

Méthode des Doubles Différences (DiD)

Pratiques de la Recherche en Économie

Florentine Oliveira-Roux

2026-03-17

Les méthodes abordées précédemment (régression OLS simple, variable instrumentale) concernaient des données en **coupe instantanée** (*cross-section*) ou des échantillons répétés dans le temps (*repeated cross-section*) sans suivi individuel

Cette séance: données de panel

- Effets fixes individus (très rapidement)
- Méthode des doubles différences

Données de Pannel et Effet Fixe Individu

Dans un jeu de données de panel, on observe:

- de multiples observations t (année, trimestre, etc)
- pour de multiples individus i

Le modèle de régression devient alors, pour tout individu i et période t :

$$y_{it} = \alpha + \beta D_{it} + \varepsilon_{it}$$

où:

- y_{it} est l'outcome d'intérêt
- D_{it} le traitement qui vaut 1 si l'individu i est traité, 0 sinon
- ε_{it} le terme d'erreur

Effet fixe

En incluant un **effet fixe individu** dans notre modèle de régression, on contrôle par tous les facteurs individuels **constants au cours du temps**, à la fois observables et **non-observables**

⇒ on utilise la variation intra-individuelle (variation pour un même individu dans le temps, *within*).

Le modèle s'écrit:

$$y_{it} = \alpha + \beta D_{it} + \alpha_i + \varepsilon_{it}$$

Exemple: effet de la taille de la ville sur le salaire

Quel est l'effet de la taille de la ville sur le salaire (*urban wage premium*) ?

Pourquoi ne peut-on pas déduire l'effet de la taille de la ville en comparant le salaire des individus qui vivent en ville au salaire des individus qui vivent dans des zones peu densément peuplées?

Exemple: effet de la taille de la ville sur le salaire

Quel est l'effet de la taille de la ville sur le salaire (*urban wage premium*) ?

Pourquoi ne peut-on pas déduire l'effet de la taille de la ville en comparant le salaire des individus qui vivent en ville au salaire des individus qui vivent dans des zones peu densément peuplées?

Endogeneous sorting: le lieu d'habitation n'est pas aléatoire (eg: les individus les plus diplômés choisissent souvent de vivre dans de grandes villes!)

Solution: Effet fixe individu! Cela veut dire que l'on exploite pour l'identification la variation de lieu de résidence individuelle, autrement dit uniquement sur les individus qui sont amenés à déménager (*movers*).

Problème: les effets fixes individu ne nous permettent pas de contrôler pour les caractéristiques des individus qui varient dans le temps...

Méthode des Doubles Différences

Méthode des doubles-différences s'appuie sur des **expériences naturelles**, i.e. une politique ou un changement institutionnel qui induit un traitement pour un groupe donné à un moment précis

Contrairement aux "vraies expériences" où les groupes de contrôle et de traitement sont constitués par assignation aléatoire, les groupes sont déterminées par le changement de politique particulier.

Les données de panel et la méthode des DiD permettent de tenir compte de cette sélection sur des caractéristiques non-observables, à condition que ces **caractéristiques soient constantes dans le temps**

Intuition

Si, avant la mise en place du traitement, le groupe d'individus traités et contrôles diffèrent, cela est probablement en partie dû à des éléments non observés (biais de sélection)

⇒ on utilise cette différence pré-traitement comme référence pour "corriger" le biais initial

On compare donc la différence entre les deux groupes (première différence), avant et après traitement (deuxième différence).

- en soustrayant la différence initiale, on obtient l'effet 'net' du traitement

Cela suppose que l'**hypothèse de tendance parallèle** est valable: en l'absence de politique (traitement), l'écart entre les deux groupes serait resté constant dans le temps.

Estimation

Supposons qu'il y a:

- t périodes $\in \{1, T\}$
- un groupe d'individus $i \in \llbracket 1; n \rrbracket$ traités $D_i = 1$, et non traités $D_i = 0$
- les individus sont traités en g_i

Si $T = n = 2$, le modèle s'écrit:

$$Y_{it} = \alpha + \beta_{DiD}(D_i \times Post_t) + \delta D_i + \eta Post_t + \varepsilon_{it}$$

Généralisation d'un modèle à plusieurs périodes:

$$Y_{it} = \beta^{TWFE} D_{it} + \delta_i + \gamma_t + \varepsilon_{it}$$

avec $D_{it} = 1\{t \geq g_i\}$

Hypothèses d'identification

Parallel trends

- En l'absence de traitement, l'outcome moyen des individus traités aurait évolué de la même manière que celui des individus non traités

- Formellement,
$$\underbrace{\mathbb{E}[Y_{i2}(0) - Y_{i1}(0) | D_i = 1]}_{\text{Changement de } Y(0) \text{ pour les traités}} = \underbrace{\mathbb{E}[Y_{i2}(0) - Y_{i1}(0) | D_i = 0]}_{\text{Changement de } Y(0) \text{ pour les contrôles}}$$

