matricial, que permite a inclusão de múltiplas variáveis no modelo. A fórmula do cálculo está apresentada abaixo. A notação $\hat{}$ indica que o valor é estimado, isto é, o valor que encontramos a partir do ajuste estatístico dos dados.

$$\hat{\beta} = (X'X)^{-1}X'Tempo$$

As etapas de manipulação dos dados, definição de quais variáveis incluir e estimação do modelo, foram feitas usando a linguagem de programação R.

2.3 Especificidades do Modelo

Vistos os fundamentos, podemos apresentar o modelo de forma mais detalhada. A partir deste ponto, começaremos a introduzir decisões motivadas pelo conhecimento institucional sobre a carreira diplomática.

2.3.1 Arredondamento

Uma especificidade simples é o arredondamento feito no resultado final. Como não é possível ser promovido em “11.3” semestres, por exemplo, o resultado final é o valor predito arredondado para cima. Esse arredondamento considera o próximo valor inteiro (‘para cima’) porque assumimos que a partir do momento que uma(um) diplomata completa o tempo esperado em dada classe: ou é promovida(o) nesse momento, caso seja um número inteiro de semestres; ou precisa completar o semestre ‘quebrado’, esperando até o próximo processo de promoção no semestre seguinte.

⁵A eficiência é uma propriedade estatística. Reflete a ‘estabilidade’ do modelo, ou seja, o quanto variariam os resultados se os dados fossem ligeiramente diferentes. Quanto menor essa variação, mais eficiente o modelo.

Outra opção seria utilizarmos uma regressão não linear que já incorporasse a função de ‘teto’ (arredondar para cima) na hora de estimar os coeficientes. Essa abordagem geraria melhorias na precisão do modelo, mas em detrimento da inclusão do ajuste Bayesiano, o que julgamos ser mais importante.

2.3.2 Variáveis do Modelo

Agora detalharemos as variáveis incluídas no modelo. Os nomes das variáveis são os mesmos que foram utilizados no código.

Variáveis básicas:

- **Promocao** - Variável categórica que indica qual é a promoção associada à observação.
- **TempoLag** - Tempo que a(o) diplomata levou para receber a promoção anterior. Diplomatas que estão recebendo promoções mais rápidas tendem a continuar nessa tendência e vice-versa.
- Interação entre **Promocao** e **TempoLag** - interagir variáveis⁶ permite que o efeito de uma variável dependa do valor da outra e vice-versa. Nesse caso, ter sido adiantado como TS a SS gera um efeito diferente do que ter sido adiantado como SS a PS, por exemplo.

Variáveis individuais:

- **SexoMasculino** - Variável categórica que indica se a(o) diplomata é do sexo masculino. Homens no Itamaraty tendem a receber promoções mais rapidamente, especialmente na passagem para MSC.
- Interação entre **SexoMasculino** e **Promocao** - A tendência acima nem sempre se aplica. Em algumas promoções, como para SS, a diferença entre homens e mulheres é menor, como esperado.
- **IdadeEntrada** - Captura possíveis efeitos de discriminação (positiva ou negativa) por idade. Idade de entrada na carreira se mostrou mais relevante do que a idade atual.
- **IdadeEntrada²** - O efeito acima não é linear, pessoas de meia idade têm efeito diferente de pessoas mais velhas ou jovens. A inclusão do termo ao quadrado captura essa não-linearidade do efeito etário.
- Interação entre **IdadeEntrada** e **Promocao** - Outra interação que captura o efeito de idade de entrada em cada promoção. MSC são no geral muito experientes, de modo que idade importa menos nessa promoção, por exemplo.

Variáveis geográficas:

- **Capital** e **GrandeRegiao** - Capturam possíveis efeitos de discriminação geográfica.

Variáveis de formação:

- **FormacaoArea**, **FormacaoNivel**, e **FormacaoNatureza** - Capturam possíveis efeitos relacionados à formação acadêmica, incluindo área e a natureza da instituição de ensino (pública ou privada).

Variáveis de ocupação e experiência:

- **Gabinete**, **Missao**, **Embaixada**, **Consulado** e **ConsuladoGeral**⁷ - Ter servido em algum desses espaços costuma acelerar promoções de diplomatas, especialmente os gabinetes.
- Interação de **Gabinete**, **Missao** e **Embaixada** com **Promoção** - Essa experiência é mais relevante no meio da carreira, onde o currículo importa mais.

Para mais informações sobre como a base de dados original foi criada, e como as variáveis foram transformadas, veja o Apêndice A.

Note que até este ponto, o modelo é uma regressão linear bastante comum, próximo do que se mostrou na Seção 2.2. Apenas adicionamos algumas variáveis e interações entre elas, mas a motivação para sua inclusão é bastante clara e não controversa. Isto é, temos um modelo pouco sensível às decisões de modelagem tomadas até aqui. Porém, falta um último conjunto de variáveis, as que capturarão as tendências temporais e geracionais.

Para chegar no modelo final, foi preciso incluir três últimas características. A primeira é um detalhe mais técnico, com uma motivação mais concreta e indisputável, vide o Apêndice 9. As outras duas são

⁶Interações são incluídas no modelo via uma nova variável, o produto entre as variáveis interagidas. Essa variável recebe seu próprio coeficiente. Neste documento, denotaremos interações pelo símbolo : (ex: **Promocao:TempoLag**).

⁷Por ‘Missão’ entenda Missão Permanente em Organismos Multilaterais, e ‘Gabinete’ se refere especificamente aos gabinetes da Presidência da República, do Ministro de Estado e da Secretaria Geral.

mais complexas, envolvem conhecimento institucional e são mais sensíveis às decisões de modelagem. Por merecerem mais escrutínio, foram as que receberam mais atenção e parcimônia.

2.3.3 Tendências Temporais e Geracionais

As tendências temporais e geracionais são características do modelo que permitem incorporar o fenômeno do descompasso entre a quantidade de vagas nas classes e o volume de diplomatas que entram na carreira. Este descompasso foi verificado empiricamente e se mostrou crescente nos anos recentes. Contribuem para isso a nova idade para a aposentadoria compulsória, alterada pela Emenda Constitucional nº 88, de 2015, e as chamadas ‘turmas de 100’, processos que, sem o acompanhamento de mudanças estruturais, acabaram comprometendo o fluxo de abertura de vagas nas etapas da carreira. Isso inclui tanto o Quadro Ordinário quanto o Quadro Especial. As mudanças descritas, desacompanhadas da criação de novas vagas, ‘prendem’ os diplomatas nas primeiras classes. Esse comprometimento da ascensão se dá pela falta de vagas disponíveis e não pelo não cumprimento dos critérios de promoção.

Dada tal conjuntura, a ascensão classe a classe demora cada vez mais para ocorrer. A ideia da tendência temporal é justamente modelar o aumento no tempo esperado entre promoções. Conforme explicamos acima, os dados históricos mais recentes são os mais importantes para extrapolar a estimativa da ‘piora’ no futuro, caso nada na estrutura da carreira mude. Realizar essa extrapolação é um desafio estatístico, pois exige cautela para evitar estimativas superestimadas ou subestimadas. Por isso, foi necessário modelar as tendências de maneira parcimoniosa e tomar cuidado com a escolha das variáveis. O ajuste bayesiano, discutido na Seção Seção 2.3.4, também tem por objetivo aprimorar essas estimativas, incorporando ao modelo as tendências conhecidas a partir do conhecimento institucional sobre a progressão na carreira.

A escolha das variáveis corretas é essencial para uma modelagem precisa das tendências temporais. Testamos algumas variáveis relacionadas a aspectos temporais: o ano da promoção avaliada (**AnoPromocao**), o ano de entrada na carreira (**AnoEntrada**), o ano de nascimento do diplomata (**AnoNascimento**), a idade que tinha ao entrar na carreira (**IdadeEntrada**), e a idade que tinha na promoção avaliada (**IdadePromocao**). A variável mais relevante para capturar efeitos temporais comuns a todos os promovidos foi a de ano de promoção. Percebemos que essa é a variável que incorpora as tendências temporais de maneira mais clara. A Figura 3 mostra como as demais variáveis se comportam em relação ao ano de promoção, indicando um claro aumento do tempo médio para ser promovido com o passar do tempo. As demais variáveis capturam componentes individuais dos diplomatas, e não tanto efeitos temporais compartilhados. A variável ‘IdadeEntrada’ é a que tem maior peso explicativo entre as características individuais, razão pela qual foi incluída no modelo a nível e ao quadrado, com o intuito de controlar por variações não lineares no seu efeito sobre o tempo de promoção. As demais variáveis não foram incluídas para evitar problemas de multicolinearidade⁸. Assim, foram selecionadas: para captar tendências temporais gerais, o ano de promoção; e, para representar características individuais relacionadas ao tempo, a idade de entrada – considerada tanto a nível quanto ao quadrado.

