

**NOVAS SOLUÇÕES PARA CONSTRANGIMENTOS  
ANTIGOS - As principais generalizações do método  
Diferença-em-Diferenças enquanto instrumentos  
para a avaliação de impacto de intervenções  
cofinanciadas por fundos europeus**

**Relatório Final**

Candidatura Aviso: N.º 06/POAT/2021

Agosto 2022

Código: POAT-77-2021-06 Designação: Metodologias de Monitorização e Avaliação

Programa Operacional Assistência Técnica

Eixo Prioritário: Coordenação, gestão monitorização e auditoria

## Coordenação:

Bruno Damásio (bdamasio@novaims.unl.pt)

# Índice

1	Introdução.....	4
2	Caracterização do problema, objetivos e revisão de literatura .....	7
2.1	Problema e Objetivos .....	7
2.2	Revisão de literatura .....	9
2.2.1	Diferença-em-diferenças.....	9
2.2.2	Estimador De Chaisemartin & D’Haultfoeuille (2020) .....	11
2.2.3	Estimador Callaway & Sant’Anna (2020).....	12
2.2.4	Estimador Sun & Abraham (2020).....	12
2.2.5	Estimador Borusyak, Jaravel, and Spiess (2021) .....	13
2.2.6	Pressuposto das tendências paralelas .....	14
2.2.7	Tabela Síntese .....	15
2.2.8	Seleção do estimador .....	16
2.2.9	Implementação Computacional .....	18
2.2.10	Aplicação computacional e simulação de resultados .....	21
3	Aquisição e preparação dos dados.....	43
3.1	Exemplo de Aplicação de Avaliação de Políticas Públicas.....	43
3.2	Aquisição de Dados .....	44
3.3	Preparação de Dados. Construção da Amostra .....	44
3.4	Estatísticas Descritivas .....	45
4	Desenvolvimento e aplicação de modelos.....	46
4.1	Estimação de Modelos .....	46
5	Testes e avaliação de precisão. Análise de Heterogeneidade .....	51
5.1	Heterogeneidade por Características Demográficas .....	51
5.1.1	Heterogeneidade por Género .....	51
5.1.2	Heterogeneidade por Habilitações .....	53
5.2	Heterogeneidade por Características das Entidades Empregadoras .....	57
5.2.1	Heterogeneidade por Dimensão da Entidade Empregadora .....	57
5.2.2	Heterogeneidade por Sector de Atividade da Entidade Empregadora.....	62
6	Disseminação .....	67
7	Conclusão .....	67
8	Referências .....	69

## Índice de Figuras

Figura 1. Método DiD canónico.....	10
Figura 2. Método DiD canónico, as suas limitações e os desenvolvimentos recentes .....	10
Figura 3. Fluxograma para seleção do estimador .....	16
Figura 4. Diferença-em-diferenças: Demonstração 1 .....	22
Figura 5. Diferença-em-diferenças: Demonstração 2 .....	25
Figura 6. Diferença-em-diferenças: Demonstração 3 .....	27
Figura 7. Diferença-em-diferenças: Demonstração 4 .....	29
Figura 8. Diferença-em-diferenças: Demonstração 5 .....	31
Figura 9. Decomposição de Bacon: Demonstração 1.....	34
Figura 10. Decomposição de Bacon: Demonstração 2.....	36
Figura 11. Resultado did_multiplt ..... 38	38
Figura 12. Resultado csdid .....	39
Figura 13. Resultado eventstudyinteract .....	41
Figura 14. Resultado did_imputation.....	42
Figura 15. Construção da Amostra.....	45
Figura 16. Efeitos dinâmicos a partir do modelo de Chaisemartin & D’Haultfoeuille (2020).....	48
Figura 17. Efeitos dinâmicos a partir do modelo de Callaway & Sant’Anna (2020).....	49
Figura 18. Efeitos dinâmicos a partir do modelo de Borusyak, Jaravel & Spiess (2021).....	49
Figura 19. Efeitos dinâmicos: Comparação dos Três Modelos.....	50
Figura 20. Efeitos dinâmicos: Mulheres .....	52
Figura 21. Efeitos dinâmicos: Homens .....	53
Figura 22. Efeitos de tratamento médios por Nível de Habilitações .....	55
Figura 23. Efeitos dinâmicos: Ensino Básico .....	56
Figura 24. Efeitos dinâmicos: Ensino Secundário.....	56
Figura 25. Efeitos dinâmicos: Ensino Superior .....	57
Figura 26. Efeitos de tratamento médios por Dimensão da Entidade Empregadora .....	59
Figura 27. Efeitos dinâmicos: Micro Empresa .....	60
Figura 28. Efeitos dinâmicos: Pequena Empresa .....	61
Figura 29. Efeitos dinâmicos no salário horário: Média Empresa.....	61
Figura 30. Efeitos dinâmicos: Grande Empresa .....	62
Figura 31. Efeitos de tratamento médios por Sector de Atividade da Entidade Empregadora..	63
Figura 32. Efeitos dinâmicos: Indústria Transformadora .....	65
Novas soluções para constrangimentos antigos	2

Figura 33. Efeitos dinâmicos: Alojamento e Restauração .....	65
Figura 34. Efeitos dinâmicos: Comércio por Grosso e a Retalho .....	66
Figura 35. Efeitos dinâmicos: Transportes e Armazenamento .....	66

## Índice de Tabelas

Tabela 1. Tabela Síntese .....	15
Tabela 2. Implementação Computacional .....	18
Tabela 3. Estatísticas Descritivas .....	46
Tabela 4. Estimções dos Modelos Differences-in-Differences com Efeitos Heterogéneos .....	47
Tabela 5. Efeito de Tratamento médio por género do trabalhador .....	52
Tabela 6. Efeito de Tratamento médio por escolaridade do trabalhador .....	54
Tabela 7. Efeito de Tratamento médio por dimensão da entidade empregadora .....	58
Tabela 8. Efeito de tratamento médio por sector de atividade da entidade empregadora .....	64

# 1 Introdução

O recurso a métodos estatísticos quase-experimentais tornou-se o paradigma das boas práticas nos exercícios de avaliação de políticas públicas em todas as entidades que se dedicam a esta função. Em particular, no que respeita aos métodos quase-experimentais, o método da diferença-em-diferenças (DiD - “*difference-in-differences*”) afirmou-se como o método central na avaliação de políticas públicas. Com base em alguns pressupostos, este método permite estabelecer cenários contra factuais e estimar efeitos de tratamento associados a políticas públicas que de outra forma só poderiam ser estimados com recurso a métodos puramente experimentais (cuja implementação é frequentemente inviável, seja pelo custo da sua implementação, pela dificuldade em manter os participantes, ou por razões éticas).

A centralidade do método DiD nos exercícios avaliação de políticas públicas iniciou-se com o trabalho pioneiro do prémio Nobel David Card e a sua popularidade nas últimas duas décadas está associada a dois fenómenos. Por um lado, ao aperfeiçoamento continuado da metodologia, o que torna a sua implementação cada vez mais credível numa grande variedade de contextos. Por outro lado, a crescente disponibilidade de poder computacional associada à passagem da utilização de dados observacionais para grandes bases de micro dados, em particular dados administrativos, o que permitiu alargar drasticamente as possibilidades de avaliação de políticas públicas e garantir uma estimação cada vez mais precisa e credível dos efeitos de tratamento que se pretende estimar.

Apesar desta “revolução” nas metodologias e da disponibilidade de dados empíricos para a avaliação de políticas públicas, o contexto em que operam as políticas públicas cofinanciadas por fundos europeus inviabiliza muitas vezes a utilização dos métodos DiD clássicos, em particular nos casos em que a zona de abrangência corresponde ao conjunto do território nacional, agravando-se quando que a implementação dos programas não é simultânea. Constituem exemplos algumas das políticas públicas que operam no domínio dos incentivos à contratação ou aquisição de vínculos permanentes de grupos etários específicos com dificuldades de integração no mercado de trabalho (por exemplo, jovens à procura do primeiro emprego, empregados de longa duração ou indivíduos com idade igual ou a aquisição de vínculos permanentes por parte dos indivíduos com idade igual ou superior a 45 anos).

A partir de 2019, uma nova revolução metodológica surgiu no âmbito dos métodos quase-experimentais. Em particular, os métodos DiD com efeitos desfasados no tempo (“*staggered designs*”), que oferecem a possibilidade de estimar de forma consistente efeitos de tratamento robustos em situações nas quais a implementação da política pública não é simultânea, podendo constituir como grupos de controlo as unidades que ainda não tenham sido sujeitas ao

tratamento (sujeitas ao programa), mas que o venham a ser no futuro, permitindo superar igualmente as dificuldades em encontrar um grupo de controlo quando a zona de abrangência é o território nacional. Estes métodos são fundados nos trabalhos pioneiros de Callaway and Sant'Anna (2020), Chaisemartin and D'Haultfoeuille (2020), Sun and Abraham (2020) e Borusyak, Jaravel and Spiess (2021), e rapidamente se tornaram no estado de arte das metodologias usadas para avaliar políticas públicas nas situações anteriormente descritas. Contudo, e apesar da sua particular relevância e utilidade, a sua utilização no contexto português, em particular aplicadas à avaliação de políticas públicas cofinanciadas por fundos europeus, é ainda inexistente.

Com o objetivo de aproveitar as importantes inovações metodológicas no contexto dos modelos DiD, em particular no que respeita aos modelos DiD com *“staggered designs”*, para generalizar a avaliação de políticas públicas em contextos em que os modelos DiD clássicos não fornecem essa possibilidade, este projeto propôs-se em primeiro lugar a elaborar um guia metodológico sobre a implementação do estimador DiD considerando os contextos de atuação de diversas políticas públicas cofinanciadas por fundos europeus (zona de abrangência, existência de um grupo de controlo explícito, simultaneidade/desfasamento do tratamento) à luz das recentes inovações metodológicas. Esse guia constitui a primeira parte deste projeto e o seu resultado encontra-se exposto ao longo da Secção 2. Em particular, na Secção 2.1 começamos por apresentar um conjunto de programas cofinanciados por fundos europeus que são *“candidatos”* à avaliação por parte dos modelos DiD com *“staggered designs”*. Posteriormente, nas secções 2.2.2 até 2.2.5 são apresentados de forma sistemática os estimadores que desde 2020 foram propostos para estimar modelos DiD com *“staggered designs”*, bem como se promove uma discussão acerca dos seus pressupostos, limitações e aplicação nos contextos das políticas públicas cofinanciadas por fundos europeus. Por último, na Secção 2.2.9 apresentam-se as rotinas para estimar cada um dos modelos no *software* estatístico *Stata*, e posteriormente apresentam-se ainda um conjunto de estudos de simulação em que se empregam as metodologias propostas para estimar os modelos DiD com *“staggered designs”*, e que têm como objetivo ajudar o leitor a familiarizar-se com as hipóteses subjacentes a cada estimador e as possíveis consequências da sua violação. Esta exposição é acompanhada, quer pelas rotinas que implementam cada estimador e/ou simulação, quer pelos gráficos subjacentes e outputs do modelo *Stata*. Tomámos esta opção de expor detalhadamente a implementação computacional, pois consideramos que poderá ser a melhor forma de ajudar o leitor a usar este guia metodológico nas suas próprias aplicações em avaliações de política pública.

A segunda parte deste projeto, procurou implementar um exercício de avaliação de políticas públicas com base no corpo teórico e nas rotinas computacionais apresentadas na primeira parte. Em particular, procurámos aplicar os métodos DiD em “*staggered designs*” a políticas que promovem a contratação ou a aquisição de vínculo permanente de trabalhadores pertencentes a certos grupos etários, através da redução ou isenção da taxa social única das entidades empregadoras. Esta opção é relevante não só por existirem vários programas cofinanciados por fundos europeus que promovem este tipo de políticas públicas (ACTIVAR.PT, Emprego Jovem Ativo, Programa Emprego +, etc.), mas também pela ampla discussão que existe quer no plano nacional, quer no plano internacional, acerca do seu impacto, nomeadamente no emprego, salários e custos das empresas.

A maior dificuldade deste exercício prende-se com a existência de micro dados administrativos que permitam uma identificação unívoca dos indivíduos e das empresas que recorrem a tais programas. Relativamente aos dados empíricos, foram usadas as bases de dados administrativas do Relatório Único (“Quadros de Pessoal”) compiladas pelo Ministério do Trabalho e Segurança Social e disponibilizadas pelo Instituto Nacional de Estatística. Esta base de dados permite observar remunerações, promoções, tipologias de vínculos contratuais, bem como características dos indivíduos (idade, sexo, escolaridade, etc.) e das empresas (capital social, volume de negócios, número de trabalhadores, etc.). Contudo, a inexistência de informação acerca do regime contributivo no qual cada trabalhador se encontra enquadrado para efeitos de contribuições para a segurança social complica a identificação dos indivíduos e empresas afetos aos programas de redução ou isenção ou redução da TSU. Tendo em conta esta limitação, restringimos o estudo às potenciais isenções da TSU concedidas às entidades empregadoras que realizem um contrato sem termo aos indivíduos com idade igual ou superior a 45 anos e que anteriormente detinham um contrato a termo na mesma entidade. Em particular, para evitar a contaminação por outro tipo de fatores, concentramo-nos no efeito na remuneração horária dos indivíduos entre os 45 e 46 anos que dentro da mesma entidade empregadora tenham transitado de um contrato a termo para um contrato sem termo. É importante salientar a limitação de não se poder aferir deterministicamente se a entidade empregadora desta subamostra de trabalhadores beneficiou efetivamente de isenção da TSU, contudo, dada natureza exemplificativa do exercício, acreditamos que constitui um bom compromisso entre os objetivos e a disponibilidade dos dados. A seleção e construção desta amostra encontra-se descrita na Secção 3.

Por último, a Secções 4 apresenta os resultados das estimações usando os modelos DiD com “*staggered designs*”, e a Secção 5 a análise de heterogeneidade por características dos indivíduos e empresas. A Secção 6 apresenta as ações de disseminação. A Secção 7 conclui.



## 2 Caracterização do problema, objetivos e revisão de literatura

### 2.1 Problema e Objetivos

O POAT 2014-2020 tem como objetivo assegurar as condições necessárias para o funcionamento dos sistemas e estruturas associadas à coordenação e monitorização estratégica do Portugal 2020, estudos e avaliação, incluindo a criação e funcionamento de mecanismos que permitam a articulação entre as políticas públicas nacionais e as operações apoiadas pelos programas operacionais ou que produzam informação relevante para apoio à decisão no âmbito do desenvolvimento das regiões.