O último passo, então, foi criar algumas variáveis para capturar os conhecimentos institucionais relevantes sobre a saturação da carreira e o decorrente aumento no tempo médio esperado entre promoções. **AnoPromocao**, em si, captura as tendências temporais gerais, como explicado acima. Criamos uma variável para refletir o aumento da idade de aposentadoria, a **MaxAposentadoria**, uma dummy com progressão gradual. Ela indica se a promoção ocorreu antes ou depois da idade máxima de aposentadoria ter sido alterada. Também criamos a **Turmas1Tamanho**, cujo valor é o tamanho aproximado da turma de Terceiras(os) Secretárias(os) de cada ano.

O tamanho de turma gera uma certa separação nas ‘gerações’ do Itamaraty. Contudo, vimos que uma definição ligeiramente diferente de gerações se correlacionava mais com **AnoPromocao**. Dessa forma, a variável indicadora **Turmas2** é incluída para representar essas gerações ‘diferentes’ a partir da motivação empírica. Uma interação entre **AnoPromocao** e **Turmas2** é também considerada para permitir tendências temporais diferentes para cada geração.

Os valores dos efeitos esperados para cada uma dessas variáveis vão ser melhor descritos na Seção 2.3.4. O resultado é apresentado abaixo:

Até este ponto, explicamos quais variáveis são suficientes para modelar as tendências temporais e capturar o conhecimento institucional sobre a saturação da carreira. Essa parte do modelo é essencial para as

⁸Multicolnearidade é uma característica em modelos estatísticos que incluem variáveis muito similares, sem trazer poder explicativo adicional, algo que acaba diminuindo a eficiência do modelo e atrapalhando (ou até mesmo impedindo) a estimativa.

Figura 3: Variáveis temporais

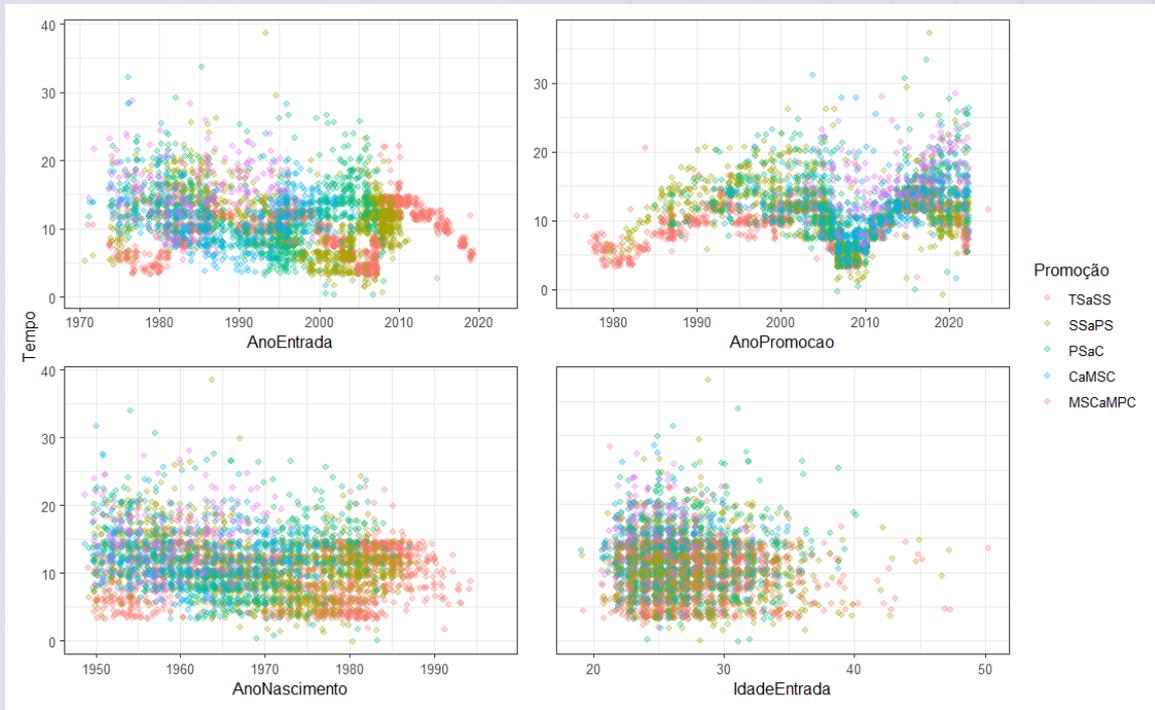
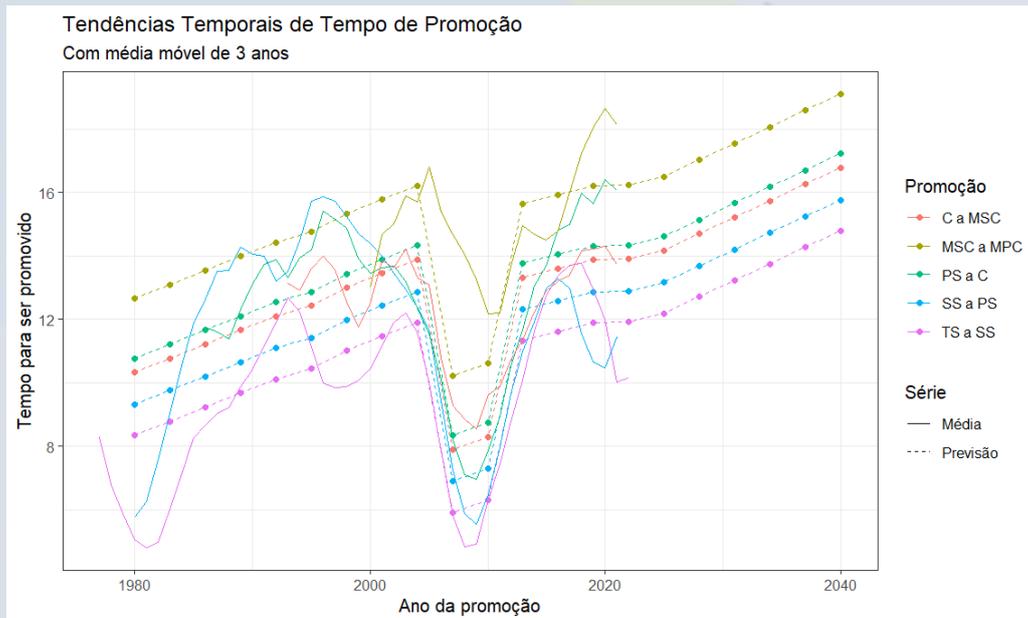


Figura 4: Tendências temporais



previsões, pois conseguimos extrapolar o comportamento do tempo médio de promoção e estimar a progressão de carreira com base nas características pessoais, fundamental na proposta da calculadora individual da carreira diplomática.

A calibração das tendências temporais, feita a partir do cenário de 2025, implica que a calculadora perde progressivamente sua acurácia conforme o tempo passa, mas é factível atualizar o modelo com novos dados e recalibrar as tendências no futuro.

2.3.4 Ajuste Bayesiano

O Ajuste Bayesiano em uma regressão linear é uma forma de incorporar algum tipo de conhecimento prévio sobre os parâmetros do modelo, isto é, o efeito de cada variável⁹, à estimação. Ao invés de supor que tudo deve ser aprendido do zero a partir dos dados, como se faz na abordagem clássica, o método Bayesiano permite começar com uma crença inicial, a ‘distribuição *a priori*’, sobre os coeficientes da regressão. Depois, essa crença é atualizada à luz dos dados observados, o que resulta em uma ‘distribuição *a posteriori*’, da qual derivamos as estimativas finais dos coeficientes do modelo.

Essa abordagem é particularmente útil para os objetivos da calculadora de carreira, pois permite incorporar o conhecimento institucional disponível sobre como os padrões mais recentes de promoção têm sido influenciados pelo descompasso entre volume de diplomatas e número de vaga nas classes. O Ajuste Bayesiano é especialmente útil em contextos com poucos dados ou alta incerteza, pois tende a produzir estimativas mais estáveis e cautelosas, evitando conclusões extremas baseadas em flutuações aleatórias dos dados.

Nós utilizamos o ajuste em quatro componentes do modelo: o intercepto, o efeito de **AnoPromocao**, e as duas interações entre **AnoPromocao** e **Turmas2**. Esses ajustes foram incluídos para conferir maior parcimônia à modelagem temporal. A extrapolação de tendências temporais, sem restrições, pode gerar valores explosivos no futuro, bem como um intercepto com uma escala pouco interpretável. Para mitigar esse risco, incorporamos crenças informadas sobre os valores esperados/plausíveis desses parâmetros.

As crenças adotadas no ajuste bayesiano foram expressas sob a forma de distribuições normais: ‘O efeito segue uma distribuição normal com média a e variância b ’. A escolha da distribuição normal é comum nesse tipo de modelagem. A média a é o valor esperado atribuído previamente ao parâmetro, enquanto a variância b reflete o grau de incerteza em torno dessa expectativa. Variâncias menores indicam maior confiança na crença inicial, reduzindo a influência dos dados observados sobre a estimativa final. Já variâncias maiores atribuem mais peso aos dados empíricos na atualização do coeficiente. As crenças que utilizamos foram as seguintes:

- O ajuste no intercepto foi feito para mantê-lo próximo de um valor base de 9 semestres, o valor do modelo pré-Bayesiano sem tendências temporais. Já os efeitos das tendências temporais foram ajustados para manter valores pequenos em termos absolutos.
- A tendência temporal média via **AnoPromocão** foi deixada em +0.5 semestres a cada ano.
- A tendência adicional para as turmas de 2004 a 2012 foi ajustada para zero, pois são turmas que sofrem efeitos positivos e negativos, então demos mais liberdade para os dados definirem o valor.
- Já para as turmas de 2013 em diante, escolhemos uma tendência menor (-0.2 semestres), para evitar os valores explosivos que poderiam ocorrer caso não houvesse esse ajuste. A Tabela 3 resume os ajustes feitos.
- Atribuímos alta variância ao coeficiente associado às turmas de 2004 a 2012, uma vez que esse coeficiente é um dos principais mecanismos de ajuste do modelo aos dados e o efeito dessa coorte era incerto. Para as outras duas variáveis, mantivemos a variância baixa.
- Todos os outros efeitos tiveram sua média mantida como o valor da regressão linear simples pré-Bayesiana, e uma alta variância de 2.5, para permitir que o modelo ajuste-os quase livremente.

A Tabela 3 resume os ajustes realizados. A última coluna apresenta os valores finais estimados para os coeficientes. Os resultados são satisfatórios: as variáveis permaneceram próximas dos valores esperados, com exceção do intercepto, cujo desvio não compromete a qualidade do modelo.

⁹Mais informações sobre a abordagem Bayesiana podem ser encontradas na [Wikipedia](#).

Tabela 3: Priors do modelo Bayesiano

Efeito	Média	Variância	Valor a posteriori
Intercepto	9	0.75	2.359
AnoPromocao	0.5	0.01	0.418
AnoPromocao:Turmas2T2	0	0.2	0.132
AnoPromocao:Turmas2T3	-0.2	0.01	-0.189
Outros	β_{OLS}	2.5	

2.4 Resultados do Modelo

O modelo gera previsões que parecem estar alinhadas com a vivência da carreira e tendências futuras. Além disso, os coeficientes do modelo são interpretáveis e informativos. Encontramos resultados muito interessantes que confirmaram algumas crenças prévias, mas também trouxeram novos conhecimentos sobre como as características individuais influenciam no tempo dispendido entre classes. Ademais, como separamos as variáveis por promoção, conseguimos ver uma heterogeneidade desses efeitos entre as classes.

Pela forma como estruturamos a análise, efeitos negativos indicam que a característica em questão facilita a promoção no geral ou entre classes, dado que um coeficiente negativo indica que o número de semestres para a promoção é menor quando a *dummy* da característica assume valor 1. Os resultados de todas as variáveis consideradas, tanto dos coeficientes fixos quanto dos específicos a cada promoção, estão disponíveis nas tabelas do Apêndice B.

Vale ressaltar que esses efeitos não permitem inferência causal sobre o efeito de cada característica no tempo de promoção, apenas indicam correlações. Essas relações sugerem que ter uma dada característica está associado com uma previsão de promoção mais rápida ou mais demorada, mas não necessariamente que essa característica em si causa tal diferença.

2.4.1 Magnitude Geral das Previsões

A Tabela 4 mostra os resultados médios do modelo, isto é, as previsões geradas a partir das características médias¹⁰ dos dados. Cada linha indica o tempo estimado para uma determinada promoção em um dado ano.

Tabela 4: Magnitude das previsões de tempo de promoção

Ano Promocao	Média	TS a SS	SS a PS	PS a C	C a MSC	MSC a MPC
1990	7.1	5.2	5.9	7.5	7.1	9.8
2000	9.4	7.5	8.2	9.8	9.4	12.1
2010	11.7	9.8	10.5	12.1	11.7	14.3
2020	14.0	12.1	12.8	14.4	14.0	16.6
2030	16.3	14.4	15.1	16.7	16.3	18.9
2040	18.6	16.6	17.4	19.0	18.6	21.2
2050	20.8	18.9	19.7	21.2	20.9	23.5

O modelo reproduz adequadamente as relações esperadas entre os diferentes momentos de promoção na carreira. A promoção de TS a SS é a mais rápida, enquanto a de MSC a MPC é a mais lenta. Destaca-se ainda que a passagem de PS a C tende a demorar mais do que a de C a MSC, um resultado possivelmente associado ao Curso de Altos Estudos.

Cabe observar que a Tabela 4 evidencia as tendências temporais incorporadas pelo modelo. Os tempos médios para promoção em 1990 aparecem significativamente mais baixos, o que se deve ao fato de o modelo ter sido calibrado para maior precisão a partir de 2020. Os resultados do período de 2020-2030 mostram valores previstos que se aproximam do cenário atual; no entanto, caso persista a tendência recente de saturação de vagas, projeta-se um agravamento expressivo nos tempos para promoção nas próximas décadas.

¹⁰Média aritmética para características numéricas e moda para variáveis categóricas.

2.4.2 Efeitos das Variáveis

Alguns resultados dos coeficientes fixos evidenciam crenças previamente formuladas sobre a carreira: o gênero masculino, por exemplo, apresentou coeficiente negativo, o que indica que, em média, os homens são promovidos mais rapidamente em comparação às mulheres. O mesmo padrão foi observado para a variável que captura a passagem em Gabinete da PR, ME e SG e idade de entrada, indicando que diplomatas que ingressam na carreira em idade mais avançada e que passaram por esses gabinetes tendem a ser promovidos em menor tempo. Outros resultados, contudo, destoaram das expectativas iniciais: a passagem por Consulados, Missões em Organismos Multilaterais e Embaixadas, por exemplo, está associada a um aumento no tempo médio entre promoções.

Os resultados do modelo não serviram apenas como base para toda a lógica da calculadora individual, como também revelaram aspectos interessantes sobre o funcionamento da carreira diplomática. Confirmaram efeitos esperados de determinadas características na progressão e evidenciaram variações importantes desses efeitos conforme a promoção analisada – uma heterogeneidade que oferece subsídios para investigações mais detalhadas futuramente.

3 Etapa 2: Verificação das Regras

Com o modelo pronto, já é possível gerar as previsões de tempo para cada promoção. O passo seguinte consiste em calcular a classe máxima alcançável, dadas essas estimativas. É importante observar que a regressão, por si só, não incorpora as regras institucionais, ela apenas projeta os tempos de promoção com base nos dados. Por isso, é necessário verificar, a cada etapa da progressão, se as projeções violam algum critério normativo.

3.1 Regras

As regras da carreira têm uma forma condicional: “se determinada variável ultrapassar um limite específico, o diplomata será aposentado ou transferido para o Quadro Especial (QE)”. A transferência para o QE implica, na prática, em chances residuais de promoção, razão pela qual consideramos esse evento como o ponto final da carreira.

A Tabela 5 resume as regras da carreira diplomática.

Tabela 5: Regras da carreira diplomática

Promoção	TS	SS	PS	C	MSC	MPC
QE: idade máxima	-	-	-	58	60	65
QE: t. de classe máximo	-	22	24	30	30	30
Aposentadoria: idade máxima	75	75	75	75	75	75
T. de carreira mínimo	0	0	0	10	15	20
T. classe mínimo	0	3	3	3	3	3

As regras referentes ao tempo mínimo de carreira e de permanência nas classes, especialmente no contexto atual, raramente operam como fatores limitantes - ou seja, os diplomatas tendem a permanecer mais tempo do que mínimo exigido para cada promoção. No caso dos diplomatas atualmente em atividade, nenhuma das previsões ficou abaixo desses tempos mínimos. Assim, por simplicidade e sem prejuízo à acurácia do modelo, optamos por não incorporar essas restrições.¹¹

3.2 Regra Limitante

Começamos calculando a idade do diplomata ao ser promovido com base na data de nascimento fornecida pelo usuário, e somando os tempos previstos de promoção desde o primeiro dia do semestre atual¹².

Em seguida, verificamos se a idade ultrapassou a idade máxima do QO ou de aposentadoria, ou se a previsão ultrapassou o tempo máximo de classe do QO.

¹¹Não é difícil criar um modelo cuja previsão seja o mínimo entre a projeção da regressão e o mínimo necessário, só não é necessário para o caso atual.

¹²A data atual é dinâmica, isto é, o algoritmo sempre utiliza a data do dia em que o usuário acessa a calculadora.

Se alguma regra foi quebrada, calculamos a idade que o diplomata teria no momento da quebra:

- Aposentadoria: 75 anos, sempre.
- QE por idade: 58 anos para C, 60 anos para MSC, e 65 anos para MPC.
- QE por tempo de classe: a idade na promoção passada, mais o tempo de classe máximo permitido para a promoção atual (22 semestres para SS, 24 para PS, 30 para C, MSC e MPC).