O objetivo central do presente documento consiste em fornecer um guia conceptual de avaliação de políticas públicas centrado no método das diferenças nas diferenças (DiD) e em possíveis inovações/extensões metodológicas que seja robusto aos diferentes contextos de aplicação das políticas públicas. Assim, com a finalidade de identificação e aperfeiçoamento de ferramentas que podem ser utilizadas para avaliar políticas públicas financiadas por fundos europeus no contexto da Estratégia 2030 e do Regulamento de disposições comuns para o período 2021-2027 da política de coesão, selecionou-se um conjunto de operações passíveis de serem avaliadas. Focou-se no objetivo temático (OT) 8 que visa a “Promoção da sustentabilidade e da qualidade do emprego e apoio à mobilidade dos trabalhadores”. Especificamente, dentro do OT8, os apoios à contratação estão abrangidos pela PI 8.1 e 8.2, deste modo extraímos a lista de operações aprovadas e selecionou-se as que se enquadravam nestas PI. As operações inseriam-se numa das seguintes categorias:

- **Apoios à Contratação a jovens e adultos:** (1) Medidas de apoio à contratação que consistem na concessão de um apoio financeiro ao empregador que celebre contrato de trabalho com desempregado inscrito nos serviços de emprego, tendo em vista combater o desemprego, fomentando a criação líquida de postos de trabalho e promovendo a contratação de públicos mais desfavorecidos e o reforço de vínculos laborais mais estáveis e combatendo a segmentação e a precariedade no mercado de trabalho. (2) Apoios financeiros ao empregador pela contratação de desempregados inscritos nos serviços de emprego, associados à criação líquida de postos de trabalho e ao reforço de vínculos laborais mais estáveis, combatendo a segmentação e a precariedade no mercado de trabalho. As medidas de apoio à contratação incluem o reembolso de uma percentagem da Taxa Social Única paga pelo empregador.

- **Estágios para adultos:** As medidas de estágios profissionais visam complementar e desenvolver as competências dos jovens que procuram um primeiro ou um novo emprego, de forma a melhorar o seu perfil de empregabilidade, através da aquisição de novas formações e competências junto das empresas, com vista à criação de emprego, nomeadamente em novas áreas profissionais tendo como objetivo o apoio à transição entre o sistema de qualificações e o mercado de trabalho.
- **Estágios para jovens:** A medida estágios emprego visa complementar e desenvolver as competências dos jovens que procuram um primeiro ou um novo emprego, de forma a melhorar o seu perfil de empregabilidade, através da aquisição de novas formações e competências junto das empresas, com vista à criação de emprego, nomeadamente em novas áreas profissionais tendo como objetivo o apoio à transição entre o sistema de qualificações e o mercado de trabalho.
- **Estágios profissionais:** A medida estágios profissionais visa complementar e desenvolver as competências dos jovens que procuram um primeiro ou um novo emprego, de forma a melhorar o seu perfil de empregabilidade, através da aquisição de novas formações e competências junto das empresas, com vista à criação de emprego, nomeadamente em novas áreas profissionais tendo como objetivo o apoio à transição entre o sistema de qualificações e o mercado de trabalho.

No âmbito do Programa Operacional da Inclusão Social e do Emprego (POISE), as medidas identificadas foram ATIVAR.PT, Estágios ATIVAR.PT, Emprego Jovem Ativo e Apoios à Contratação – Redução da Taxa Única Social (TSU) e Isenção da TSU. Dentro do Programa Operacional Regional do Algarve, tem-se Programa FormAlgarve e os Estágios PEPAL. O Programa Operacional Regional dos Açores tem o INTREGA, o Programa de Incentivo à Inserção do Estagiar (PIIE), o Programa Emprego + e ELP contratação. Por fim, do Programa Operacional Regional da Madeira, identificou-se o Programa de Incentivos à Contratação, os Estágios REATIVAR e os Estágios para Jovens.

## 2.2 Revisão de literatura

### 2.2.1 Diferença-em-diferenças

Considerando um caso com  $T$  períodos temporais e sendo  $t$  um período particular, onde  $t = 1, \dots, T$ , o método DiD canónico tem  $T = 2$ , ou seja, considera dois períodos. Para  $s$  áreas geográficas (que podem ser, por exemplo “zonas de abrangência”) é possível observar dois potenciais resultados:

- $y_{1ist}$  = representa o resultado para o indivíduo  $i$  no período  $t$  se reside na zona objeto de tratamento;
- $y_{0ist}$  = representa o resultado para o indivíduo  $i$  no período  $t$  se reside fora da zona objeto de tratamento.

O interesse reside na estimativa consistente do efeito tratamento de uma dada política pública para o conjunto dos indivíduos  $i$  residentes na zona  $s$  abrangida por essa política pública.


A estimação deste modelo implica a observância de quatro hipóteses fundamentais. A primeira, central a todas as aplicações do método DiD, é a de que o grupo de controlo que não recebe o efeito tratamento exibe uma tendência paralela ao grupo tratado. As restantes hipóteses – desconsideradas até às mais recentes inovações metodológicas – têm que ver como a “homogeneidade” do efeito de tratamento, e essencialmente assumem que as datas de tratamento são iguais para todas as unidades, que os tratamentos têm a mesma dimensão para todas as unidades tratadas e que não existem diferentes estados de tratamento ao longo do tempo.

Verificadas as hipóteses acima referidas, o estimador DiD canónico pode ser obtido através da seguinte regressão:

$$y_{ist} = \alpha + \gamma T + \delta D + \tau(T \times D) + \epsilon_{ist}$$

Onde  $T$  representa uma variável dummy que identifica os grupos (por exemplo, regiões) e  $D$  representa uma variável dummy que assume o valor 0 antes do tratamento, e 1 após o tratamento. O coeficiente de interesse, que fornece uma estimativa do impacto da política pública, é dado pelo parâmetro  $\tau$ . A Figura 1 fornece uma ilustração gráfica das hipóteses e da estimativa subjacente ao método das diferenças nas diferenças.

Figura 1. Método DiD canónico




Fonte: Clark, D. Microeconometrics with Matlab.

O método DiD canónico contém dois períodos, antes e depois do tratamento, e dois grupos, o tratado e não-tratado (ou de controlo). Contudo, a generalidade das aplicações de DiD têm grupos de observações que receberam tratamento a momentos diferentes, ou seja, tem-se múltiplos períodos de tratamento e estados de tratamento.

Quando existe desfasamento temporal no efeito tratamento, a estimativa dos efeitos de tratamento através do OLS pode ser bastante enviesada como estimativa de uma média ponderada dos efeitos de tratamento, dado as observações “já tratadas” serem usadas como controlos das estimativas “ainda não tratadas” nos períodos futuros, originando estimativas com um enviesamento médio negativo ou mesmo com o sinal errado (Goodman-Bacon (2020), ver Figura 2). Neste contexto, surgiram estimadores alternativos que permitem ultrapassar este obstáculo.

Figura 2. Método DiD canónico, as suas limitações e os desenvolvimentos recentes



Fonte: DiD com múltiplos períodos de tratamento (três grupos) – Goodman-Bacon (2019)

Na presente secção, considerar-se-á os seguintes pressupostos:

- **Pressuposto 1:**  $\{y_{is1}, y_{is2}, \dots, y_{isT}, D_{is1}, \dots, D_{isT}\}$  (onde  $i$  corresponde ao indivíduo,  $s$  área geográfica e  $T$  o número de períodos temporais considerados) é independente e identicamente distribuído (iid). Este pressuposto implica que se considera dados de painel.
- **Pressuposto 2:** Para  $t = 2, \dots, T$ ,  $D_{t-1} = 1$  implica que  $D_t = 1$ . Isto significa que o tratamento é irreversível, ou seja, uma vez que a unidade seja tratada, mantém-se tratada.
- **Pressuposto 3:** Não existe efeito de antecipação do tratamento para as unidades tratadas.
- **Pressuposto 4:** Nenhuma unidade é tratada no primeiro período, isto é, não há um grupo de unidades de observação “sempre tratado”.

### 2.2.2 Estimador De Chaisemartin & D’Haultfoeuille (2020)

A solução geral proposta por De Chaisemartin & D’Haultfoeuille (2020) (doravante dCD) baseia-se na atribuição de um peso a cada grupo que depende da sua frequência nos dados. Tipicamente, utiliza-se regressões lineares com efeitos fixos no grupo e período (*TWFE - Two-Way Fixed Effects*) para estimar o efeito de tratamento. dCD mostrou que a soma ponderada por pesos dos efeitos de tratamento médios (“*average treatment effects (ATE)*”) em cada grupo e período, pode ter pesos negativos, o que pode enviesar os resultados.

O estimador alternativo proposto permite ultrapassar este problema e estima o efeito do tratamento em observações que mudam de estado de tratamento, no momento que passam de não-tratados a tratados, isto é, no momento em que recebem o tratamento. Deste modo, não depende de nenhuma condição de homogeneidade do efeito do tratamento.

Matematicamente, sendo  $G_g$  uma variável binária que toma o valor 1 se uma unidade é tratada no período  $g$ , o efeito é dado por:

$$\delta = E \left[ \frac{\sum_{i=1}^n \sum_{t=2}^T G_{ig} \cdot (y_{1it} - y_{0it})}{\sum_{i=1}^n \sum_{t=2}^T G_{it}} \right]$$

Esta estimativa é mais adequada quando estamos a analisar efeitos de tratamento instantâneos.

Também em De Chaisemartin & D'Haultfoeuille (2020) (secção 4) é proposta uma extensão do estimador para casos com muitos grupos e muitos períodos. Para cada par de períodos de tempo consecutivos  $t-1$  e  $t$  e para cada valor do tratamento  $D$ , calcula-se um estimador DID comparando a evolução do resultado entre os grupos que mudam de estado de tratamento (*switchers*), entre  $t-1$  e  $t$ , com a evolução para o mesmo período, entre os grupos controlo.

O estimador,  $DID_M$ , é igual à média destes DIDs em todos os pares de períodos de tempo consecutivos e em todos os valores do tratamento. Assim, permite calcular os efeitos dinâmicos de tratamentos dos *switchers*, um período de tempo ou mais, após terem começado a receber o tratamento.

### 2.2.3 Estimador Callaway & Sant'Anna (2020)

Callaway & Sant'Anna (2020) (doravante CS) propuseram um outro estimador que centra a análise no efeito médio de tratamento no momento  $t$  para o grupo de observações tratadas no período  $g$ :

$$ATT(g, t) = E[y_{1it} | G_g = 1] - E[y_{0it} | G_g = 1]$$

Ou seja, irá analisar-se tantos efeitos médios de tratamento quanto grupos tratados. No caso de haver muitos grupos tratados em períodos diferentes, pode ser um procedimento computacionalmente exigente.

Como grupo de controlo, pode recorrer-se às unidades nunca tratadas e às unidades ainda por tratar. Ainda é possível agregar os efeitos de tratamento médios de cada grupo a outros parâmetros para resumir de forma concisa a heterogeneidade em relação a alguma dimensão particular de interesse (como o tempo de exposição ao tratamento) ou, alternativamente, agregar num único parâmetro geral.

### 2.2.4 Estimador Sun & Abraham (2020)

Tipicamente, para estimar os efeitos dinâmicos de um tratamento, recorre-se a regressões de efeitos fixos (TWFE) que incluem os períodos antes e após o tratamento.

Sun & Abraham (2020) (doravante SA) mostraram que, com a variação no tempo de tratamento entre as unidades, os coeficientes do efeito desfasado do tratamento podem ser contaminados pelos efeitos de outros períodos, surgindo aparentes pré-tendências. Como tal, propuseram um estimador alternativo, livre desta contaminação, o estimador “interaction-weighted” (IW) para estimar o efeito dinâmico de tratamento. Os estimadores IW são calculados primeiro estimando o efeito médio de tratamento de cada coorte (“*cohort-specific average*”).

*treatment Effect* – CATT) através de uma regressão com indicadores de coorte (sendo cada coorte, cada grupo de unidades tratadas no mesmo período) e do período relativo ( $e$ ):

$$y_{it} = \lambda_i + \lambda_t + \sum_{g=2}^{T-1} \sum_{e \neq 0} \delta_{ge} \cdot G_{ig} 1\{t - G_i + 1 = e\} + v_{it}$$

Onde,  $\lambda_i$  e  $\lambda_t$  são os efeitos fixos na unidade de observação e no tempo, respetivamente.

De seguida, calculam a média dos CATT para cada período. Estes estimadores são fáceis de implementar e robustos a efeitos de tratamento heterogéneos em coortes.

## 2.2.5 Estimador Borusyak, Jaravel, and Spiess (2021)

Por fim, Borusyak, Jaravel, and Spiess (2021) (doravante BJS) propuseram um estimador eficiente para o método DiD com múltiplos períodos e estados de tratamento (*“staggered designs”*) que assume uma forma de “imputação”. O procedimento é o seguinte:

1. Para as observações não tratadas, estima por OLS a seguinte regressão:

$$y_{it} = \lambda_i + \lambda_t + v_{it}$$

Onde obtém os efeitos fixos no tempo e na unidade de observação.

2. Para cada unidade tratada, subtrai o valor estimado no passo anterior, ao valor associado a esta unidade, para obter uma estimativa do tratamento. Ou seja, sendo,  $y_{0it}$  o resultado de uma unidade  $i$  no momento  $t$ , que não foi tratada e  $y_{1it}$  uma unidade  $i$  no momento  $t$ , tratada e  $D_{it}$  uma variável binária que indica o tratamento, tem-se:

$$y_{0it} = \lambda_i + \lambda_t + v_{it}$$

$$y_{1it} = \lambda_i + \lambda_t + \tau_{it} + v_{it}$$

$$y_{0it} - y_{1it} = \tau_{it}$$

O racional deste procedimento é que a estimativa do efeito de tratamento (de cada unidade tratada, num período específico) é dada pela diferença entre o valor ajustado no ponto 1 (do grupo de controlo) e o valor observado para essa mesma unidade tratada.

3. Por fim, agrega-se os efeitos de tratamento numa média ponderada. Os pesos podem variar de acordo com o estudo, tipicamente para estudos de evento, considera-se o efeito médio de  $h$  períodos desde o tratamento.

Este desenvolvimento apresenta uma maior eficiência computacional, face aos restantes.