Com base nisso, descobrimos qual ocorreria primeiro, e essa é a regra reportada como limitante ao avanço da carreira.

3.3 Classe Máxima

Com base na regra limitante e na promoção que o diplomata estaria prestes a receber, é possível determinar a classe máxima que ele alcançaria. Na maioria dos casos, se o diplomata ultrapassa algum dos limites previstos, ele é aposentado ou transferido para o Quadro Especial (QE) na classe atual – ou seja, antes da promoção –, encerrando sua progressão. Nesses casos, a classe máxima é a classe em que ele se encontrava imediatamente antes da transição.

Há, contudo, uma exceção importante: diplomatas nas classes de Segundo Secretário (SS) e Primeiro Secretário (PS) que são transferidos para o QE recebem uma ‘promoção diagonal’. Isso significa que entram no QE já na classe imediatamente superior – PS do QE, se eram SS; ou C do QE, se eram PS. Nesses casos, a classe máxima considerada é a seguinte à que ocupavam.

4 Etapa 3: Previsões Alternativas

Cabe destacar que os padrões e projeções utilizados representam modelagens estatísticas aproximadas. Ainda que baseadas em dados concretos, elas estão sujeitas a incertezas inerentes à previsão de processos institucionais futuros. A trajetória real de cada diplomata pode, portanto, divergir dos cenários estimados.

Para denotar esta incerteza, o último exercício da calculadora é informar sobre possíveis ‘universos alternativos’: cenários simulados a partir das discrepâncias entre as promoções efetivamente observadas e aquelas previstas pelo modelo. Isso permite informar qual seria o pior caso esperado em $x\%$ dos cenários simulados, oferecendo ao usuário uma noção concreta de quão mais longos os tempos de promoção podem vir a ser.

Em termos formais, com base nos coeficientes estimados $\hat{\beta}$, obtemos nossas previsões \widehat{Tempo} , e então conseguimos medir o resíduo do modelo: $\hat{\epsilon} = Tempo - \hat{\beta}$.

Como $\hat{\epsilon}$ está associado ao erro do modelo, uma grande variabilidade dos resíduos entre observações indica alta incerteza nas estimativas de tempo de promoção – ou seja, uma influência significativa de fatores aleatórios não capturados pelo modelo. Assim, quanto maior a *variância* dos resíduos, menor a confiança nas previsões médias, e mais próxima a realidade pode estar de cenários alternativos plausíveis.

Para compreender exatamente como essas previsões alternativas são construídas, é necessário recorrer a dois conceitos estatísticos aplicados à regressão linear multivariada. Como se trata de um conteúdo mais avançado, sugerimos a aula [Stat 501](#) da Penn State University (PSU) para uma apresentação introdutória na versão univariada.

4.1 Erro do Modelo

Primeiro, como mencionado, o erro do modelo está associado à ideia de que existe uma parte aleatória – ou, ao menos, não explicada pelas variáveis do modelo – que influencia o tempo de promoção. Em outras palavras, o erro ϵ é tratado como uma variável que pode assumir diferentes valores seguindo uma distribuição de probabilidade. No modelo de regressão linear tradicional, assume-se que essa distribuição é normal, com média 0 e variância fixa, mas desconhecida.

O resíduo $\hat{\epsilon}$ pode ser visto como uma estimativa desse erro aleatório, portanto, é utilizado para estimar essa variância desconhecida. Veja abaixo o *desvio padrão*¹³ de uma previsão.

$$se(\hat{y}_h) = \sqrt{\text{MSE}(\mathbf{X}_h^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}_h)}$$

¹³A raiz quadrada da variância.

Onde:

- \mathbf{X} é a matriz de dados do modelo, como explicado na Seção 2.2; e \mathbf{X}_h é o vetor de dados de uma observação (promoção) específica.
- \hat{y}_h é a previsão dessa observação.
- MSE é a média dos quadrados dos resíduos, isto é, $\sum_{i=1}^N \hat{\epsilon}^2$.

Ela pode ser difícil de interpretar, mas note que quanto maiores os resíduos (MSE), maior a variância ($se(\hat{y}_h)$).

4.2 Intervalo de Confiança de Previsão

Agora, considere a fórmula de um *intervalo de confiança de previsão*:

$$IC_\alpha = \hat{y}_h \pm t_{(1-\alpha/2, n-p)} \times \sqrt{MSE + (se(\hat{y}_h))^2}$$

Antes de considerar $t_{(1-\alpha/2, n-p)}$, note que estamos criando um intervalo em torno da previsão \hat{y}_h (somando e subtraindo \pm). O tamanho desse intervalo depende do tamanho do nosso erro MSE e do desvio padrão estimado $se(\hat{y}_h)$.

Queremos que esse intervalo tenha a seguinte interpretação: “O erro ϵ_h varia segundo uma distribuição normal, mas em $x\%$ dos casos, o valor real de y_h estará dentro desse intervalo”.

Esse *nível de confiança* $x\%$ está associado à noção de *valor crítico*, – ou seja, a resposta da pergunta “qual valor cuja chance de ele ser maior que uma variável aleatória é $x\%$?”. Então, escolhamos um valor de $x\%$ (α), e calculamos esse valor $t_{(1-\alpha/2, n-p)}$. Existem alguns outros detalhes, como o fato de utilizarmos uma distribuição *t de Student* e o valor crítico ser o valor associado a um teste bi-caudal, mas não entraremos neles aqui.

4.3 Previsões Alternativas

Separamos os valores de 20%, 60%, 80% e 95%, e para cada observação h , calculamos os intervalos de confiança de previsão correspondentes a cada um desses níveis de confiança. Para cada intervalo, reportamos o valor máximo, de modo a informar qual seria o pior cenário esperado com $x\%$ de confiança.

5 Algoritmo no Website

A aplicação desse algoritmo no [website da calculadora](#) tem algumas peculiaridades. O código em *JavaScript* (JS) que implementa o algoritmo pode ser visto no Apêndice D.

A seguir, explicamos algumas diferenças da implementação do algoritmo no website em relação ao que foi descrito até aqui.

5.1 Criação de Variáveis

O usuário insere suas informações pessoais por meio dos campos do formulário. A partir disso, o modelo precisa “construir” algumas variáveis que se referem ao futuro. Algumas variáveis têm uma definição clara:

- **MaxAposentadoria**: fixado como 1, uma vez que em 2026 a idade máxima de aposentadoria chega no ápice de 75 anos.
- **Turmas1Tamanho**: fixado em 30, uma vez que é o tamanho médio das turmas atualmente.
- **Turmas2T3**: A turma 3 da variável de tendências temporais é a turma ‘do futuro’, logo é a única *dummy* ativada, e recebe o valor 1.

Outras variáveis dependem do próprio tempo de promoção, o que tornaria a construção das previsões mais complexa. Por isso, foram calibradas com valores considerados relevantes no contexto de 2025:

- **AnoPromocao**: o ano de promoção, a variável que baseia as tendências temporais. Utilizamos os tempos médios em que cada próxima promoção se daria, 2030, 2035, 2041, 2047, e 2055.
- **TempoLag**: o tempo da promoção passada, foram fixados nos valores 5, 5, 6, 6, e 8 semestres para as promoções TS a SS, SS a PS, PS a C, C a MSC, e MSC a MPC, respectivamente.

- Interações envolvendo essas variáveis foram criadas de forma similar.

Note que também fazemos as transformações indicadas no Apêndice A nos dados supridos pelo usuário.

5.2 Cálculo das Previsões Alternativas

Lembre que para o cálculo das previsões alternativas, cada promoção precisa ter seu $se(\hat{y}_h)$ calculado. Isto deixaria a calculadora muito lenta, pois envolve inverter a matriz X .

Portanto, nós calculamos para cada nível de confiança α , os valores de \hat{y}_h para todas as observações nos dados. A seguir, calculamos qual seria o tamanho do limite superior intervalo de confiança médio, IC_α^+ , em termos de \hat{y}_h , o que gera um ‘multiplicador’ m_α :

$$m_\alpha = \frac{1}{N} \sum_{h=1}^N \frac{IC_\alpha^+}{\hat{y}_h}$$

Com isso, podemos dizer que, o pior cenário, a α de confiança, é $1 + m_\alpha$ vezes pior do que a previsão média. Deste modo, simplificamos o cálculo dos intervalos de confiança para:

$$IC_\alpha^+ = (1 + m_\alpha) \cdot \hat{y}_h$$

Veja na tabela Tabela 6 os multiplicadores e qual seria o pior cenário associado ao nível de confiança, para uma promoção prevista em 10 semestres.

Tabela 6: Multiplicadores das previsões alternativas

Nível de confiança (α)	Multiplicador (m_α)	Alternativa ($10 \cdot (1 + m_\alpha)$)	Alternativa final
20%	0.07869	10.79	11
60%	0.26184	12.62	13
80%	0.39907	13.99	14
95%	0.61018	16.10	17

6 Conclusão

A calculadora individual resulta da combinação entre modelagem estatística e conhecimento institucional adquirido através de análises qualitativas da carreira e inúmeros testes, até que se alcançasse um modelo robusto, coerente com os dados e com a realidade observada e projetada. A modelagem de tendências temporais, aliada à abordagem Bayesiana, permitiu integrar padrões históricos às limitações recentes na progressão da carreira, conforme compreendida pelos próprios diplomatas.

Com esses resultados foi possível construir um algoritmo que projeta o fluxo individual de carreira e aplica as regras vigentes para determinar a classe máxima alcançável ao longo da trajetória da(o) diplomata.

Apesar de suas limitações, o instrumento oferece uma forma sólida e transparente de informar diplomatas sobre as tendências da carreira e pode contribuir para o debate público sobre sua estrutura.

A estatística aqui não apenas projeta trajetórias individuais, mas também serve como ferramenta de análise institucional para refletir sobre o futuro da carreira diplomática diante de sua atual configuração.

A Dados

A.1 Construção da Base Original

Os dados utilizados no modelo foram extraídos da base sistematizada em 2022 pela Múnus Social Data, em parceria com a Pythonic Café, a partir dos currículos fornecidos pela Administração do MRE. A base organiza informações demográficas e trajetórias de carreira de todos os diplomatas ativos no final do período, abrangendo de 1971 a 2022. Embora os currículos tenham sido atualizados até 2022, os registros individuais remontam a 1971, o que garante uma cobertura ampla e consistente das trajetórias profissionais. O fato dos dados se limitarem a esse intervalo temporal não compromete a acurácia do modelo, uma vez que ele foi calibrado com base nesse universo completo de informações.

A.2 Transformação dos Dados

Com base nesses dados, foram feitas transformações de formato, exemplificadas pelas tabelas 1 e 2. Em seguida, algumas variáveis foram criadas/transformadas:

- Anos foram multiplicados por 2 para que o tempo fosse medido em semestres.
- Variáveis categóricas tiveram “outros” e “sem informação” coletados em apenas uma categoria “outros”, por simplicidade.
- Criação das variáveis de tempo:
 - $\text{AnoPromocao} = \text{AnoEntrada}[1] + \text{cumsum}(\text{Tempo})/2$.
 - $\text{IdadePromocao} = \text{IdadeEntrada} + \text{cumsum}(\text{Tempo})/2$.
 - $\text{TempoLag} = \text{lag}(\text{Tempo}) \%>\% \text{ifelse}(\text{is.na}(\cdot), \text{tempo_mean}, \cdot)$, onde tempo_mean é a média do tempo de todas as promoções, e é colocada como o valor se não houve promoção passada.
- Criação das variáveis de geração:
 - MaxAposentadoria é 0 antes de 2015, 1 após 2026, e entre esses anos é calculada como $\text{trunc}((\text{AnoPromocao} - 2014) * 5 / 10) / 5$, isto é, +0.1 a cada dois anos.
 - Turmas1 recebe um valor para cada intervalo separados pelos cortes $c(0, 1995, 1997, 2004, 2011, \text{Inf})$. Turmas1Tamanho associa um tamanho de turma para cada intervalo, sendo o quinto intervalo o das turmas de 100 diplomatas.
 - Turmas2 é baseado nos cortes $c(0, 2004, 2012, \text{Inf})$.
- Re-centralização das variáveis de idade:
 - IdadeEntrada e IdadePromocao foram subtraídas de 18, a idade mínima de entrada no Itamaraty.
 - AnoEntrada e AnoPromocao foram subtraídos do menor valor de cada observado na base.

B Coeficientes

As tabelas com todos os coeficientes resultantes do modelo (tanto os fixos, quanto dependentes de cada promoção) são expostas abaixo:

B.1 Coeficientes Fixos

Tabela 7: Coeficientes fixos

Variável	Coefficiente
Intercepto	2.35943
MaxAposentadoria	-0.89156
Turmas1Tamanho	-0.06316
Turmas2T3	0.2975
SexoMasculino	-0.00279
IdadeEntrada	-0.03579
IdadeEntrada2	-0.00026
CapitalCapital	-0.55273
CapitalInterior	-0.60701
CapitalExterior	-0.30096
GrandeRegiaoNorte	0.15531

Variável	Coefficiente
GrandeRegiaoNordeste	0.52628
GrandeRegiaoCentroOeste	-0.00108
GrandeRegiaoSudeste	0.42774
GrandeRegiaoSul	0.10605
FormacaoAreaTecnicos	-0.20696
FormacaoAreaHumanisticos	-0.09363
FormacaoNivelEspecializacao	-0.70142
FormacaoNivelMestrado	-0.69549
FormacaoNivelDoutorado	-0.95307
FormacaoNivelGraduacao	-0.27331
FormacaoNaturezaPublica	-0.21747
FormacaoNaturezaPrivada	-0.09857
Gabinete	-0.1392
Missao	0.07437
Embaixada	1.01447
ConsuladoGeral	0.85466
Consulado	0.43769

B.2 Coeficientes Dependentes da Promoção

Tabela 8: Coeficientes dependentes da promoção

Variável	TSaSS	SSaPS	PSaC	CaMSC	MSCaMPC
Promocao	0	6.25419	6.0579	1.95446	10.08716
TempoLag	0.0217	0.0217	0.0217	0.0217	0.0217
Promocao:TempoLag	0	-0.30551	-0.13103	0.10076	-0.05548
AnoPromocao	0.41873	0.41873	0.41873	0.41873	0.41873
AnoPromocao:Turmas2T3	-0.18967	-0.18967	-0.18967	-0.18967	-0.18967
Promocao:SexoMasculino	0	-0.05959	0.01469	0.55869	0.08323
Promocao:IdadeEntrada	0	-0.01403	0.00766	0.01096	-0.34249
Promocao:Gabinete	0	-0.37031	-1.39213	0.02922	-0.65025
Promocao:Missao	0	-0.38989	-0.96711	-0.13057	0.01886
Promocao:Embaixada	0	-1.99767	-1.59562	-1.67982	-1.81676

C Detalhes Estatísticos

C.1 Pesos da Regressão

Os dados representam uma ‘fotografia’ de 2022, de modo que as(os) diplomatas que já haviam saído do serviço ativo antes dessa data não estão na base. Por isso, as promoções mais antigas observadas dizem respeito a diplomatas que ingressaram há mais tempo e ainda permaneciam na carreira em 2022 – ou seja, refletem etapas iniciais, como a promoção a SS ou a C. Já as promoções ao topo da carreira, como a de MPC, não aparecem nesses períodos mais antigos, pois os diplomatas que as receberam nesse passado já haviam se aposentado ou deixado a carreira antes do recorte temporal da base.

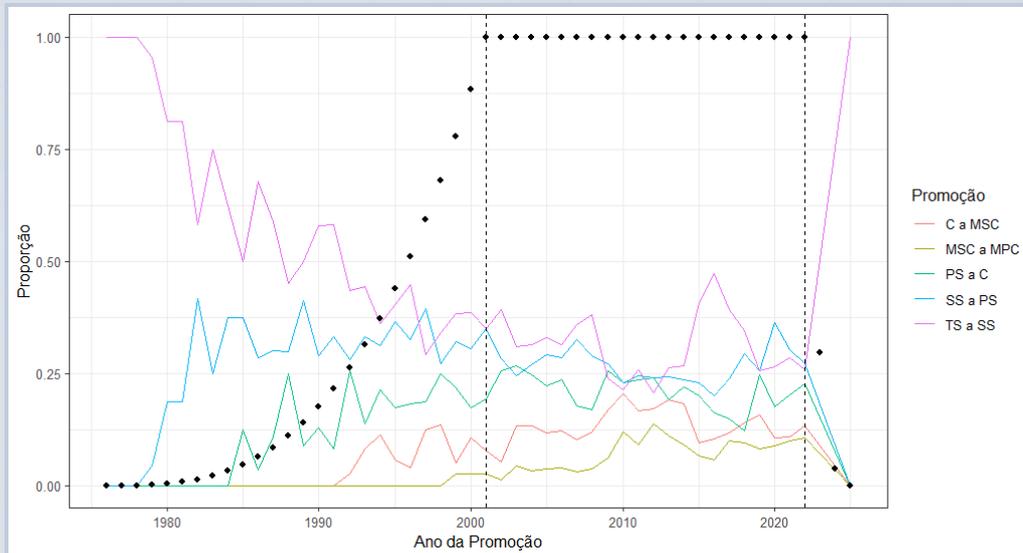
A princípio, a proporção de promoções para cada classe, em cada semestre, tende a se manter relativamente constante, conforme os valores apresentados na Tabela 9. Contudo, o viés descrito no parágrafo anterior afeta essa estabilidade: nas datas mais antigas da base, predominam as promoções iniciais, como a de ‘TS a SS’, conforme ilustrado na Figura 5.