## 2.2.6 Pressuposto das tendências paralelas

Nesta subsecção, apresentamos algumas considerações sobre os pressupostos de tendências paralelas considerados pelos estimadores apresentados anteriormente. Visualmente, o pressuposto de tendências paralelas pode ser observado na Figura 2. No momento pré-tratamento, tem-se a variável de resultado para cada unidade de observação, com trajetórias paralelas. No contexto dos estimadores, o primeiro pressuposto é invocado por dCD, SA e BJS:

- **Pressuposto 5 (Tendências paralelas para todos os períodos temporais e para todos os grupos):** Implica que, na ausência de tratamento, é esperado que a variável de resultado siga a mesma trajetória em todos os grupos para todos os períodos disponíveis na amostra. Este pressuposto impõe a existência de pré-tendências paralelas para todos os grupos tratados, e, como consequência, permite que se utilize qualquer grupo que não tenha sido ainda tratado, como grupo de controlo. Matematicamente, para todo  $t = 2, \dots, T$ ,  $g = 2, \dots, T$ :

$$E[y_{0t} - y_{0t-1} | G_g = 1] = E[y_{0t} - y_{0t-1} | C = 1] = E[y_{0t} - y_{0t-1}]$$

Os dois segundos pressupostos são invocados por CS:

- **Pressuposto 6 (Tendências paralelas baseadas nas unidades “nunca tratadas”):** Apenas utiliza o grupo de unidades “nunca tratadas” como grupo de controlo. Este pressuposto não implica que as unidades “ainda-por-tratar” sejam utilizadas como grupo de comparação para as unidades “tratadas cedo”. Deste modo, apenas impõe a existência de pré-tendências paralelas entre os grupos tratados e os grupos nunca tratados. Deste modo, é um pressuposto mais “fraco” que o pressuposto 5. Matematicamente, para todo  $g, t = 2, \dots, T$ , onde  $t \geq g$ :

$$E[y_{0t} - y_{0t-1} | G_g = 1] = E[y_{0t} - y_{0t-1} | C = 1]$$

- **Pressuposto 7 (Tendências paralelas baseadas nas unidades “ainda-por-tratar”):** Implica a existência de pré-tendências paralelas, nos períodos antes da primeira unidade ser tratada. Matematicamente, para todo  $g, t = 2, \dots, T$ , onde  $t \geq g, s \geq t$ :

$$E[y_{0t} - y_{0t-1} | G_g = 1] = E[y_{0t} - y_{0t-1} | D_s = 0]$$



## 2.2.7 Tabela Síntese

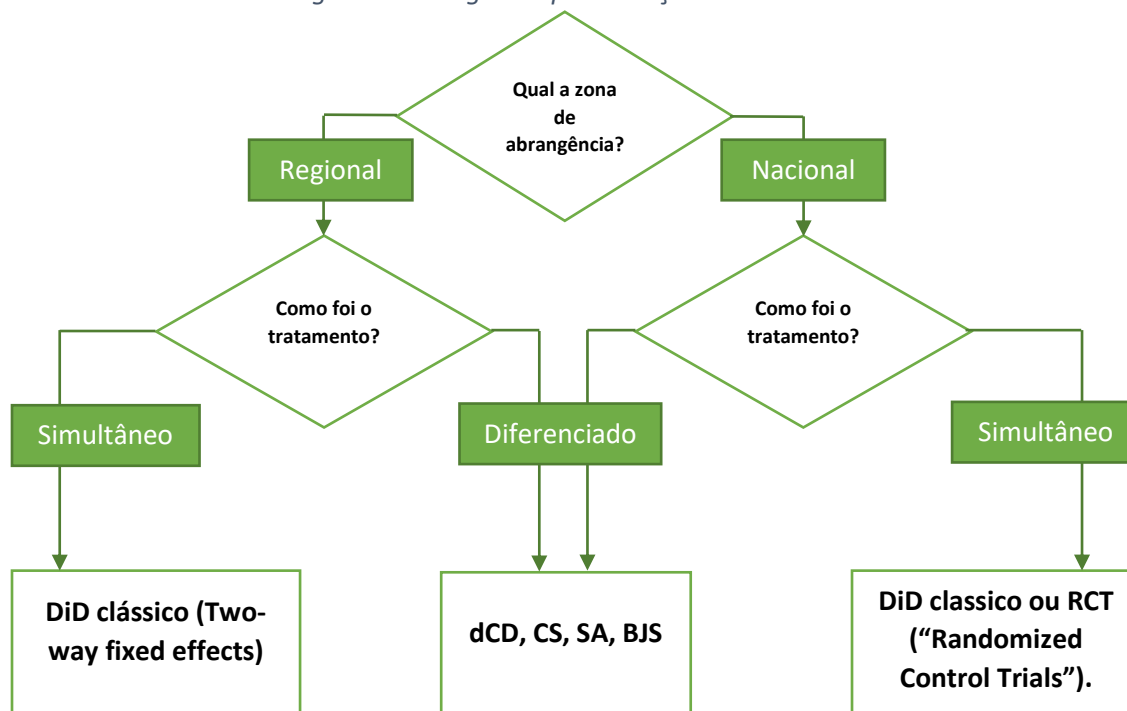
Tabela 1. Tabela Síntese

Estimador	Efeito	Tratamento	Vantagens	Desvantagens
<b>DiD canónico</b>	Efeito médio de tratamento	Tratamento é administrado ao mesmo tempo aos indivíduos a ser tratados.	Simple de aplicar e interpretar	Requer que o pressuposto de tendências paralelas se verifique; contexto de aplicabilidade é difícil de se verificar.
<b>De Chaisemartin &amp; D'Haultfoeuille (2020)</b>	Efeito médio de tratamento por período (i.e., efeito dinâmico)	Tratamento é administrado em momentos diferentes aos grupos tratados	Propõe um estimador alternativo que considera a heterogeneidade no efeito de tratamento dentro de cada grupo, atribuindo um peso de acordo com a sua frequência.	Requer que o pressuposto de tendências paralelas se verifique; Podem ser exigentes computacionalmente
<b>Callaway &amp; Sant'Anna (2020)</b>	Efeito de tratamento por grupo e por período (i.e., efeito dinâmico)		Permite estimar efeitos de tratamento heterogêneos por grupo e período.	
<b>Sun &amp; Abraham (2020)</b>	Efeito de tratamento por período (i.e., efeito dinâmico)		Permite estimar efeitos de tratamento heterogêneos; interpretar as estimativas de especificações <i>two-way fixed effects</i> quando se inclui regressores dinâmicos; propõe uma estratégia de estimação mais sensível que a convencional, utilizando como controlo a última coorte a ser tratada; é mais eficiente computacionalmente que Callaway & Sant'Anna (2020).	
<b>Borusyak, Jaravel, and Spiess (2021)</b>	Efeito médio de tratamento por período (i.e., efeito dinâmico)		Permite estimar efeitos de tratamento heterogêneos; é mais eficiente computacionalmente que os restantes métodos.	Requer que o pressuposto de tendências paralelas se verifique.

## 2.2.8 Seleção do estimador

De um ponto de vista prático, a questão que a se coloca é que metodologia escolher para avaliar políticas públicas. O fluxograma apresentado abaixo procura ajudar na secção do modelo mais adequado para essa escolha.

*Figura 3. Fluxograma para seleção do estimador*



Em particular, a identificação das etapas de aplicação encontra-se ligada à conceptualização teórica da intervenção e à correspondente identificação dos grupos de controlo e tratamento. A estratégia empírica será condicional ao contexto de cada política, destacando-se os três casos limite:

1. Se a zona de abrangência excluir certas regiões e o tratamento for simultâneo usar-se-á o método DiD canónico ou clássico, usando como grupo de controlo as regiões excluídas.
2. Se a zona de abrangência for nacional e o tratamento for simultâneo, isso exclui a utilização da região como grupo de controlo e só poderá recorrer-se aos métodos quase-experimentais DiD, caso se encontre outro grupo de controlo credível, e que por uma razão exógena não tenha sido submetido ao tratamento. Atendendo à abrangência das medidas de âmbito nacional e aplicação simultânea, isso não é frequentemente possível, sendo a única alternativa disponível o recurso a métodos puramente experimentais, tais como os "Randomized Control Trials" (RCT).

3. Caso a zona de abrangência for o conjunto do território nacional, mas se o tratamento for desfasado no tempo (*“staggered designs”*) utilizar-se-ão os métodos DiD com efeitos heterógenos no tempo, tal como apresentados anteriormente.

Considerando as operações selecionadas para avaliação na secção 2.1, apresentamos alguns exemplos de como selecionar o tipo de estimador:

#### **Caso 1: Avaliação dos Estágios REATIVAR (Programa Operacional Regional da Madeira)**

Os estágios REATIVAR visam promover a reintegração profissional de pessoas desempregadas de longa e de muita longa duração e propiciar um contacto com o mercado de trabalho, em contexto de formação, através da aquisição de competências, obedecendo a um plano de estágio, com vista ao reingresso no mercado de trabalho. Pretende-se avaliar o impacto deste programa na empregabilidade dos seus participantes, assumindo que os indivíduos entram e saem do estágio, simultaneamente.

No caso deste programa a ferramenta indicada para a sua avaliação seria o método DiD canónico, dado que a zona de abrangência é regional e o tratamento é em simultâneo, e com base no pressuposto de tendências paralelas entre a Madeira e as regiões selecionadas como grupos de controlo.

#### **Caso 2: Impacto do programa INTREGA (Programa Regional dos Açores)**

O programa INTREGA visa a promoção de criação de novos postos de trabalho através da atribuição de um apoio financeiro às entidades empregadoras. Pretende-se avaliar o impacto deste programa na remuneração dos seus participantes. O apoio financeiro às entidades empregadoras é realizado após a celebração do contrato. Os participantes não são contratados simultaneamente.

No caso deste programa, também a ferramenta indicada para efetuar a sua avaliação seria o método DiD com *staggered designs*, dado que a zona de abrangência é regional e o tratamento não é simultâneo.

## 2.2.9 Implementação Computacional

A implementação computacional dos estimadores DiD com efeitos heterogêneos, bem como o cálculo das suas matrizes de variâncias-covariâncias, são bem mais complexos e computacionalmente exigentes de estimar do que o método DiD clássico, dado que envolvem processos de agregação de efeitos de tratamento de acordo com frequências amostrais (ou outros critérios), em vez da simples estimação de regressões através do método OLS. Assim, ao contrário do que ocorre com o método DiD canónico, não é possível estimar os efeitos e tratamento das políticas públicas apenas com base em comandos de packages estatísticos convencionais.

A “revolução” metodológica do método DiD tem sido acompanhada pelo desenvolvimento de rotinas que permitem implementar os cada vez mais complexos estimadores DiD com efeitos heterogêneos. Na Tabela 2 apresentamos as *packages* existentes para cada uma das metodologias DiD com efeitos heterogêneos:

*Tabela 2. Implementação Computacional*

STATA	R	Artigo
bacondecomp	bacondecomp	Goodman-Bacon (2021)
csdid	did	Callaway & Sant’Anna, (2020)
did_multiplegt	DIDmultiplegt	De Chaisemartin & D’Haultfoeuille (2020)
did_imputation	didimputation	Borusyak, Jaravel, & Spiess (2021)
eventstudyinteract	sunab	Sun & Abraham (2020)

### 2.2.9.1 De Chaisemartin & D’Haultfoeuille (2020)

O comando `did_multiplegt` permite obter o estimador proposto por dCH. A instalação da package é feita através do comando:

```
ssc install did_multiplegt, replace
```

O comando principal é:

```
did_multiplegt Y G T D
```

onde

Variável	Descrição
Y	Variável do resultado
G	Variável do grupo
T	Variável do tempo
D	Variável binária do tratamento (=1 se foi tratado)

As opções padrão são:

Opção	Descrição
<code>robust_dynamic</code>	Se esta opção não for especificada, então o estimador (Chaisemartin and D'Haultfoeuille (2020a)) é calculado, caso contrário, o estimador considerado é Chaisemartin and D'Haultfoeuille (2020b).
<code>dynamic(#)</code>	Número de desfasamentos a ser estimado.
<code>placebo(#)</code>	Número de avanços a ser estimado.
<code>breps(#)</code>	Número de replicações <i>bootstrap</i>
<code>seed(#)</code>	Seed para a replicação de breps
<code>cluster(varname)</code>	Variável de cluster da matriz de variâncias
<code>average_effect</code>	O efeito médio de ser tratado (requer a opção <code>robust_dynamic</code> )
<code>longdiff_placebo</code>	Para testar se a hipótese das tendências paralelas se verifica (requer a opção <code>robust_dynamic</code> )

### 2.2.9.2 Callaway & Sant'Anna (2021)

O comando `csdid` de Callaway e Sant'Anna foi originalmente lançado como um pacote R, e posteriormente codificado em Stata.

Este comando pode ser lento, dado que calcula todas as combinações 2x2 possíveis. Se os tempos de tratamento e observações tratadas forem muito heterogêneas, não é aconselhado.

A instalação é realizada através:

```
ssc install csdid, replace
```

O comando principal é:

```
csdid Y [ind vars], [ivar(varname)] time(varname) gvar(varname) [options]
```

onde

Variável	Descrição
Y	Variável de resultado
ivar	ID do painel
time	Variável do tempo
gvar	Tempo do tratamento (0 para grupos nunca tratados)

As opções são:

Opção	Descrição
notyet	Para utilizar os grupos ainda-não-tratados como controlo
wboot	Opções para <i>wild bootstrap</i>
rseed(#)	control the seeding for the bootstraps
cluster(var)	Variável de cluster para estimar a matriz de variâncias
level(#)	Para definir um nível de confiança dos intervalos diferente (o valor por defeito é 95%)

Por fim, podemos definir as opções de agregação das estimativas:

Opção	Descrição
simple	Efeito de tratamento médio (ATT)
group	Efeito de tratamento médio (ATT) por grupos
calendar	Efeito de tratamento médio (ATT) por período
event	Especificação de <i>event study</i>

### 2.2.9.3 Estimador Sun & Abraham (2020)

Por fim, o comando `eventstudyinterac`, a instalação é realizada através do comando:

```
ssc install eventstudyinteract, replace
```

A sintaxe é:

```
eventstudyinteract Y *lags* *leads*, vce(cluster *var*) absorb(*i* *t*)
cohort(first_treat) control_cohort(*variable*)
```

onde:

Variável	Descrição
Y	Variável de Resultado
i	ID do painel
t	Variável do tempo
lags	Variável de desfasamento gerada manualmente
leads	Variável de avanço gerada manualmente
first_treat	Tempo de tratamento (omisso para grupos não tratados)
control_cohort (var)	Definição do grupo de controlo: nunca tratado ou ainda-por-tratar

#### 2.2.9.4 Estimador Borusyak, Jaravel, and Spiess (2021)

O `did_imputation` do Stata é instalado através de:

```
ssc install did_imputation, replace
```

O comando é:

```
did_imputation Y i t first_treat
```

onde:

Variável	Descrição
Y	Variável de resultado
i	ID do painel
t	Variável do tempo
first_treat	Tempo do tratamento (0 para grupos nunca tratados)

#### 2.2.10 Aplicação computacional e simulação de resultados

Na presente secção apresentamos um conjunto de simulações e estimação dos modelos através das metodologias apresentadas anteriormente.

##### 2.2.10.1 Diferença-em-diferenças

##### 2.2.10.1.1 Demonstração 1: Duas unidades e dois períodos

Vamos começar por simular uma estrutura de painel, com duas unidades e dois períodos temporais:

```
clear
local units = 2
local start = 1
local end = 2

local time = `end' - `start' + 1
local obsv = `units' * `time'
set obs `obsv'

egen id = seq(), b(`time')
egen t = seq(), f(`start') t(`end')

sort id t
xtset id t

lab var id "Variável de Painei"
lab var t "Variável do Tempo"
```

De seguida, definimos o grupo de tratamento e o processo gerador de dados:

```
gen D = id==2 & t==2


gen btrue = cond(D==1, 2, 0)
gen Y = id + 3*t + btrue*D
```

De acordo com a última linha, o efeito do tratamento deverá ter um impacto de 3 unidades em Y no grupo tratado (id=2).

```
lab de prepost 1 "Pre" 2 "Pos"
lab val t prepost

twoway ///
    (connected Y t if id==1) ///
    (connected Y t if id==2) ///
    , legend(order(1 "id=1" 2 "id=2")) ///
    xlabel(1 2, value label) ylabel(4(1)10)
```

Figura 4. Diferença-em-diferenças: Demonstração 1





Pelo gráfico gerado podemos verificar que a diferença entre as linhas azul e laranja é cerca de 3 unidades no período pós-tratamento e 1 unidade no período pré-tratamento. Estas estimativas também se podem obter através da estimação da regressão:

```
xtset id t
xtreg Y D t, fe
```

```
Fixed-effects (within) regression      Number of obs   =          4
Group variable: id                    Number of groups =          2

R-sq:                                Obs per group:
    within = 1.0000                      min =          2
    between = 1.0000                     avg =         2.0
    overall = 0.9550                     max =          2

corr(u_i, Xb) = 0.2357                  F(0,1)          =          .
                                      Prob > F          =          .

                                     (Std. Err. adjusted for 2 clusters in id)
```

Y	Coef.	Robust Std. Err.	t	P> t	[95% Conf. Interval]
D	2	.	.	.	.
t	3	.	.	.	.
_cons	1.5	.	.	.	.
sigma_u	.70710678				
sigma_e	.				
rho	.	(fraction of variance due to u_i)			

```
.
end of do-file
```

```
ssc install reghdfe
reghdfe Y D, absorb(id t)
```

```
(MWFE estimator converged in 2 iterations)
warning: missing F statistic
```

```
HDFE Linear regression      Number of obs   =          4
Absorbing 2 HDFE groups    F( 1, 0)       =          .
                           Prob > F       =          .
                           R-squared       =         1.0000
                           Within R-sq.   =         1.0000
                           Root MSE     =         0.0000
```

Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
D	2	.	.	.	.
_cons	6	.	.	.	.

```
Absorbed degrees of freedom:
```

Absorbed FE	Categories	- Redundant	= Num. Coefs
id	2	0	2
t	2	1	1

```
.
end of do-file
```

Releva-se que, devido ao número reduzido de observações no presente exemplo, a matriz de variâncias não é estimada e, consequentemente, os erros padrão e inferência sobre as estimativas não aparecem no output.

#### 2.2.10.1.2 Demonstração 2: Duas unidades, mais de dois períodos

Na segunda demonstração, em vez de 2 períodos temporais, irá considerar-se 10 períodos temporais por cada unidade:

```
clear
local units = 2
local start = 1
local end = 10

local time = `end' - `start' + 1
local obsv = `units' * `time'
set obs `obsv'

egen id      = seq(), b(`time')
egen t      = seq(), f(`start') t(`end')

sort id t
xtset id t

lab var id "Variável de Painei"
lab var t "Variável Temporal"
```

Definimos, novamente, o tratamento para id = 2, em que a variável de resposta aumenta 3 unidades no período 5:


```
gen D = id==2 & t>=5
lab var D "Tratados"

gen btrue = cond(D==1, 3, 0)

gen Y = id + t + btrue*D
lab var Y "Resultado"

twoway ///
    (connected Y t if id==1) ///
    (connected Y t if id==2) ///
    ,
    legend(order(1 "id=1" 2 "id=2")) ///
    xline(4.5) xlabel(1(1)10) ylabel(0(1)15)
```

Figura 5. Diferença-em-diferenças: Demonstração 2



Estimando os efeitos através das mesmas funções, tem-se que o efeito da intervenção é igual 3. A constante é 1.5, correspondendo ao valor médio das linhas azul e laranja para  $t = 0$ .

xtreg Y D t, fe

Fixed-effects (within) regression  
Group variable: id

Number of obs = 20  
Number of groups = 2

R-sq:

within = 1.0000  
between = 1.0000  
overall = 0.9842

Obs per group:

min = 10  
avg = 10.0  
max = 10

corr(u\_i, Xb) = 0.2428

F(2,16) = .  
Prob > F = .

Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
D	3	.	.	.	.	.
t	1	.	.	.	.	.
_cons	1.5	.	.	.	.	.
sigma_u	.70710678					
sigma_e	0					
rho	1 (fraction of variance due to u_i)					

F test that all u\_i=0: F(1, 16) = .

Prob > F = .

```
reghdfe Y D, absorb(id t)
. reghdfe Y D, absorb(id t)
(MWFE estimator converged in 2 iterations)
warning: missing F statistic; dropped variables due to collinearity or too few clusters
```

```
HDFE Linear regression
Absorbing 2 HDFE groups

Number of obs   =          20
F( 1, 8)        =          .
Prob > F        =          .
R-squared       =         1.0000
Adj R-squared   =         1.0000
Within R-sq.   =         1.0000
Root MSE       =         0.0000
```

	Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
	D	3	7.37e-16	4.1e+15	0.000	3
	_cons	7	2.85e-16	2.5e+16	0.000	7

Absorbed degrees of freedom:

Absorbed FE	Categories	- Redundant	= Num. Coefs
id	2	0	2
t	10	1	9

```
.
end of do-file
```

### 2.2.10.1.3 Demonstração 3: Mais unidades, mesmo período de tratamento, efeitos de tratamento diferentes

Para o terceiro caso, vamos considerar três unidades, que foram tratadas no mesmo período, com efeitos de tratamento diferentes:

```
clear
local units = 3
local start = 1
local end    = 10

local time = `end' - `start' + 1
local obsv = `units' * `time'
set obs `obsv'

egen id    = seq(), b(`time')
egen t    = seq(), f(`start') t(`end')

lab var id "Variável de Paine1"
lab var t  "Variável de Tempo"

sort id t
xtset id t

gen D = 0
replace D = 1 if id>=2 & t>=5
lab var D "Tratamento"


cap drop Y
gen Y = 0
replace Y = cond(D==1, 2, 0) if id==2
replace Y = cond(D==1, 4, 0) if id==3

lab var Y "Resultado"

twoway ///
```

```
(connected Y t if id==1) ///
(connected Y t if id==2) ///
(connected Y t if id==3) ///
,
xline(4.5) ///
xlabel(1(1)10) ///
legend(order(1 "id=1" 2 "id=2" 3 "id=3"))
```

Figura 6. Diferença-em-diferenças: Demonstração 3



Podemos verificar que o pós-tratamento tem um efeito médio de 2 unidades para o id=2 e de 4 unidades para o id=3. Isto implica que o efeito médio de tratamento (“average treatment effect”) seja de 3 unidades, tal é possível verificar através dos coeficientes:

```
xtreg Y D t, fe
```

```
Fixed-effects (within) regression
Group variable: id

R-sq:
  within = 0.9000
  between = 0.7500
  overall = 0.8438

Number of obs   = 30
Number of groups = 3

Obs per group:
  min = 10
  avg = 10.0
  max = 10

corr(u_i, Xb) = -0.0000

F(2,25) = 112.50
Prob > F = 0.0000
```

Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
D	3	.2786522	10.77	0.000	2.426105 3.573895
t	-2.19e-16	.0388057	-0.00	1.000	-.0799218 .0799218
_cons	0	.1767684	0.00	1.000	-.3640613 .3640613
sigma_u	.6				
sigma_e	.43817805				
rho	.65217391	(fraction of variance due to u_i)			

```
F test that all u_i=0: F(2, 25) = 18.75
Prob > F = 0.0000

.
end of do-file
```

#### 2.2.10.1.4 Demonstração 4: Mais unidades, mesmo período de tratamento, efeitos de tratamento diferentes, controlando o tempo e indivíduo

Considerando o exemplo anterior, é possível analisar o efeito médio do tratamento, assumindo que este não varia no tempo nem com o painel (i.e., indivíduo). Se os efeitos variam de acordo com o tempo e com o indivíduo, os resultados tornam-se mais complexos.

```
clear
local units = 3
local start = 1
local end = 10

local time = `end' - `start' + 1
local obsv = `units' * `time'
set obs `obsv'

egen id = seq(), b(`time')
egen t = seq(), f(`start') t(`end')

sort id t
xtset id t

lab var id "Variável de Painel"
lab var t "Variável do Tempo"

gen D = 0
replace D = 1 if id>=2 & t>=5
lab var D "Tratamento"


cap drop Y
gen Y = 0
replace Y = id + t + cond(D==1, 0, 0) if id==1
replace Y = id + t + cond(D==1, 2, 0) if id==2
replace Y = id + t + cond(D==1, 4, 0) if id==3

lab var Y "Resultado"

twoway ///
```

```
(connected Y t if id==1) ///
(connection Y t if id==2) ///
(connection Y t if id==3) ///
,
xline(4.5) ///
xlabel(1(1)10) ///
legend(order(1 "id=1" 2 "id=2" 3 "id=3"))
```

Figura 7. Diferença-em-diferenças: Demonstração 4



A partir do exemplo anterior, sabemos que o efeito médio de tratamento corresponde a 3 unidades, contudo no gráfico este efeito não é claro. Isto é porque temos de omitir os efeitos do tempo e de painel:

```
xtreg Y D t, fe
```

```
Fixed-effects (within) regression
Group variable: id

Number of obs   =      30
Number of groups =       3

R-sq:
  within = 0.9891
  between = 0.7500
  overall = 0.9193

Obs per group:
  min = 10
  avg = 10.0
  max = 10

corr(u_i, Xb) = 0.1346

F(2,25) = 1132.03
Prob > F = 0.0000
```

Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
D	3	.2786522	10.77	0.000	2.426105	3.573895
t	1	.0388057	25.77	0.000	.9200782	1.079922
_cons	2	.1767684	11.31	0.000	1.635939	2.364061
sigma_u	1.4					
sigma_e	.43817805					
rho	.91078067 (fraction of variance due to u_i)					

```
F test that all u_i=0: F(2, 25) = 82.84 Prob > F = 0.0000
```

```
.
end of do-file
```

O efeito médio de tratamento pode ser avaliado controlando o tempo, o painel ou ambos da seguinte forma:

```
reg Y D // não controla nenhum efeito
reg Y D i.t // controla apenas os efeitos fixos no tempo
reg Y D i.id // controla os efeitos no indivíduo (painel)
reg Y D i.t i.id // controla os efeitos no tempo e indivíduo (correto!)
xtreg Y D i.id, fe
```

Quando o efeito de tratamento varia com a unidade de observação ou com o tempo, terá de se avaliar o efeito médio de tratamento controlando estes dois fatores, através das últimas linhas de código acima.

#### 2.2.10.1.5 Demonstração 5: Mais unidades, tempo de tratamento diferente e efeitos de tratamento diferentes

Por fim, o último caso, considera tempos de tratamento diferentes. O processo gerador de dados é dado pelo código:

```
clear
local units = 3
local start = 1
local end = 10

local time = `end' - `start' + 1
local obsv = `units' * `time'
set obs `obsv'

egen id = seq(), b(`time')
egen t = seq(), f(`start') t(`end')

sort id t
xtset id t

lab var id "Variável de Painel"
lab var t "Variável de Tempo"

gen D = 0
```




```
replace D = 1 if id==2 & t>=5
replace D = 1 if id==3 & t>=8
lab var D "Tratamento"

gen Y = 0
replace Y = D * 2 if id==2 & t>=5
replace Y = D * 4 if id==3 & t>=8

lab var Y "Resultado"

twoway ///
    (connected Y t if id==1) ///
    (connected Y t if id==2) ///
    (connected Y t if id==3) ///
    , ///
    xline(4.5 7.5) ///
    xlabel(1(1)10) ///
    legend(order(1 "id=1" 2 "id=2" 3 "id=3"))
```

Figura 8. Diferença-em-diferenças: Demonstração 5



A figura mostra que o id =2 é tratado no período 5 e continua tratado, enquanto o id=3 é tratado no período 8. Ao contrário dos exemplos anteriores, podemos calcular o efeito médio de tratamento, observando exclusivamente o gráfico. Embora não existam efeitos fixos no tempo e indivíduo, tempos de tratamento diferentes provocam diferenças significativas no tempo e no painel. Como tal, para obter o efeito médio de tratamento temos de recorrer ao código:

### xtreg Y D i.t, fe

```
Fixed-effects (within) regression
Group variable: id

Number of obs   =      30
Number of groups =       3

R-sq:
  within = 0.9125
  between = 0.7500
  overall = 0.8626

Obs per group:
  min = 10
  avg = 10.0
  max = 10

F(10,17) = 17.72
Prob > F = 0.0000

corr(u_i, Xb) = -0.3266
```

Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
D	2.909091	.3179908	9.15	0.000	2.238189	3.579993
t						
2	-1.52e-15	.385106	-0.00	1.000	-.8125025	.8125025
3	-1.53e-15	.385106	-0.00	1.000	-.8125025	.8125025
4	-1.55e-15	.385106	-0.00	1.000	-.8125025	.8125025
5	-.3030303	.399427	-0.76	0.458	-1.145748	.539687
6	-.3030303	.399427	-0.76	0.458	-1.145748	.539687
7	-.3030303	.399427	-0.76	0.458	-1.145748	.539687
8	.0606061	.4395998	0.14	0.892	-.8668685	.9880806
9	.0606061	.4395998	0.14	0.892	-.8668685	.9880806
10	.0606061	.4395998	0.14	0.892	-.8668685	.9880806
_cons	1.44e-15	.272311	0.00	1.000	-.5745261	.5745261
sigma_u	.44088566					
sigma_e	.47165654					
rho	.46631834	(fraction of variance due to u_i)				

F test that all u\_i=0: F(2, 17) = 7.23 Prob > F = 0.0053

.  
end of do-file

### reghdfe Y D, absorb(id t)

(MWFE estimator converged in 2 iterations)

```
HDFE Linear regression
Absorbing 2 HDFE groups

Number of obs   =      30
F( 1, 17) = 83.69
Prob > F = 0.0000
R-squared = 0.9284
Adj R-squared = 0.8778
Within R-sq. = 0.8312
Root MSE = 0.4717
```

Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
D	2.909091	.3179908	9.15	0.000	2.238189	3.579993
_cons	-.0727273	.1285144	-0.57	0.579	-.343869	.1984145

Absorbed degrees of freedom:

Absorbed FE	Categories	- Redundant	= Num. Coefs
id	3	0	3
t	10	1	9

Assim, pode-se concluir que efeito médio de tratamento é cerca de 2.91 unidades.