Tabela 9: Proporções médias de cada promoção em um semestre

Prop_id	Prop
TS a SS	31.56%
SS a PS	27.13%
PS a C	21.02%
C a MSC	13.28%

Prop_id	Prop
MSC a MPC	7.01%

Figura 5: Proporções de cada promoção ao longo do tempo



Esse padrão gera um viés no modelo, pois essas primeiras promoções, por natureza, ocorrem mais rapidamente. Assim, o modelo poderia interpretar que, no passado, as promoções eram mais ágeis – o que até pode conter alguma verdade histórica, mas que, neste caso, decorre principalmente da ausência, nos dados mais antigos, de promoções mais lentas que hoje são comuns nos níveis finais da carreira.

Para corrigir esse problema, utilizamos uma *regressão com pesos*. Como indicado anteriormente na Figura 2, a regressão busca ajustar uma reta que minimize a distância entre os pontos observados e a reta estimada. Na versão com pesos, atribuímos mais peso a certas observações e menos a outras. No caso, damos mais peso para as promoções mais recentes e menos para as mais antigas. Essa ponderação está representada pelos pontos pretos na Figura 5. O intervalo entre as linhas pontilhadas marca o período em que as proporções de promoções são constantes; datas mais distantes desse intervalo recebem pesos progressivamente menores, conforme uma função quadrática.

D Algoritmo no Website

D.1 Setup

Na primeira parte do código, são definidos os coeficientes, armazenadas informações auxiliares e implementadas funções utilitárias.

```
// ----- Coeficientes e cutoffs -----
// Coeficientes fixos
const coefs_fixed = {
  "Intercepto": 2.35943,
  "MaxAposentadoria": -0.89156,
  "Turmas1Tamanho": -0.06316,
  "Turmas2T3": 0.2975,
  "SexoMasculino": -0.00279,
  "IdadeEntrada": -0.03579,
  "IdadeEntrada2": -0.00026,
  "CapitalCapital": -0.55273,
  "CapitalInterior": -0.60701,
  "CapitalExterior": -0.30096,
  "GrandeRegiaoNorte": 0.15531,
```

```

"GrandeRegiaoNordeste": 0.52628,
"GrandeRegiaoCentroOeste": -0.00108,
"GrandeRegiaoSudeste": 0.42774,
"GrandeRegiaoSul": 0.10605,
"FormacaoAreaTecnicos": -0.20696,
"FormacaoAreaHumanisticos": -0.09363,
"FormacaoNivelEspecializacao": -0.70142,
"FormacaoNivelMestrado": -0.69549,
"FormacaoNivelDoutorado": -0.95307,
"FormacaoNivelGraduacao": -0.27331,
"FormacaoNaturezaPublica": -0.21747,
"FormacaoNaturezaPrivada": -0.09857,
"Gabinete": -0.1392,
"Missao": 0.07437,
"Embaixada": 1.01447,
"ConsuladoGeral": 0.85466,
"Consulado": 0.43769
};

// Coeficientes dependentes da promoção
const coefs_prom = {
  "TSaSS": {
    "Promocao": 0,
    "TempoLag": 0.0217,
    "Promocao:TempoLag": 0,
    "AnoPromocao": 0.41873,
    "AnoPromocao:Turmas2T3": -0.18967,
    "Promocao:SexoMasculino": 0,
    "Promocao:IdadeEntrada": 0,
    "Promocao:Gabinete": 0,
    "Promocao:Missao": 0,
    "Promocao:Embaixada": 0
  },
  "SSaPS": {
    "Promocao": 6.25419,
    "TempoLag": 0.0217,
    "Promocao:TempoLag": -0.30551,
    "AnoPromocao": 0.41873,
    "AnoPromocao:Turmas2T3": -0.18967,
    "Promocao:SexoMasculino": -0.05959,
    "Promocao:IdadeEntrada": -0.01403,
    "Promocao:Gabinete": -0.37031,
    "Promocao:Missao": -0.38989,
    "Promocao:Embaixada": -1.99767
  },
  "PSaC": {
    "Promocao": 6.0579,
    "TempoLag": 0.0217,
    "Promocao:TempoLag": -0.13103,
    "AnoPromocao": 0.41873,
    "AnoPromocao:Turmas2T3": -0.18967,
    "Promocao:SexoMasculino": 0.01469,
    "Promocao:IdadeEntrada": 0.00766,
    "Promocao:Gabinete": -1.39213,
    "Promocao:Missao": -0.96711,
    "Promocao:Embaixada": -1.59562
  },
  "CaMSC": {
    "Promocao": 1.95446,

```

```

    "TempoLag": 0.0217,
    "Promocao:TempoLag": 0.10076,
    "AnoPromocao": 0.41873,
    "AnoPromocao:Turmas2T3": -0.18967,
    "Promocao:SexoMasculino": 0.55869,
    "Promocao:IdadeEntrada": 0.01096,
    "Promocao:Gabinete": 0.02922,
    "Promocao:Missao": -0.13057,
    "Promocao:Embaixada": -1.67982
  },
  "MSCaMPC": {
    "Promocao": 10.08716,
    "TempoLag": 0.0217,
    "Promocao:TempoLag": -0.05548,
    "AnoPromocao": 0.41873,
    "AnoPromocao:Turmas2T3": -0.18967,
    "Promocao:SexoMasculino": 0.08323,
    "Promocao:IdadeEntrada": -0.34249,
    "Promocao:Gabinete": -0.65025,
    "Promocao:Missao": 0.01886,
    "Promocao:Embaixada": -1.81676
  }
};

// Cutoffs para cada promoção [QEIdade, QETempoClasse, Aposentadoria]
const cuts = {
  "TSaSS": [Infinity, Infinity, 75],
  "SSaPS": [Infinity, 20, 75],
  "PSaC": [Infinity, 24, 75],
  "CaMSC": [58, 30, 75],
  "MSCaMPC": [60, 30, 75]
};

// ----- Nomes -----
// Nome das classes
const classNames = {
  0: "Terceiro Secretário",
  1: "Segundo Secretário",
  2: "Primeiro Secretário",
  3: "Conselheiro",
  4: "Ministro de Segunda Classe",
  5: "Ministro de Primeira Classe"
};
const classKeys = ["TS", "SS", "PS", "C", "MSC", "MPC"];

// Nomes das promoções
const promotionNames = {
  "TSaSS": "TS → SS (Terceiro Secretário para Segundo Secretário)",
  "SSaPS": "SS → PS (Segundo Secretário para Primeiro Secretário)",
  "PSaC": "PS → C (Primeiro Secretário para Conselheiro)",
  "CaMSC": "C → MSC (Conselheiro para Ministro de Segunda Classe)",
  "MSCaMPC": "MSC → MPC (Ministro de Segunda Classe para Ministro de Primeira
  ↳ Classe)"
};
const promotionKeys = Object.keys(promotionNames);

// ----- Criação de variáveis -----

```

```

// Função para criar variáveis fixas com base nos inputs do usuário
function create_vars_fixed() {
  const idadeEntrada =
    ↪ parseInt(document.getElementById('form-field-idade_entrada').value) - 18;

  return {
    "Intercepto": 1,
    "MaxAposentadoria": 1,
    "Turmas1Tamanho": 30,
    "Turmas2T3": 1,
    "SexoMasculino": parseInt(document.querySelector('input[name="form_fields[sex_
    ↪ o]"]:checked').value),
    "IdadeEntrada": idadeEntrada,
    "IdadeEntrada2": idadeEntrada * idadeEntrada,
    "CapitalCapital": document.querySelector('input[name="form_fields[capital_dum_
    ↪ my]"]:checked').value === "capital" ? 1 : 0,
    "CapitalInterior": document.querySelector('input[name="form_fields[capital_du_
    ↪ mmy]"]:checked').value === "interior" ? 1 : 0,
    "CapitalExterior": document.querySelector('input[name="form_fields[capital_du_
    ↪ mmy]"]:checked').value === "exterior" ? 1 : 0,
    "GrandeRegiaoNorte": document.querySelector('input[name="form_fields[grande_r_
    ↪ egiao]"]:checked').value === "norte" ? 1 : 0,
    "GrandeRegiaoNordeste": document.querySelector('input[name="form_fields[grand_
    ↪ e_regiao]"]:checked').value === "nordeste" ? 1 : 0,
    "GrandeRegiaoCentroOeste": document.querySelector('input[name="form_fields[gr_
    ↪ ande_regiao]"]:checked').value === "centro-oeste" ? 1 : 0,
    "GrandeRegiaoSudeste": document.querySelector('input[name="form_fields[grande_
    ↪ _regiao]"]:checked').value === "sudeste" ? 1 : 0,
    "GrandeRegiaoSul": document.querySelector('input[name="form_fields[grande_reg_
    ↪ iao]"]:checked').value === "sul" ? 1 : 0,
    "GrandeRegiaoExterior": document.querySelector('input[name="form_fields[grand_
    ↪ e_regiao]"]:checked').value === "exterior" ? 1 : 0,
    "FormacaoAreaTecnicos": document.querySelector('input[name="form_fields[forma_
    ↪ cao_area]"]:checked').value === "tecnicos" ? 1 : 0,
    "FormacaoAreaHumanisticos": document.querySelector('input[name="form_fields[f_
    ↪ ormacao_area]"]:checked').value === "humanisticos" ? 1 : 0,
    "FormacaoNivelGraduacao": document.querySelector('input[name="form_fields[for_
    ↪ macao_nivel]"]:checked').value === "graduacao" ? 1 : 0,
    "FormacaoNivelEspecializacao": document.querySelector('input[name="form_field_
    ↪ s[formacao_nivel]"]:checked').value === "especializacao" ? 1 : 0,
    "FormacaoNivelMestrado": document.querySelector('input[name="form_fields[form_
    ↪ acao_nivel]"]:checked').value === "mestrado" ? 1 : 0,
    "FormacaoNivelDoutorado": document.querySelector('input[name="form_fields[for_
    ↪ macao_nivel]"]:checked').value === "doutorado" ? 1 : 0,
    "FormacaoNaturezaPublica": document.querySelector('input[name="form_fields[fo_
    ↪ rmacao_natureza]"]:checked').value === "publica" ? 1 : 0,
    "FormacaoNaturezaPrivada": document.querySelector('input[name="form_fields[fo_
    ↪ rmacao_natureza]"]:checked').value === "privada" ? 1 : 0,
    "Gabinete": parseInt(document.querySelector('input[name="form_fields[gabinete_
    ↪ ]"]:checked').value),
    "Missao": parseInt(document.querySelector('input[name="form_fields[missao]":_
    ↪ checked').value),
    "Embaixada": parseInt(document.querySelector('input[name="form_fields[embaixa_
    ↪ da]"]:checked').value),
    "ConsuladoGeral": parseInt(document.querySelector('input[name="form_fields[co_
    ↪ nsulado_geral]"]:checked').value),
    "Consulado": parseInt(document.querySelector('input[name="form_fields[consula_
    ↪ do]"]:checked').value)
  }
}