## 2.2.10.2 Decomposição de Bacon

### 2.2.10.2.1 Demonstração 1: Caso simples

A decomposição de Bacon é particularmente útil para compreender em que contexto o estimador de efeitos fixos do método DiD deixa de ser viável. Considerando o último exemplo em que os períodos de tratamento diferiam de acordo com a observação (id), não é claro o período pré e pós tratamento. A estimativa do efeito médio de tratamento pode ser obtida através dos comandos expostos no exemplo anterior.

A decomposição de Bacon permite decompor esta estimativa em três grupos distintos:

- *Tratado versus Nunca Tratado*
- *Tratado cedo versus Tratado tarde*
- *Tratado tarde versus Tratado cedo*

Por outras palavras, as observações do painel são divididas em diferentes coortes de acordo com o período de tratamento. Quantas mais observações tratadas em diferentes períodos, maior será o número de combinações dos grupos definidos acima.

No exemplo anterior (secção 2.2.10.1.5), temos duas observações tratadas: id=2 (tratado cedo) e id=3 (tratado tarde). O grupo *Tratado versus Nunca Tratado* também pode ser dividido em *Tratado cedo versus Tratado tarde* e *Tratado tarde versus Tratado cedo*.

```
bacondecomp Y D, ddetail
```

```
Calculating treatment times...
Calculating weights...
Estimating 2x2 diff-in-diff regressions...
```


```
Diff-in-diff estimate: 2.909
```

DD Comparison	Weight	Avg DD Est
Earlier T vs. Later C	0.182	2.000
Later T vs. Earlier C	0.136	4.000
T vs. Never treated	0.682	2.933

```
T = Treatment; C = Control
```

```
.
end of do-file
```

Figura 9. Decomposição de Bacon: Demonstração 1



A figura mostra quatro pontos de três grupos do exemplo anterior. O efeito médio de tratamento do grupo *Tratado versus Nunca Tratado* corresponde aos triângulos. Como temos o *id=2* e o *id=3* tratados, o eixo das ordenadas indica os valores 2 e 4, respetivamente. Estes valores correspondem ao aumento em *y* após o tratamento em cada *id*, como verificado na demonstração anterior. As cruces representam o grupo de *Tratado cedo versus Tratado Tarde* e *Tratado tarde versus Tratado cedo*. O eixo das abcissas indica os pesos de cada parâmetro.

#### 2.2.10.2.2 Demonstração 2: Caso TWFE não funciona

Até agora, considerámos um efeito de tratamento homogéneo. Neste exemplo, vamos considerar vários grupos, tratados em momentos diferentes, com o efeito de tratamento a variar ao longo do tempo. Começamos por criar o painel:

```
clear
local units = 30
local start = 1
local end   = 60

local time = `end' - `start' + 1
local obsv = `units' * `time'
set obs `obsv'

egen id      = seq(), b(`time')
egen t      = seq(), f(`start') t(`end')

sort id t
xtset id t

lab var id "Variável de Painel"
lab var t "Variável do Tempo"
```

Definimos a seed, para que os resultados sejam replicáveis:

```
set seed 13082021
```

Geramos as variáveis:

```
gen Y      = 0          // variável de resultado
gen D      = 0          // variável de intervenção
gen cohort = .          // total de variáveis tratadas
gen effect = .          // dimensão do efeito de tratamento
gen timing = .          // quando o tratamento ocorre para cada coorte
```

No código abaixo, associamos aleatoriamente cada id a uma coorte:

```
levelsof id, local(lvls)
foreach x of local lvls {
    local chrt = runiformint(0,5)
    replace cohort = `chrt' if id==`x'
}
```

E, por fim, definimos, aleatoriamente, a dimensão do efeito de tratamento e quando o tratamento ocorre:

```
levelsof cohort , local(lvls) // Não se considera um grupo nunca tratado
foreach x of local lvls {

    // (a) effect

    local eff = runiformint(10,15)
    replace effect = `eff' if cohort==`x'

    // (b) timing

    local timing = runiformint(`start'+5,`end' -5)
    replace timing = `timing' if cohort==`x'
    replace D = 1 if cohort==`x' & t>= `timing'
}
```


O efeito do tratamento varia entre 10 e 15 e o tempo de tratamento varia em t=5 e t=55. A variável de resultado é dada pelo código abaixo:

```
replace Y = id + t + cond(D==1, effect * (t - timing), 0)
```

O gráfico é obtido através do código:

```
xtline Y, overlay legend(off)
```

Figura 10. Decomposição de Bacon: Demonstração 2



Cada linha representa um id (unidade de observação), cada conjunto de linhas representa uma coorte (grupo tratado no mesmo período). Através da inspeção do gráfico, é possível concluir que o efeito de tratamento é positivo e aumenta ao longo do tempo. Pretendemos então, quantificar esse efeito:

reghdfe Y D, absorb(id t)

. reghdfe Y D, absorb(id t)  
(MWFE estimator converged in 2 iterations)

HDFFE Linear regression  
Absorbing 2 HDFFE groups

Number of obs =	1,800
F( 1, 1710) =	59.04
Prob > F =	0.0000
R-squared =	0.8359
Adj R-squared =	0.8273
Within R-sq. =	0.0334
Root MSE =	39.7334

Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
D	-25.93176	3.374793	-7.68	0.000	-32.55092 -19.3126
_cons	114.9349	1.997427	57.54	0.000	111.0172 118.8525

Absorbed degrees of freedom:

Absorbed FE	Categories	- Redundant	= Num. Coefs
id	30	0	30
t	60	1	59

De acordo com o output acima, o efeito de tratamento é negativo. Analisando a decomposição de Bacon:

```
. bacondecomp Y D, ddetail
Calculating treatment times...
Calculating weights...
Estimating 2x2 diff-in-diff regressions...
```

Diff-in-diff estimate: -25.932

DD Comparison	Weight	Avg DD Est
Earlier T vs. Later C	0.447	56.530
Later T vs. Earlier C	0.553	-92.545

T = Treatment; C = Control

Os grupos “Later T vs. Earlier C.” (*Tratados tarde versus Tratados cedo*) apresentam uma estimativa negativa, enviando o resultado final.

### 2.2.10.3 *did\_multiplegt*

Iremos começar a analisar os resultados do estimador dCD. O processo gerador de dados será o mesmo nas subsecções seguintes:

```
// Gerar painel de 400 observações e 15 periodos

clear all
timer clear
set seed 10
global T = 15
global I = 400

set obs `=$I*$T'
gen id = int((_n-1)/$T )+1          // id
gen t = mod((_n-1),$T )+1          // periodo
gen effect = .
tsset id t

// Gerar grupos de tratamento aleatoriamente, do periodo 10 ao 16

*Periodo quando a unidade é tratada
gen first_treat = ceil(runiform()*7)+$T -6 if t==1
bys id (t): replace first_treat = first_treat[1]

*Tempo relativo
gen rel_time = t-first_treat

*Variável binária do tratamento
gen D = rel_time>=0 & first_treat!=.

*Gerar aleatoriamente o efeito por cada grupo tratado
levelsof first_treat , local(lvls)
foreach x of local lvls {
    local eff = runiformint(2,5)
    replace effect = `eff' if first_treat==`x'
}

*Criar a variável de resposta a depender do id, do tempo e do efeito de tratamento
gen Y = id + t + cond(D==1, effect * rel_time, 0) + rnormal()

*O efeito de tratamento depende do grupo tratado e do tempo relativo*
```

Começamos por estimar os efeitos através do seguinte comando:

```
did_multiplegt Y id t D, robust_dynamic dynamic(5) placebo(5) breps(20) cluster(id)
```


```
. *Estimation
. did_multipligt Y id t D, robust_dynamic dynamic(5) placebo(5) breps(20) cluster(id)
```

DID estimators of the instantaneous treatment effect, of dynamic treatment effects if the dynamic option is used, and of placebo tests of the parallel trends assumption if the placebo option is used. The estimators are robust to heterogeneous effects, and to dynamic effects if the robust\_dynamic option is used.

	Estimate	SE	LB CI	UB CI	N	Switchers
Effect_0	.1196316	.0802151	-.03759	.2768533	1612	327
Effect_1	3.096465	.1201041	2.861061	3.331869	1202	270
Effect_2	5.019964	.0942877	4.83516	5.204768	846	216
Effect_3	7.092762	.1257523	6.846288	7.339237	544	157
Effect_4	10.122	.2452532	9.641306	10.6027	301	98
Effect_5	14.9027	.2906401	14.33305	15.47236	120	47
Placebo_1	-.0504606	.0928108	-.2323698	.1314487	1612	327
Placebo_2	-.0030868	.0807104	-.1612791	.1551056	1612	327
Placebo_3	-.0085218	.0949029	-.1945314	.1774878	1612	327
Placebo_4	.122315	.0696848	-.0142672	.2588971	1612	327
Placebo_5	-.1866539	.0829533	-.3492423	-.0240655	1612	327

```
event_plot e(estimates)#e(variances), default_look ///
graph_opt(xtitle("Períodos desde o evento") ytitle("Efeito médio de
tratamento")) ///
title("de Chaisemartin-D'Haultfoeuille (2020)") xlabel(-5(1)5))
stub_lag(Effect_#) stub_lead(Placebo_#) ///
plottype(scatter) ciplottype(rcap) together ///
lag_opt(msymbol(Dh) color(navy)) lag_ci_opt(color(navy))
```

Figura 11. Resultado did\_multipligt



O gráfico do evento indica o efeito de tratamento, isto é a diferença entre o tratado e o não tratado, até 5 períodos após o tratamento. Podemos verificar que, neste exemplo, o efeito aumenta ao longo do tempo. As estimativas dos períodos antes do tratamento ( $t=0$ ) são evidência a favor do pressuposto das tendências paralelas. Idealmente, o intervalo de confiança destas estimativas deverá se encontrar à volta do zero, indicando que antes do tratamento, a diferença entre os grupos era semelhante, isto é, os grupos seguiam trajetórias semelhantes.



#### 2.2.10.4 csdid


Para aplicar o estimador de CS, começa-se por criar a variável `gvar`. O resultado do comando `csdid` inclui os efeitos de tratamento para cada grupo em cada período, não se irá apresentar o output, devido à sua extensão. A partir destas estimativas, é possível obter um *event study*, a partir do qual se irá estudar o efeito dinâmico de tratamento:

```
gen gvar = first_treat
recode gvar (. = 0)
csdid Y, ivar(id) time(t) gvar(gvar) notyet
estat event, window(-5 5) estore(cs)
. estat event, window(-5 5) estore(cs)
ATT by Periods Before and After treatment
Event Study:Dynamic effects
```

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
Pre_avg	-.0252816	.0196714	-1.29	0.199	-.0638368	.0132736
Post_avg	6.725588	.1212707	55.46	0.000	6.487902	6.963274
Tm5	-.1866539	.0943045	-1.98	0.048	-.3714873	-.0018205
Tm4	.122315	.0850012	1.44	0.150	-.0442844	.2889143
Tm3	-.0085218	.0873563	-0.10	0.922	-.1797369	.1626933
Tm2	-.0030868	.0904466	-0.03	0.973	-.1803589	.1741854
Tm1	-.0504606	.0969123	-0.52	0.603	-.2404052	.139484
Tp0	.1196316	.0938451	1.27	0.202	-.0643014	.3035647
Tp1	3.096465	.1169635	26.47	0.000	2.86722	3.325709
Tp2	5.019964	.1279007	39.25	0.000	4.769283	5.270645
Tp3	7.092762	.174461	40.66	0.000	6.750825	7.4347
Tp4	10.122	.2580579	39.22	0.000	9.616218	10.62779
Tp5	14.9027	.270492	55.09	0.000	14.37255	15.43286

```
event_plot cs, default_look ///
    stub_lag(Tp#) stub_lead(Tm#) plottype(scatter) ciplottype(rcap) ///
    together ///
    graph_opt(xtitle("Períodos desde o evento") ytitle("Efeito médio de
tratamento")) ///
    title("Callaway-Sant'Anna (2020)") xlabel(-5(1)5))
```

Figura 12. Resultado csdid



As conclusões desta estimação são semelhantes à do método anterior.

#### 2.2.10.5 eventstudyinteract

O próximo estimador é SA, começa-se por gerar manualmente as variáveis binárias referentes aos efeitos desfasados e antecipados do tratamento:

```
sum first_treat
gen lastcohort = first_treat==r(max) // dummy for the latest- or never-
treated cohort
forvalues l = 0/5 {
    gen L`l'event = rel_time==`l'
}
forvalues l = 0/5 {
    gen F`l'event = rel_time==-`l'
}
```

Para estimar os efeitos, considerando como grupo de tratamento a última coorte:

```
eventstudyinteract Y L*event F*event, vce(cluster id) absorb(id t) cohort(first_treat)
control_cohort(lastcohort)
```

IW estimates for dynamic effects  
Absorbing 2 HDE groups

Number of obs	=	6,000
F( 51, 399)	=	295.52
Prob > F	=	0.0000
R-squared	=	0.9999
Adj R-squared	=	0.9999
Root MSE	=	1.0170


(Std. Err. adjusted for 400 clusters in id)

Y	Coef.	Robust Std. Err.	t	P> t	[95% Conf. Interval]	
L0event	.0807002	.0843261	0.96	0.339	-.0850788	.2464791
L1event	3.063256	.11426	26.81	0.000	2.838629	3.287883
L2event	4.969102	.1199616	41.42	0.000	4.733266	5.204937
L3event	7.029918	.1722699	40.81	0.000	6.691248	7.368588
L4event	10.10832	.2486325	40.66	0.000	9.619529	10.59712
L5event	15.135	.1919235	78.86	0.000	14.75769	15.5123
F0event	0	(omitted)				
F1event	-.0396455	.085648	-0.46	0.644	-.2080232	.1287323
F2event	.0255819	.0803747	0.32	0.750	-.132429	.1835927
F3event	.026312	.0795591	0.33	0.741	-.1300955	.1827194
F4event	.022361	.0760195	0.29	0.769	-.1270879	.1718099
F5event	-.0812348	.0679207	-1.20	0.232	-.214762	.0522924

```
event_plot e(b_iw)#e(V_iw), default_look plottype(scatter) ciplottype(rcap) ///
    stub_lag(L#event) stub_lead(F#event) together ///
    graph_opt(xtitle("Períodos desde o evento") ytitle("Efeito médio de
tratamento") xlabel(-5(1)5) ///
    title("Sun-Abraham (2020)") ///
    lag_opt(msymbol(Sh) color(dkorange)) lag_ci_opt(color(dkorange))

matrix sa_b = e(b_iw) // guardar estimativas
matrix sa_v = e(V_iw)
```

Figura 13. Resultado eventstudyinteract



#### 2.2.10.6 did\_imputation

Por fim, para aplicar o comando `did_imputation`, recorre-se ao seguinte comando, onde se verifica que os resultados são semelhantes aos dos estimadores apresentados anteriormente:

```
did_imputation Y i t first_treat, horizons(0/5) pretrend(5)
```

. \*Estimation  
. did\_imputation Y id t first\_treat, horizons(0/5) pretrends(5)


Number of obs = 6,000

Y	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
tau0	.0967037	.0677519	1.43	0.153	-.0360877 .229495
tau1	3.063015	.0794558	38.55	0.000	2.907285 3.218746
tau2	4.955097	.0846535	58.53	0.000	4.789179 5.121015
tau3	7.013297	.1093621	64.13	0.000	6.798951 7.227643
tau4	10.08724	.137904	73.15	0.000	9.816955 10.35753
tau5	15.07664	.1834655	82.18	0.000	14.71705 15.43622
pre1	.0060502	.0986864	0.06	0.951	-.1873717 .199472
pre2	.0439222	.0888271	0.49	0.621	-.1301757 .21802
pre3	.037923	.0818881	0.46	0.643	-.1225747 .1984208
pre4	.0388178	.0729534	0.53	0.595	-.1041683 .1818039
pre5	-.0469103	.0625642	-0.75	0.453	-.1695339 .0757133

```
event_plot, default_look ///
plotttype(scatter) ciplotttype(rcap) ///
together ///
graph_opt(xtitle("Períodos desde o evento") ytitle("Efeito médio de
tratamento")) ///
title("Borusyak et al. (2021)") xlabel(-5(1)5)) ///
lag_opt(msymbol(0) color(cranberry)) lag_ci_opt(color(cranberry))

estimates store bjs
```

Figura 14. Resultado did\_imputation



## 3 Aquisição e preparação dos dados

### 3.1 Exemplo de Aplicação de Avaliação de Políticas Públicas

Nas secções que se seguem, procuramos exemplificar a aplicação dos modelos e das simulações apresentadas no guia anterior a situações concretas de avaliação de políticas públicas. Em particular, focamo-nos na avaliação de impacto de políticas públicas que visam conceder a isenção ou redução do pagamento da taxa social única (TSU) por parte das entidades empregadoras, tal como referido na Secção 2.1. Exemplos de questões empíricas que se enquadrariam num tal exercício de avaliação seriam: Qual o impacto nos salários e nas horas de trabalho dos trabalhadores abrangidos na redução da TSU? Qual será o impacto nos níveis de emprego das faixas etárias abrangidas? E qual será o impacto nos salários dos restantes trabalhadores? Qual o impacto nos custos e na produtividade das empresas?

A resposta às questões anteriores depende criticamente da disponibilidade de microdados administrativos que permita responder às questões formuladas anteriormente. É neste ponto que reside a maior dificuldade do presente exercício, pois a base de micro dados administrativos do Ministério do Trabalho e da Segurança Social (MTSS) que contém informação sobre horas de trabalho, remunerações, características das entidades empregadoras, etc., o “Relatório Único” (anteriormente designada “Quadros do Pessoal”, designação que utilizaremos ao longo do presente estudo por ser a designação pela qual esta base de dados se popularizou) não contém informação acerca do código de enquadramento no regime contributivo, o que dificulta a identificação precisa das situações de redução da TSU ao abrigo dos incentivos à contratação.

Para superar a dificuldade anterior, focamo-nos naquilo que é possível identificar através dos “Quadros do Pessoal”, em particular a isenção do pagamento de contribuições por parte de entidades empregadoras que celebrem contrato sem termo com trabalhadores já vinculados com contrato de trabalho a termo e com idade igual ou superior a 45 anos. Para este efeito, analisamos o impacto desta medida na remuneração total por hora de trabalho nos trabalhadores que têm entre 45 e 46 anos e que transitam para um contrato sem termo dentro da mesma entidade empregadora entre os anos 2014-2019. À priori, a teoria económica da incidência das contribuições para sistemas de segurança social prevê que, não existindo contratação adicional de trabalhadores, a remuneração total horária aumente como consequência da incidência partilhada da isenção do pagamento da TSU. Contudo, a evidência empírica nem sempre corrobora esta hipótese.

À luz do guia de implementação dos modelos anteriores, a avaliação do impacto nas remunerações pode ser feita recorrendo aos modelos DiD com efeitos heterogéneos, dado que os indivíduos transitam para um contrato sem termo em diferentes momentos ao longo do

período 2014-2016, podendo as unidades ainda não tratadas servir de grupo de controlo às unidades já tratadas.

### 3.2 Aquisição de Dados

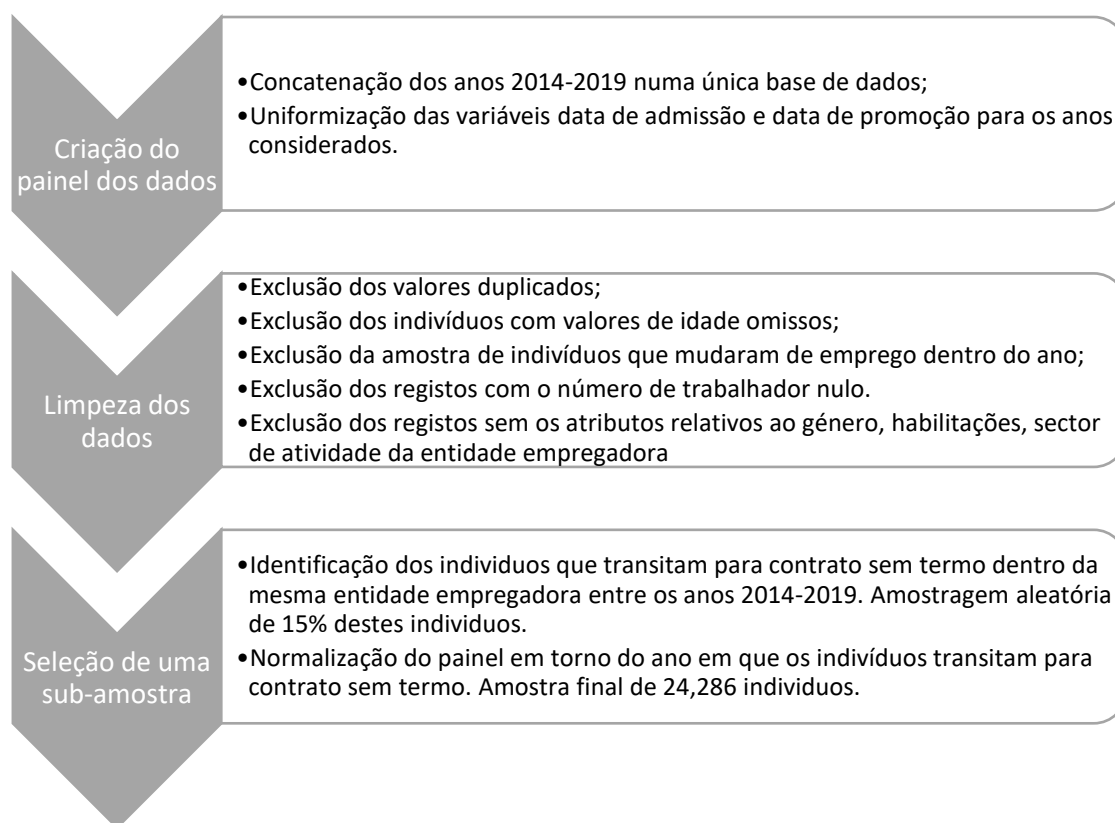
Conforme referido anteriormente, os exercícios de avaliação de políticas públicas são tão mais completos quanto maior for o acesso à informação administrativa. No contexto deste estudo, recorreu-se à base de dados do “Relatório Único” (ou “Quadros do Pessoal”) de 2011-2020. Para o efeito. Para o efeito de acesso aos dados, realizou-se um pedido de acreditação junto do Instituto Nacional de Estatística para o acesso aos dados administrativos dos “Quadros do Pessoal” (Processo 1026 – Protocolo INE/FCT/DGEEC).

### 3.3 Preparação de Dados. Construção da Amostra

No que respeita ao tratamento dos dados, os dados estavam agrupados em ficheiros por ano, pelo que se juntou os anos em questão numa só base de dados com o objetivo de construir um painel de 2014 a 2019. Excluíram-se os anos de 2011-2013, para evitar contaminação dos resultados com a fase do ciclo económico (redução das contratações e redução de salários), bem como o ano de 2020 dado que se tratou de um ano extraordinário devido às circunstâncias da pandemia. Posteriormente, construiu-se uma subamostra com os indivíduos que em qualquer um dos anos de 2014 a 2019 transitaram de um contrato a termo para um contrato sem termo e com idades compreendidas entre os 45 e os 46 anos (cerca de 25,000 indivíduos por ano). Identificada esta subamostra, construiu-se uma segunda subamostra de 15% da amostra original (cerca de 4,000 indivíduos por ano) de indivíduos que em algum dos anos entre 2014 e 2019 transitaram para um contrato sem termo, o que resultou num painel com cerca de 25,000 indivíduos que transitam para um contrato sem termo, normalizada em torno do ano em que ocorre a transição.

Efetuaram-se ainda tratamentos adicionais, como a remoção de duplicados ao nível do identificador único do trabalhador (NTRAB) e de valores em falta (*missings*) nas remunerações ou noutras variáveis cruciais para a estimação dos modelos e análise de heterogeneidade. A Figura 15 sumariza o processo de construção da amostra a partir dos Quadros do Pessoal.

*Figura 15. Construção da Amostra*



### 3.4 Estatísticas Descritivas

A amostra final é constituída por 24,286 indivíduos, que se repartem em cada ano conforme se encontra na Figura 15. A Tabela 3 apresenta estatísticas descritivas da amostra final usada na estimação dos modelos, podendo-se igualmente observar que a média de idades varia entre 43 e 47 anos (pois a maior parte das observações concentra-se nas transições que ocorrem entre 2016-2018), é composta por indivíduos do sexo masculino (54%-53%), o que constitui o reflexo das taxas de participação feminina no mercado de trabalho.

Relativamente às habilitações, cerca de 2/3 dos indivíduos possui apenas a escolaridade básica, cerca de 1/5 concluiu o ensino secundário e apenas 11% possuem formação superior. A remuneração horária varia entre os 4.90 euros (2014) e os 5.82 euros (2019), refletindo o aumento das remunerações no período de 2014-2019. A remuneração horária média corresponde ao rácio entre o total das remunerações (prestações regulares, como o salário base, e irregulares, tais como bónus ou prémios) e o número de horas trabalhadas por semana (o que corresponde ao período normal de trabalho acrescido das horas suplementares).

*Tabela 3. Estatísticas Descritivas*

	Ano 2014	Ano 2015	Ano 2016	Ano 2017	Ano 2018	Ano 2019
Idade	42.98	43.90	44.72	45.57	46.49	47.47
Sexo	0.54	0.53	0.53	0.53	0.53	0.53
Ensino Básico	0.66	0.65	0.63	0.63	0.62	0.61
Ensino Secundário	0.23	0.23	0.24	0.25	0.26	0.27
Ensino Superior	0.11	0.11	0.12	0.12	0.12	0.12
Remuneração Horária	4.90	4.97	5.06	5.28	5.54	5.82
Número de Observações	3,485	3,839	4,138	4,318	4,376	4,190

**Notas:** A Tabela 3 apresenta as estatísticas descritivas da amostra de trabalho que seleciona aleatoriamente 15% dos indivíduos que transitam para um contrato sem termo em pelo menos um dos anos de 2014-2019, conforme os critérios apresentados na Figura 15

## 4 Desenvolvimento e aplicação de modelos

Nesta secção procederemos à estimação dos efeitos na remuneração total horária pela passagem a contrato sem termo nos indivíduos com idade igual a 45 ou 46 no ano da alteração do contrato usando os modelos apresentados na Secção 2.2. Este exercício reveste-se de algumas limitações, conforme afluído na Secção 3. Em particular, o facto de não existir informação nos Quadros do Pessoal acerca do código do regime contributivo no qual o trabalhador se encontra enquadrado, não sendo, portanto, possível identificar univocamente se as entidades empregadoras dos indivíduos com idade igual ou superior a 45 anos que beneficiaram das isenções previstas da TSU. Para facilitar a exposição da aplicação dos modelos apresentados na Secção 2.2, nas secções que se seguem, vamos admitir que as entidades empregadoras dos indivíduos que constituem a nossa amostra beneficiaram destas isenções.

### 4.1 Estimação de Modelos

A Tabela 4 apresenta os resultados da estimação dos quatro modelos, usando a amostra anteriormente descrita, em particular na coluna (1) encontramos os resultados da estimação do modelo de Borusyak, Jaravel and Spiess (ver Secção 2.2.5), na coluna (2) encontramos os resultados da estimação do modelo de Chaisemartin and D'Haultfoeuille (ver Secção 2.2.2), na coluna (3) os resultados da estimação do modelo de Callaway and Sant'Anna (ver Secção 2.2.3) e, finalmente, na coluna (4) os resultados da estimação do modelo de Sun and Abraham (ver Secção 2.2.4). No conjunto dos quatro modelos, a estratégia subjacente à identificação dos efeitos de tratamento está no facto de os indivíduos transitarem para um contrato sem termo em diferentes momentos do tempo (*"staggered designs"*).