```

```

    };
}

// Função para criar variáveis dependentes da promoção
function create_vars_prom(promotion, vars_fixed) {
    const tempoLagValues = [5, 5, 6, 6, 8];
    const anoPromocaoValues = [60, 65, 71, 77, 85];

    return {
        "Promocao": 1,
        "TempoLag": tempoLagValues[promotion],
        "Promocao:TempoLag": tempoLagValues[promotion],
        "AnoPromocao": anoPromocaoValues[promotion],
        "AnoPromocao:Turmas2T3": anoPromocaoValues[promotion],
        "Promocao:SexoMasculino": vars_fixed["SexoMasculino"],
        "Promocao:IdadeEntrada": vars_fixed["IdadeEntrada"],
        "Promocao:Gabinete": vars_fixed["Gabinete"],
        "Promocao:Missao": vars_fixed["Missao"],
        "Promocao:Embaixada": vars_fixed["Embaixada"]
    };
}

// ----- Funções utilidade -----
// Função para calcular soma cumulativa
function cumsum(numbers) {
    const result = [];
    let sum = 0;

    for (const num of numbers) {
        sum += num;
        result.push(sum);
    }

    return result;
}

// Formata semestres para mês e ano por extenso
function format_semester_to_year(semestres) {
    const anos = Math.floor(semestres / 2);
    const remainder = semestres % 2;

    const remainder_text = remainder == 1 ? ` e ${remainder} semestre` : "";
    const anos_text = `${anos} ano${anos > 1 ? "s" : ""}`;

    if (anos == 0) {
        return "1 semestre";
    } else {
        return `${anos_text}${remainder_text}`;
    }
}

// Função para calcular a diferença de anos entre duas datas
function date_diff_years(date1, date2) {
    const year1 = date1.getFullYear();
    const year2 = date2.getFullYear();

    let date2_year1 = new Date(date2);
    date2_year1.setYear(year1);

```

```

    hasBirthdayPassed = date2_year1 >= date1;

    return year2 - year1 - (hasBirthdayPassed ? 0 : 1);
};

// Função para obter a idade em cada data de promoção
function accumulate_age(carrier_time, date_of_birth) {
    const birthDate = new Date(date_of_birth);

    let currentDate = new Date();
    const promotion_date = new
    ↪ Date(`${currentDate.getFullYear()}-${currentDate.getMonth() >= 7 ? 7 :
    ↪ 1}-01`);
    //const referenceDate = new Date('2025-01-01');

    let age = [];
    let date = [];

    for (let i = 0; i < carrier_time.length; i++) {
        promotion_date.setMonth(promotion_date.getMonth() + 6 * carrier_time[i]);
        date.push(`${promotion_date.getFullYear()}${promotion_date.getMonth() < 6 ? 1
    ↪ : 2}`);
        age.push(date_diff_years(birthDate, promotion_date));
    };

    return {age: age, date: date};
};

```

D.2 Calculadora

Agora, o cálculo das previsões é feito com base nas funções abaixo:

```

// Função para calcular as previsões
function calculate_predictions(current_class, current_time) {
    const promotions = [];

    for (let i = current_class; i <= 4; i++) {
        promotions.push(i);
    }

    const vars_fixed = create_vars_fixed();
    const preds = {};

    promotions.forEach(p => {
        const promotionKey = promotionKeys[p];
        const coefs = {...coefs_fixed, ...coefs_prom[promotionKey]};
        const vars = {...vars_fixed, ...create_vars_prom(p, vars_fixed,
    ↪ current_class)};

        let prediction = 0;
        for (const key in coefs) {
            prediction += coefs[key] * vars[key];
        }

        preds[p] = prediction;
    });

    preds[current_class] = Math.max(preds[current_class] - current_time, 1);
}

```

```

return preds;
}

// Função para calcular a classe máxima alcançável
function calculate_max_class(predictions, user_age, current_class, date_of_birth) {
  // Variáveis para armazenar as regras quebradas
  let maxClass = -1;
  let brokenRule = "";
  let explanationMessage = {};

  // Extrai os valores de previsão em ordem
  const predValues = Object.values(predictions).map(v => Math.ceil(v));

  // Calcula tempo de classe, tempo de carreira e idade
  const class_time = predValues;
  const career_time = cumsum(predValues);

  const accumulate_results = accumulate_age(career_time, date_of_birth);
  const age = accumulate_results.age;
  const date = accumulate_results.date;

  // Verifica cada promoção
  for (let p = current_class; p <= 4; p++) {
    pAdj = p - current_class; // Ajusta o índice para começar do zero
    const currentCuts = cuts[promotionKeys[p]];
    const currentClass = classKeys[p];
    const nextClass = classKeys[p + 1] || "";

    // Verifica regras para esta promoção e calcula idade de quebra
    const idades = {};
    if (age[pAdj] >= currentCuts[2]) idades.idadeAposentadoria = 75;
    if (age[pAdj] >= currentCuts[0]) idades.idadeQePorIdade = currentCuts[0];
    if (class_time[pAdj] >= currentCuts[1]) idades.idadeQePorTempo = age[pAdj] +
      ↪ (currentCuts[1] / 2);

    if (Object.keys(idades).length > 0) {
      // Obtem a primeira a ser quebrada
      let regraLimitante = null;
      let idadeLimitante = Infinity;
      for (const [key, value] of Object.entries(idades)) {
        if (value < idadeLimitante) {
          idadeLimitante = value;
          regraLimitante = key;
        }
      }

      message = `Demoraria <strong>${predValues[pAdj]} semestres</strong> para
      ↪ ser promovido, `;

      if (regraLimitante === "idadeAposentadoria") {
        maxClass = p;
        brokenRule = "Aposentadoria compulsória";
        message += `mas atinge <strong>75 anos</strong> de idade como
      ↪ <strong>${currentClass}</strong>, e é aposentado compulsoriamente`;
        type = "APOSENTADORIA";
      } else if (regraLimitante === "idadeQePorIdade") {
        brokenRule = "Quadro Especial por idade";
        message += `mas atinge <strong>${idadeLimitante} anos</strong> de
      ↪ idade como <strong>${currentClass}</strong>, passando para o QE`

```

```

    } else if (regraLimitante === "idadeQePorTempo") {
        brokenRule = "Quadro Especial por tempo de classe";
        message += `acima do limite, passando, aos <strong>${idadeLimitante}</strong>
↪ anos</strong>, para o QE`
    }

    if (regraLimitante === "idadeQePorIdade" || regraLimitante ===
↪ "idadeQePorTempo") {
        if (p === 1 || p === 2) { // SSaPS ou PSaC
            maxClass = p + 1;
            message += ` como ${nextClass}.`;
            type = "QE_PROMOTION";
        } else {
            maxClass = p;
            message += `.`;
            type = "QE_BLOCK";
        }
    }

    explanationMessage = {
        type: type,
        message: message
    };

    break;
}
}

// Se nenhuma regra foi quebrada, alcançou MPC
if (maxClass === -1) {
    maxClass = 5; // MPC
    brokenRule = "Nenhuma regra limitante";
    explanationMessage = {
        type: "MAX_CLASS",
        message: "O usuário alcançou a classe máxima (MPC) sem restrições."
    };
}

return {
    maxClass: maxClass,
    brokenRule: brokenRule,
    explanationMessage: explanationMessage,
    class_time: class_time,
    career_time: career_time,
    age: age,
    date: date
};
}