Tabela 4. Estimacões dos Modelos Differences-in-Differences com Efeitos Heterogéneos


Evento: Passagem a Contrato sem Termo	(1) Borusyak, Jaravel and Spiess (2021)	(2) Chaisemartin and D'Haultfoeuille (2020)	(3) Callaway and Sant'Anna (2020)	(4) Sun and Abraham (2021)
3 Anos <i>antes</i> evento	0.0178* (0.0123)	0.0044 (0.0090)	0.0163* (0.0123)	-0.0093*** (0.0003)
2 Anos <i>antes</i> evento	0.0482** (0.0215)	0.0047 (0.0058)	0.0094 (0.0082)	-0.0057*** (0.0003)
1 Anos <i>antes</i> evento	0.0728*** (0.0309)	-0.0046** (0.0025)	-0.0046 (0.0049)	– –
Ano do Evento	0.0048 (0.0042)	-0.0044 (0.0047)	-0.0044 (0.0036)	0.1322*** (0.0055)
1 Anos <i>após</i> evento	0.0036 (0.0066)	-0.0083 (0.0084)	-0.0046 (0.0063)	0.0747*** (0.0041)
2 Anos <i>após</i> evento	0.0024 (0.0092)	-0.0048 (0.0111)	0.0052 (0.0106)	-0.0156*** (0.0023)
3 Anos <i>após</i> evento	-0.0135 (0.0133)	-0.0311*** (0.0088)	0.0101 (0.0165)	-0.2903*** (0.0026)
Efeito Médio ( $\delta^{k \geq 1, avg}$ )	-0.0025 (0.0087)	–	0.0036 (0.0097)	–
Efeitos Fixos Indivíduos	Yes	Yes	Yes	Yes
Efeitos Fixos Tempo	Yes	Yes	Yes	Yes
Interacção				
Número de Observações	17,218	25,769	17,039	19,575

**Notas:** \*\*\*Valor- $p < 0.01$ , \*\*Valor- $p < 0.05$ , \*Valor- $p < 0.10$ . Resultados da estimacão dos modelos apresentados nas Secções 2.2.2, 2.2.3, 2.2.4 e 2.2.5. Tratando-se de modelos DiD com *staggered designs*, o grupo de controlo corresponde aos indivíduos ainda não tratados e o grupo de tratamento corresponde aos indivíduos que transitaram para um contrato sem termo. Os resultados sugerem que a passagem a contrato sem termo para os indivíduos entre os 45 e 46 anos (elegíveis para a isenção da TSU), não se traduz num aumento do salário horário.

Assim, o grupo de controlo corresponde aos indivíduos que ainda não foram tratados (“*not-yet-treated*”), ou seja, que ainda possuem um contrato a termo, enquanto o grupo de tratamento corresponde aos indivíduos que já transitaram para um contrato sem termo. Dada a natureza de painel dos dados, são também incluídos efeitos fixos nos indivíduos e no tempo, por forma a controlar para o efeito da heterogeneidade individual (e.g., indivíduos intrinsecamente mais produtivos, com mais habilidade, etc.) e/ou tendências no tempo de variação do salário horário. Por fim, a partir dos efeitos dinâmicos calculou-se, o efeito médio ou de longo prazo no salário horário pela passagem ao contrato sem termo.


A Figura 16, Figura 17 e a Figura 18 ilustram os efeitos dinâmicos dos modelos (1)-(3) e a Figura 19 compara os três modelos e põe em evidência as diferenças num mesmo gráfico.

Figura 16. Efeitos dinâmicos a partir do modelo de Chaisemartin & D'Haultfoeuille (2020)




**Notas:** Efeitos dinâmicos correspondentes à coluna (2) da Tabela 4 Intervalos de confiança a 5% de significância.

Figura 17. Efeitos dinâmicos a partir do modelo de Callaway & Sant'Anna (2020)



**Notas:** Efeitos dinâmicos correspondentes à coluna (3) da Tabela 4 Intervalos de confiança a 5% de significância.

Figura 18. Efeitos dinâmicos a partir do modelo de Borusyak, Jaravel & Spiess (2021)




**Notas:** Efeitos dinâmicos correspondentes à coluna (1) da Tabela 4 Intervalos de confiança a 5% de significância.

A análise dos resultados mostra que não existe evidência empírica de um aumento da remuneração horária pela passagem a um contrato sem termo nos indivíduos entre 25 e 46 anos, isto é, nos indivíduos cuja passagem a contrato sem termo é elegível a isenção da TSU das entidades empregadoras. Admitindo que não existe alteração no emprego ou noutro tipo de custos relevantes, isto implica que a incidência contributiva da TSU pode não recair inteiramente sobre as empresas, pois caso contrário a redução dos custos de trabalho pela isenção da TSU deveria acarretar um aumento da remuneração horária.

Relativamente à consistência entre modelos, note-se que os modelos de Chaisemartin and D'Haultfoeuille (2020) e Callaway and Sant'Anna (2020) apresentam consistência nos resultados. Por outro lado, o modelo de Borusyak, Jaravel and Spiess (2021), não divergindo nas conclusões principais, apresenta resultados ligeiramente diferentes, em particular no que respeita à existência de tendências não paralelas nos períodos que antecedem o evento. É importante notar que a observação empírica de que os Chaisemartin and D'Haultfoeuille (2020) e Callaway and Sant'Anna (2020) apresentam resultados consistentes entre si é esperada pois estes modelos assentam em hipóteses de identificação similares, sendo este resultado coerente com a literatura (Marcus & Sant'Anna, 2021), bem como o que se encontra explanado nas Secção 2.2.

Figura 19. Efeitos dinâmicos: Comparação dos Três Modelos



**Notas:** A Figura 19 apresenta uma comparação entre os efeitos dinâmicos de tratamento dos modelos estimados na Tabela 4. Conforme é possível observar, os modelos Chaisemartin and D'Haultfoeuille (2020) e Callaway and Sant'Anna (2020) apresentam resultados consistentes, enquanto o modelo de Borusyak, Jaravel and Spiess (2021) aponta para a existência de tendências preexistentes ao evento. Intervalos de confiança a 5% de significância.

Atendendo aos resultados apresentados, importa estudar quais os fatores que guiam o resultado central obtido nesta secção de que não existe alteração na remuneração horária média entre os indivíduos elegíveis para a redução da TSU. Para esse efeito, desenvolvemos uma análise de heterogeneidade por género e habilitações dos trabalhadores, bem como por sector de atividade e escalão de dimensão (emprego e volume de negócios) da entidade empregadora.

O modelo “baseline” adotado é o de Callaway and Sant’Anna (2020), por duas razões: (i) é baseado em hipóteses de tendências paralelas menos estritas relativamente ao modelo de Chaisemartin and D’Haultfoeuille (2020); (ii) é computacionalmente menos exigente do que o modelo de Chaisemartin and D’Haultfoeuille (2020). O modelo de Borusyak, Jaravel and Spiess (2021) não é considerado, pois, apesar de coincidir nas conclusões principais, os coeficientes dos efeitos dinâmicos “pré-evento” são estatisticamente significativos, o que representa uma aparente violação da hipótese de tendências paralelas e invalidaria a análise estatística. Por último, o modelo Callaway and Sant’Anna (2020) é o que se popularizou nas aplicações de modelos de Diferença-em-diferenças com efeitos heterogêneos no tempo e datas de tratamento não simultâneas (“*staggered designs*”).

## 5 Testes e avaliação de precisão. Análise de Heterogeneidade

Nesta Secção procuramos analisar a existência de heterogeneidade no resultado “baseline” com base nas características demográficas dos trabalhadores (Secção 5.1) e nas características das entidades empregadoras (Secção 5.2), estimando o modelo de Callaway and Sant’Anna (2020) separadamente para cada um dos atributos. É importante salientar que, tendo em conta a forma não-standard como são estimados os coeficientes dinâmicos no contexto do modelo de Callaway and Sant’Anna (2020), o estudo da heterogeneidade não pode ser feito através da simples inclusão de interações com as características, tal como se faz habitualmente nos modelos standard de regressão linear (Marcus & Sant’Anna, 2021).

### 5.1 Heterogeneidade por Características Demográficas

#### 5.1.1 Heterogeneidade por Género


A Tabela 5 apresenta os efeitos médios de tratamento por género (média dos efeitos dinâmicos), indicando que existe um efeito marginalmente positivo na remuneração horária dos homens, e marginalmente negativo na remuneração horária das mulheres, ainda que ambos os efeitos sejam estatisticamente não significativos. A Figura 20 e a Figura 21 apresentam os efeitos dinâmicos estimados por género.

Tabela 5. Efeito de Tratamento médio por género do trabalhador

Evento	Callaway and Sant'Anna (2020)
Passagem a Contrato sem Termo	(Average Effect $\delta$ )
Mulheres	-0.0056 (0.0089)
Homens	0.0039 (0.0110)
Unit FE	Yes
Time FE	Yes


**Notas:** \*\*\*Valor- $p < 0.01$ , \*\*Valor- $p < 0.05$ , \*Valor- $p < 0.10$ . A Tabela 5 apresenta dos efeitos de tratamento por género dos trabalhadores tratados, não revelando diferenças estatisticamente significativas por género.

Figura 20. Efeitos dinâmicos: Mulheres



**Notas:** Coeficientes dinâmicos do modelo estimado na subamostra das mulheres. Intervalos de confiança a 5% de significância.

Figura 21. Efeitos dinâmicos: Homens



**Notas:** Coeficientes dinâmicos do modelo estimado na subamostra dos homens. Intervalos de confiança a 5% de significância.

### 5.1.2 Heterogeneidade por Habilitações

Nesta secção procurou-se analisar efeitos diferenciados na remuneração horária pela passagem a contrato sem termo nos trabalhadores com diferentes níveis de habilitação literária, estimando-se o modelo “baseline” por três níveis de habilitação, incluindo efeitos fixos nos indivíduos e no tempo. Em particular, o ensino básico (que compreende os 1º, 2º e 3º ciclo do ensino básico), o ensino secundário (o ensino secundário e profissional) e o ensino superior (ensino pós-secundário, licenciaturas, mestrados e doutoramentos). Os resultados dos efeitos de tratamento médios encontram-se na Tabela 6 e na Figura 22.

Tabela 6. Efeito de Tratamento médio por escolaridade do trabalhador


Evento	Callaway and Sant'Anna (2020)
Passagem a Contrato sem Termo	(Average Effect $\delta$ )
Ensino Básico	-0.0069 (0.0084)
Ensino Secundário	0.0341** (0.0174)
Ensino Superior	-0.0243 (0.0215)
Unit FE	Yes
Time FE	Yes

**Notas:** \*\*\*Valor- $p < 0.01$ , \*\*Valor- $p < 0.05$ , \*Valor- $p < 0.10$ . A Tabela 6 apresenta os resultados da estimação do modelo *baseline* por níveis de escolaridade dos trabalhadores. Verifica-se um efeito positivo, ainda que apenas estatisticamente significativo ao nível de 5%, nos trabalhadores com habilitações ao nível do ensino secundário.

Os resultados evidenciam um efeito estatisticamente significativo nos indivíduos com um nível de habilitação igual ao ensino secundário. Em média a remuneração horária média aumenta cerca de 3.4 p.p. nos dois anos que se seguem à passagem a contrato sem termo, para os indivíduos com o ensino secundário e com uma idade entre os 45 e os 46 anos no ano da passagem a contrato sem termo.



Figura 22. Efeitos de tratamento médios por Nível de Habilitações




**Notas:** A Figura 22 apresenta os efeitos de tratamento médios por nível de escolaridade, ordenados por magnitude do efeito. Verifica-se um efeito positivo e estatisticamente significativo na remuneração horária pela passagem a contrato sem termo nos trabalhadores que possuem o ensino secundário, sendo não significativa nos restantes níveis de escolaridade. Intervalos de confiança a 5% de significância.

Este resultado merece um olhar mais atento, em particular a sua comparação com os efeitos dinâmicos. A Figura 23, Figura 24 e Figura 25, apresentam os efeitos dinâmicos para o modelo estimado nos indivíduos com o ensino básico, ensino secundário e ensino superior, respetivamente. Enquanto nos casos do ensino básico e superior, nenhum dos efeitos dinâmicos é estatisticamente significativo, no caso do ensino superior é visível que os coeficientes dos efeitos dinâmicos são positivos e apresentam tendência crescente após o evento, sendo o coeficiente associado ao segundo período ( $t=2$ ) estatisticamente significativo, mas os coeficientes no período 0 e do período 1, não são estatisticamente significativos.


Apesar de doze meses após a passagem a um contrato sem termo (período relativo 1), o coeficiente dinâmico ser positivo – o que pode indiciar uma incidência partilhada entre trabalhador e entidade empregadora da isenção da TSU – há que ter em linha de conta que outros fatores possam igualmente contribuir para o aumento da remuneração horária que não uma a redução dos custos de trabalho pela via da isenção da TSU (e.g. promoções, horas extra, elevada incidência da contratação coletiva entre os trabalhadores com estas habilitações, etc.).

Figura 23. Efeitos dinâmicos: Ensino Básico




**Notas:** Coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores com o ensino básico. Intervalos de confiança a 5% de significância.

Figura 24. Efeitos dinâmicos: Ensino Secundário



**Notas:** Coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores com o ensino secundário. Intervalos de confiança a 5% de significância.

Figura 25. Efeitos dinâmicos: Ensino Superior



**Notas:** Coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores com o ensino superior. Intervalos de confiança a 5% de significância.

## 5.2 Heterogeneidade por Características das Entidades Empregadoras

Nesta secção analisamos a heterogeneidade dos efeitos de tratamento da passagem a um contrato sem termo nos trabalhadores elegíveis para isenção da TSU, mas do ponto de vista das características das entidades empregadoras, em particular o escalão de dimensão da entidade empregadora – micro, pequena, média ou grande empresa -- (Secção 5.2.1 Heterogeneidade por Dimensão da Entidade Empregadora), bem como o sector de atividade da entidade empregadora (Secção 5.2.2).

### 5.2.1 Heterogeneidade por Dimensão da Entidade Empregadora

Atendendo às experiências de incentivo à contratação pela concessão de isenções ou reduções das contribuições para a segurança social por parte do empregador noutros contextos<sup>1</sup>, é expectável que o impacto de tais medidas possa variar de acordo com o número de trabalhadores ou o volume de negócios da entidade empregadora.

<sup>1</sup> Ver o caso as Hungria em “The Impact of Payroll Tax Subsidies: Theory and Evidence”, 2021, Bíró et al.

Tabela 7. Efeito de Tratamento médio por dimensão da entidade empregadora

Evento	Callaway and Sant'Anna (2020)
Passagem a Contrato sem Termo	(Average Effect $\delta$ )
Micro Empresa	0.0083 (0.0143)
Pequena Empresa	-0.0021 (0.0131)
Média Empresa	-0.0043 (0.0130)
Grande Empresa	0.0169 (0.0158)
Unit FE	Yes
Time FE	Yes


**Notas:** \*\*\*Valor- $p < 0.01$ , \*\*Valor- $p < 0.05$ , \*Valor- $p < 0.10$ . A Tabela 7 apresenta os efeitos médios de tratamento por escalão de dimensão da entidade empregadora.

Assim, nesta secção o modelo é estimado por escalão de dimensão da empresa, em particular conforme a entidade empregadora do trabalhador que transita para um contrato sem termo seja uma micro empresa (emprega menos de 10 pessoas e possui um volume de negócios anual inferior a 2 milhões de euros), pequena empresa (emprega menos de 50 pessoas e possui um volume de negócios inferior a 10 milhões de euros), média empresa (emprega menos de 250 pessoas e tem um volume de negócios inferior a 43 milhões de euros) e “grande empresa” (que embora não tenha uma classificação no sistema estatístico nacional, é como aqui optamos por designar as entidades empregadoras que não cabem nas categorias anteriores).

A Tabela 7 e a Figura 26 apresentam os efeitos de tratamento médios das estimações por escalão de dimensão da entidade empregadora. Ainda que nenhum dos efeitos de tratamento médios seja estatisticamente significativo, os coeficientes parecem sugerir que a passagem para um contrato sem termo entre os indivíduos elegíveis para a isenção da TSU só representa um aumento da remuneração horária nos casos dos indivíduos cujas entidades empregadoras são

grandes empresas, sendo que o efeito é nulo (ou marginalmente negativo) nos indivíduos cujas entidades empregadoras são pequenas ou médias empresas.

Figura 26. Efeitos de tratamento médios por Dimensão da Entidade Empregadora




**Notas:** A Figura 26 apresenta os efeitos de tratamento médios por escalão de dimensão da entidade empregadora, ordenados por magnitude do efeito. Intervalos de confiança a 5% de significância.

A comparação dos efeitos de tratamento médios com os efeitos dinâmicos completa este exercício. As Figura 27, Figura 28, Figura 29 e Figura 30 representam os efeitos de tratamento dinâmicos na remuneração horária pela passagem a contrato sem termo entre os indivíduos elegíveis para isenção da TSU (com 45 e 46 anos), cujas entidades empregadoras são micro empresas, pequenas empresas, médias empresas e grandes empresas, respetivamente.

Conforme pode ser observado, os coeficientes dinâmicos dos quatro modelos não são estatisticamente significativos para um nível de significância de 5%, contudo a análise do sinal dos coeficientes sugere uma interpretação diferenciada da interpretação do sinal dos coeficientes dos efeitos de tratamento médios. O coeficiente no ano do evento é próximo de zero no caso das grandes empresas (ano em que poderá decorrer a vigência da isenção da TSU), aumentando nos anos seguintes em que já são se aplicam tais incentivos, mas por outras razões tais como promoções ou aumentos salariais negociados no âmbito da contratação coletiva. No caso das pequenas, os coeficientes dinâmicos assumem uma trajetória distinta, verificando-se um coeficiente positivo ano da (potencial) isenção da TSU (e estatisticamente significativo a 10%) e uma tendência para o decréscimo nos anos posteriores, o que poderá indicar que a


incidência económica da isenção da TSU é repartida entre trabalhadores e empresas no caso das pequenas empresas.

Figura 27. Efeitos dinâmicos: Micro Empresa




**Notas:** A Figura 27 representa os coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores cuja entidade empregadora é uma micro empresa. Intervalos de confiança a 5% de significância.

*Figura 28. Efeitos dinâmicos: Pequena Empresa*




**Notas:** A Figura 28 representa os coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores cuja entidade empregadora é uma pequena empresa. Intervalos de confiança a 5% de significância.

*Figura 29. Efeitos dinâmicos no salário horário: Média Empresa*



**Notas:** A Figura 29 representa os coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores cuja entidade empregadora é uma média empresa. Intervalos de confiança a 5% de significância.

Figura 30. Efeitos dinâmicos: Grande Empresa




**Notas:** A Figura 30 representa os coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores cuja entidade empregadora é uma grande empresa. Intervalos de confiança a 5% de significância.

## 5.2.2 Heterogeneidade por Sector de Atividade da Entidade Empregadora

Nesta Secção, estimam-se os efeitos de tratamento por sector de atividade da entidade empregadora. Em particular, procura-se averiguar se existe uma repartição da incidência da TSU dos empregadores pela passagem dos trabalhadores elegíveis (idade igual ou superior a 45 anos) a um contrato sem termo. A Tabela 8 e Figura 31 apresentam os efeitos de tratamento médio na remuneração horária pela passagem de trabalhadores com idades compreendidas entre os 45 e 46 anos a um contrato sem termo, estimados a partir do modelo *baseline*, em cada um dos sectores de atividade (CAE ao nível da secção) das entidades empregadoras.



Figura 31. Efeitos de tratamento médios por Sector de Atividade da Entidade Empregadora



**Notas:** A Figura 31 apresenta os efeitos de tratamento médios por escalão de dimensão da entidade empregadora, ordenados por magnitude do efeito. Intervalos de confiança a 5% de significância.


Dois factos ressaltam da análise da Figura 31. Em primeiro lugar existe um efeito positivo e estatisticamente significativo no sector do comércio a retalho e um efeito nulo no sector da indústria transformadora (*Manufacturing*), os dois sectores, que pela composição do sector do emprego, empregam mais trabalhadores e, portanto, a partir dos quais se obtêm estimativas mais precisas. Em segundo lugar, analisando os coeficientes dinâmicos (Figura 32, Figura 33, Figura 34, Figura 35), observa-se que o efeito positivo no comércio a retalho é sobretudo devido à evolução nos períodos relativos 1 e 2, pelo que não é de excluir a influência de outros fatores que não a redução dos custos de trabalho via TSU na evolução da remuneração horária.

Tabela 8. Efeito de tratamento médio por sector de atividade da entidade empregadora

Evento	Callaway and Sant'Anna (2020)
Passagem a Contrato sem Termo	(Average Effect $\delta$ )
Agriculture (NACE-A)	0.0204 (0.0355)
Mining & Quarrying (NACE-B)	-0.0799 (0.1548)
Manufacturing (NACE-C)	0.0073 (0.0097)
Water Collection (NACE-E)	-0.0530 (0.0569)
Construction (NACE-F)	-0.0120 (0.0255)
Retail Trade (NACE-G)	0.0465** (0.0205)
Transportation & Storage (NACE-H)	0.0277 (0.0312)
Restaurants & Hotels (NACE-I)	-0.0305 (0.0286)
Consultancy (NACE-M)	-0.0244 (0.0326)
Administrative Activities (NACE-N)	-0.0218 (0.0353)
Education (NACE-P)	0.0705 (0.0595)
Human Health (NACE-Q)	-0.0119 (0.0159)
Unit FE	Yes
Time FE	Yes


**Notas:** \*\*\*Valor- $p < 0.01$ , \*\*Valor- $p < 0.05$ , \*Valor- $p < 0.10$ . A Tabela 8 apresenta os efeitos médios de tratamento por sector de atividade (divisão) da entidade empregador

*Figura 32. Efeitos dinâmicos: Indústria Transformadora*




**Notas:** A Figura 32 representa os coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores pertencentes à indústria transformadora (divisão C). Intervalos de confiança a 5% de significância.

*Figura 33. Efeitos dinâmicos: Alojamento e Restauração*




**Notas:** A Figura 33 representa os coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores pertencentes ao alojamento e restauração (divisão I). Intervalos de confiança a 5% de significância.

*Figura 34. Efeitos dinâmicos: Comércio por Grosso e a Retalho*



**Notas:** A Figura 34 representa os coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores pertencentes ao comércio por grosso e retalho (divisão G). Intervalos de confiança a 5% de significância.

*Figura 35. Efeitos dinâmicos: Transportes e Armazenamento*



**Notas:** A Figura 35 representa os coeficientes dinâmicos do modelo estimado na subamostra dos trabalhadores pertencentes aos transportes e armazenagem (divisão H). Intervalos de confiança a 5% de significância.

## 6 Disseminação

Com a conclusão do projeto, as metodologias e os resultados obtidos serão objeto de divulgação abrangente com base em três tipologias de ações.

Em primeiro lugar está prevista uma sessão de apresentação das metodologias e dos resultados durante o mês de Outubro de 2023 num seminário do Mestrado de *Data Science and Advanced Analytics*, o qual decorrerá em formato aberto aos restantes programas de mestrado, pós-graduações e doutoramento.

A segunda linha de ação será a promoção das metodologias e das questões de investigações trabalhadas neste relatório na bolsa de temas dos estudantes de mestrado, encontrando-se neste momento duas teses de mestrado a concluir no ano letivo de 2022/2023, que têm como objeto a aplicação das metodologias de DiD com “*staggered designs*” no contexto da avaliação de políticas públicas em Portugal. Estas teses originarão igualmente comunicações em conferências científicas.

Por último, prevê-se a publicação de pelo menos um “*policy paper*” que reúna as principais conclusões do exemplo empírico apresentado e que sirva de divulgação junto de públicos menos familiarizados com os conceitos estatísticos que são objeto do projeto. Por outro lado, prevê-se igualmente que o projeto dê origem a pelo menos uma publicação num periódico científico ou conferência internacional.

## 7 Conclusão

Este projeto teve como objetivo central a construção de um guia metodológico usando técnicas estatísticas que estão na fronteira do conhecimento de avaliação de políticas públicas, em particular os desenvolvimentos do método da diferença-em-diferenças (DiD) em contextos que se desviem dos pressupostos do método DiD clássico, isto é, em contextos em que a aplicação dos programas não é simultânea, a zona de abrangência corresponde à integralidade do território nacional, ou que existem efeitos de tratamento heterogéneos associados às políticas públicas (DiD em “*staggered designs*”). A construção deste guia metodológico procurou incluir a literatura fundadora destas metodologias, as suas bases teóricas e pressupostos, mas também as rotinas computacionais que permitem a sua implementação por parte do leitor, seja qual for o exercício de avaliação de políticas públicas em causa. Ainda no âmbito do guia metodológico, desenvolvemos um conjunto de estudos de simulação com vista a melhor ilustrar as consequências da verificação dos pressupostos de cada modelo.

A segunda parte do projeto teve como objetivo desenvolver um exercício de avaliação de políticas públicas, utilizando bases de dados administrativos, e que procurasse exemplificar as

metodologias desenvolvidas na primeira parte do projeto. A ideia central foi escolher um caso de avaliação de políticas públicas que fosse suficientemente geral para servir de exemplo a outros programas cofinanciados por fundos europeus, e que simultaneamente não pudesse ser objeto de avaliação utilizando as técnicas disponíveis antes do advento dos métodos DiD com *“staggered designs”*. A escolha recaiu sobre as políticas que visam a redução da taxa social única (TSU) das entidades empregadoras, em particular as isenções da TSU relacionadas com a passagem a contrato sem termo de trabalhadores da mesma entidade com idade igual ou superior a 45 anos. Para tal foram usados os dados do Relatório Único (Quadros do Pessoal), compilados pelo Ministério do Trabalho e da Segurança Social, e que permitem observar as remunerações, bem como as características dos trabalhadores e entidades patronais. A limitação deste exercício residiu no facto de não se poder observar o código do regime contributivo dos trabalhadores, pelo que não se pode determinar se as entidades empregadoras dos trabalhadores que transitam para contratos a termo reclamam o direito ao benefício da isenção da TSU. Tendo em conta a natureza exemplificativa, e sem prejuízo de ser essa a situação que é provavelmente dominante, optou-se por considerar que era esse o caso, no entanto a interpretação dos resultados é condicional à limitação referida.

Os resultados colocam em causa alguns dos mecanismos teóricos acerca da incidência da TSU, uma vez que o resultado central parece sugerir que a redução do custo de trabalho não se parece traduzir num aumento da remuneração horária no ano em que essa redução ocorre, e marginalmente, no ano posterior. Esta conclusão é robusta a uma extensa análise de heterogeneidade por características de indivíduos (género e habilitações literárias) e por características das entidades empregadoras (sector de atividade, escalão de dimensão da entidade empregadora).

O plano de disseminação deste trabalho prevê a apresentação das conclusões principais num conjunto de ações, desde seminários e workshops, à divulgação em conferências e à sua publicação sob a forma de artigo científico. Prevê-se que a concretização do plano de divulgação seja particularmente importante para recolher contributos que possam ser incorporados nas publicações que fazem parte do plano de disseminação.

## 8 Referências

- Athey, S., & Imbens, G. W. (2021). Design-based analysis in difference-in-differences settings with staggered adoption. *Journal of Econometrics*. Retrieved from <https://www.sciencedirect.com/science/article/abs/pii/S0304407621000488>
- Bertrand, M., Duflo, E., & Mullainathan, S. (2004). How much should we trust differences-in-differences estimates? *The Quarterly Journal of Economics*, 119(1), 249–275.
- Borusyak, K., Jaravel, X., & Spiess, J. (2021). Revisiting event study designs: Robust and efficient estimation. Retrieved from <https://arxiv.org/abs/2108.12419>
- Callaway, B., & Sant’Anna, P. H. C. (2020). Difference-in-differences with multiple time periods. *Journal of Econometrics*. Retrieved from <https://www.sciencedirect.com/science/article/abs/pii/S0304407620303948>
- Card, D., & Krueger, A. B. (2000). Minimum wages and employment: a case study of the fast-food industry in New Jersey and Pennsylvania: reply. *American Economic Review*, 90(5), 1397–1420.
- De Chaisemartin, C., & D’Haultfoeuille, X. (2020a). Two-way fixed effects estimators with heterogeneous treatment effects. *American Economic Review*, 110(9), 2964– 2996. Retrieved from <https://www.aeaweb.org/articles?id=10.1257/aer.20181169>
- De Chaisemartin, C., & D’Haultfoeuille, X. (2020b). Two-way Fixed Effects Regressions with Several Treatments. *arXiv*. Retrieved from <https://arxiv.org/abs/2012.10077>
- Duflo, E., Glennerster, R., & Kremer, M. (2007). Chapter 61 Using Randomization in Development Economics Research: A Toolkit. In T. P. Schultz & J. A. Strauss (Eds.) (Vol. 4, pp. 3895–3962). Elsevier. [https://doi.org/https://doi.org/10.1016/S1573-4471\(07\)04061-2](https://doi.org/https://doi.org/10.1016/S1573-4471(07)04061-2)
- Freyaldenhoven, S., Hansen, C., Pérez, J. P., & Shapiro, J. M. (2021). Visualization, Identification, and Estimation in the Linear Panel Event-Study Design. Retrieved from <https://www.nber.org/papers/w29170>
- Goodman-Bacon, A. (2021). Difference-in-differences with variation in treatment timing. *Journal of Econometrics*. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0304407621001445>
- Kleven, H. J. (2018). Language trends in public economics. Slides Accessed At< [https://www.henrikkleven.com/uploads/3/7/3/1/37310663/Languagetrends Slides Kleven. Pdf](https://www.henrikkleven.com/uploads/3/7/3/1/37310663/Languagetrends%20Slides%20Kleven.pdf)> on December, 7, 2019.
- Naqvi, A (2020). Difference-in-Differences (DiD), <https://asjadnaqvi.github.io/DiD/>. Acedido a Junho de 2022
- Sun, L., & Abraham, S. (2020). Estimating dynamic treatment effects in event studies with heterogeneous treatment effects. *Journal of Econometrics*. Retrieved from <https://www.sciencedirect.com/science/article/abs/pii/S030440762030378X>