```

E as previsões alternativas são calculadas e formatadas com:

```

// Função para calcular o intervalo de confiança
function calculate_confidence_interval(predictions) {
    // Multiplicadores pré-definidos
    const mults = {
        "20%": 0.07869,
        "60%": 0.26184,
        "80%": 0.39907,
        // "90%": 0.51213,
    };
}

```

```

    "95%": 0.61018
  };

  // Aplica os multiplicadores
  const preds_ci = {};
  Object.entries(mults).forEach(([multName, multValue]) => {
    const adjusted = {};
    for (const [p, pred] of Object.entries(predictions)) {
      adjusted[p] = pred * (1 + multValue);
    }
    preds_ci[multName] = adjusted;
  });

  return {
    multipliers: mults,
    adjustedPredictions: preds_ci
  };
}

// Função que gera tabela de cenários para intervalo de confiança da previsão
function tabulate_ci(predictions, preds_ci, user_age, current_class, date_of_birth) {
  const scenarios = {
    'Previsão': predictions,
    ...preds_ci
  };

  const maxClassMap = {};

  // Calcula a classe máxima por cenário
  for (const [label, preds] of Object.entries(scenarios)) {
    const result_max_class = calculate_max_class(preds, user_age, current_class,
      ↵ date_of_birth);
    console.log('result_max_class', result_max_class);
    maxClassMap[label] = result_max_class.maxClass;
  }

  // Início da tabela
  let html = `<table class="tabela-cenarios">
  <thead>
  <tr>
  <th>CLASSE</th>
  ${Object.keys(scenarios).map(label => `<th>${label}</th>`).join('')}
  </tr>
  </thead>
  <tbody>`;

  for (const [i, classLabel] of Object.entries(classNames)) {
    html += `<tr><td>${classLabel}</td>`;

    for (const [label, preds] of Object.entries(scenarios)) {
      const maxClass = maxClassMap[label];

      if (i === 0) {
        // Terceiro Secretário sempre
        html += `<td><i class="fas fa-check"></i></td>`;
      } else if (i <= current_class) {
        html += `<td><i class="fas fa-check"></i></td>`;
      } else if (i > maxClass) {
        html += `<td><i class="fas fa-times"></i></td>`;
      }
    }
  }
}

```

```

    } else {
      const val = Math.ceil(preds[i-1]) ?? '-';
      html += ` ${val}</td>`;     }   }    html += `</tr>`; }  html += `</tbody></table>`; return html; } |
```

Todas essas funções são orquestradas pelo código:

```

// Função principal que orquestra todo o cálculo
function calculateCareer(event) {
  event.preventDefault();

  const idadeEntrada =
    ↪ parseInt(document.getElementById('form-field-idade_entrada').value);
  const dtBirth = document.getElementById('form-field-data_nasc').value;
  const currentClass = parseInt(document.querySelector('input[name="form_fields[class_
    ↪ e_atual]"]:checked').value);
  const currentTime = parseInt(document.querySelector('input[name="form_fields[semest_
    ↪ res_na_classe]"]').value);
  const predictions = calculate_predictions(currentClass, currentTime);
  const maxClassResult = calculate_max_class(predictions, idadeEntrada, currentClass,
    ↪ dtBirth);

  console.log('predictions', predictions);
  console.log('maxClassResult', maxClassResult);

  const previsaoLista = {
    0: { elementorContainerId: "#etapa-ts", ...emptyEtapa() },
    1: { elementorContainerId: "#etapa-ss", ...emptyEtapa() },
    2: { elementorContainerId: "#etapa-ps", ...emptyEtapa() },
    3: { elementorContainerId: "#etapa-c", ...emptyEtapa() },
    4: { elementorContainerId: "#etapa-msc", ...emptyEtapa() },
    5: { elementorContainerId: "#etapa-mpc", ...emptyEtapa() }
  };

  function emptyEtapa() {
    return {
      promotion: "", detailedInfo: "", brokenRule: "",
      etapaPassada: false, etapaAtual: false, etapaAlcancavel: false, etapaImpedida:
        ↪ false
    };
  }

  // Garante que maxClass nunca é menor que a classe atual
  const maxClasseCorrigida = Math.max(maxClassResult.maxClass, currentClass);

  // Prepara a apresentação dos resultados
  // Lógica de marcação de etapas e informações complementares
  for (const [index, etapa] of Object.entries(previsaoLista)) {
    // Preenche tempo estimado
    if (predictions[index] !== undefined) {
      predictionRounded = Math.ceil(predictions[index]);
    }
  }
}

```

```

nextClass = classKeys[parseInt(index) + 1] || "";

if ((index == currentClass) & (currentTime > 0)) {
    plural_prediction = predictionRounded > 1 ? "s" : "";
    plural_current = currentTime > 1 ? "s" : "";
    current_time_text = `
<n<li>${predictionRounded}
↪ <strong>semestre${plural_prediction}</strong> após o${plural_current}
↪ ${currentTime} já cumprido${plural_current}</li>`
    } else {
        current_time_text = ""
    }

    etapa.detailedInfo = `<ul>${current_time_text}
↪ <li><strong>Semestre da promoção:</strong> ${maxClassResult.date[index -
↪ currentClass]}</li>
↪ <li><strong>Idade na promoção:</strong> ${maxClassResult.age[index -
↪ currentClass]} anos</li>
</ul>`
    previsaoLista[index].promotion = `${format_semester_to_year(predictionRounded)}
↪ entre ${classKeys[index]} e ${nextClass}`;
}

if (index < currentClass) {
    etapa.etapaPassada = true;
} else if (index == currentClass) {
    etapa.etapaAtual = true;

    // Se a maxClass for igual ao currentClass, também marcamos como alcançável
    if (index == maxClasseCorrigida) {
        etapa.etapaAlcancavel = true;
        etapa.brokenRule = maxClassResult.brokenRule;
        etapa.detailedInfo =
↪ `<span>${maxClassResult.explanationMessage.message}</span>`;
    }
} else if (index <= maxClasseCorrigida) {
    etapa.etapaAlcancavel = true;

    // Se for a última etapa alcançável, adicionamos as regras
    if (index == maxClasseCorrigida) {
        etapa.brokenRule = maxClassResult.brokenRule;
        etapa.detailedInfo =
↪ `<span>${maxClassResult.explanationMessage.message}</span>`;
    }
} else {
    etapa.etapaImpedida = true;
}
}

// [Aqui existe um código que, dado as informações das etapas, trata da camada de
↪ apresentação, aplicando as alterações no DOM]

// Apresenta resultado da calculadora
document.getElementById('resultado_calculadora')?.classList.remove("hide");

// Outras previsões para comparativo de cenários
const confidenceResult = calculate_confidence_interval(predictions);
console.log('confidenceResult.adjustedPredictions',
↪ confidenceResult.adjustedPredictions);
const tabelaCenariosHtml = tabulate_ci(predictions,
↪ confidenceResult.adjustedPredictions, idadeEntrada, currentClass, dtBirth);

```

```

const tabelaResponsiva = document.querySelector('.tabela-responsiva');
tabelaResponsiva.querySelector('.tabela-cenarios').remove();
tabelaResponsiva.innerHTML = tabelaCenariosHtml + tabelaResponsiva.innerHTML;

// Botão outros cenários
document.getElementById('calcular_outros_cenarios')?.addEventListener('click',
  ↪ function () {
  ↪ document.getElementById('tabela-comparacao')?.classList.remove("hide"); });
}

// Botão de ativação
document.getElementById('calcular')?.addEventListener('click', calculateCareer);

```

E Contribuições dos Autores segundo a taxonomia CRediT

A tabela abaixo apresenta a atribuição individual das contribuições dos membros da equipe envolvida na elaboração da Calculadora de Carreira, não apenas este documento, conforme a taxonomia CRediT¹⁴ (Contributor Roles Taxonomy):

Autor	Contribuições
Loreta Guerra	Conceitualização, Metodologia, Validação, Análise formal, Investigação, Curadoria de dados, Escrita – Rascunho Original, Escrita – Revisão e Edição, Visualização, Supervisão
Ricardo Semião	Conceitualização, Metodologia, Validação, Análise formal, Investigação, Curadoria de dados, Escrita – Rascunho Original, Escrita – Revisão e Edição, Visualização, Supervisão, Software
Fabia Berlatto	Conceitualização, Validação, Investigação, Curadoria de dados, Escrita – Rascunho Original, Escrita – Revisão e Edição, Supervisão, Administração de projetos
Sérgio Santana	Software, Validação, Visualização
Lucivan Queiroz	Software, Validação, Visualização, Administração de projetos
Karla Gobo	Curadoria de Dados, Validação

¹⁴Contributor Roles Taxonomy. A definição das categorias utilizadas pode ser consultada em: credit.niso.org.