- Ou encore,
$$\underbrace{\mathbb{E}[Y_{i2}(0) | D_i = 1] - \mathbb{E}[Y_{i2}(0) | D_i = 0]}_{\text{Biais de sélection en période 2}} = \underbrace{\mathbb{E}[Y_{i1}(0) | D_i = 1] - \mathbb{E}[Y_{i1}(0) | D_i = 0]}_{\text{Biais de sélection en période 1}}$$

Absence d'anticipation

- Le traitement n'a pas d'effet causal avant qu'il ne soit implanté
- Formellement, $Y_{i1}(1) = Y_{i1}(0)$

Event Study

On peut aussi estimer un effet dynamique, par période relative à l'adoption du traitement:

$$Y_{it} = \sum_{k \neq -1} \beta_k 1\{k = t - g_i\} + \delta_i + \gamma_t + \varepsilon_{it}$$

où $k = t - g_i$ est le **temps relatif à l'adoption** (*time to treatment*)

Pour **tester les tendances parallèles**, on vérifie que pour $k < -1$, le traitement n'est pas encore actif $\hat{\beta}_k \approx 0$

Les coefficients $\hat{\beta}_k$ permettent d'**estimer la dynamique de l'effet**: pour $k \geq 0$, $\hat{\beta}_k$ capture l'effet du traitement k périodes après l'adoption

NB: La période $k = -1$ est normalisée à zéro par construction (catégorie de référence)


Implémentation sur R : `feols(y ~ i(time_to_treat, ref = -1) | id + year, data = data)`

Traitement à adoption différé et effets hétérogènes


La littérature sur les DiD est très active ces dernières années et a notamment permis de montrer

- La **décomposition de l'estimateur TWFE** en une moyenne pondérée des effets de traitement deux à deux (Goodman-Bacon, 2021)
- Les problèmes liés à l'utilisation de l'estimateur TWFE lorsque l'adoption du traitement est différée et que les effets sont hétérogènes, et les **estimateurs permettant de corriger ces biais**
 - de Chaisemartin and d'Hautefeuille (2020), package R `DIDmulti` et `legitDYN`
 - Callaway and Sant'Anna (2021), package R `did`
 - Sun and Abraham (2020), `sunab()` argument in `fixest`
 - Borusyak, Jaravel and Spiess (2024), package R `didimputation`
- Les méthodes permettant de gérer des traitements dits *non-absorbing*


Exemple: les collèges sans note



Exemple: les collèges sans note



Exemple: les collèges sans note



Application 1: Card and Krueger (1994)

Question de Recherche: quel est l'effet causal d'une augmentation du salaire minimum sur le taux d'emploi?

Question: pourquoi ne peut-on pas simplement comparer le taux de chômage de deux états ayant des niveaux de salaire minimum différents?

Biais de sélection/OVB:

Angrist et Krueger (1994)

- expérience naturelle: augmentation du salaire minimum dans le New Jersey au 1er Avril 1992 de \ \$4,25 à \ \$5,05 par heure
- focus sur l'industrie des fast-foods
- comparaison avec l'état de Pennsylvanie

Application 1: Card and Krueger (1994)

1) Importez les données sur `R` et stockez dans `df`. Créer les variables:

- `fte_before` (équivalent temps-plein) = `empft + nmgrs + (0.5*emppt)`
- `fte_after` = `empft2 + nmgrs2 + (0.5*emppt2)`
- Ré-encoder `state` de pour que ce soit égal à Pennsylvanie si `state` = 0 et New Jersey si `state` = 1

2) Pourquoi s'intéresser à l'industrie des fast-food, et à quel effet s'attend-t-on?

3) Calculer le nombre moyen d'employés en équivalent temps-plein par store dans chaque état, avant et après la réforme, et l'évolution de cette moyenne. Interpréter.

4) Calculer la différence de changement d'heures entre New Jersey et Pennsylvanie. Interprétez.

5) Proposez un modèle économétrique qui estime l'effet du traitement.

Application 2: Medicaid Expansion

Exemple tiré du site interactif de reproduction des résultats de Difference-in-Differences Designs: A Practitioner's Guide, Baker, Callaway, Cunningham and Goodman-Bacon (JEL) [https://psantanna.com/JEL-DiD/markdown/R_Stata/Code_Appendix.html#introduction]

Contexte : l'Affordable Care Act (ACA) a permis aux états américains d'étendre leur programme Medicaid

- L'adoption est **échelonnée** (*staggered*) : certains états adoptent en 2014, d'autres en 2015, 2016, etc
- Les états non-adoptants servent de groupe contrôle

Outcome : taux de mortalité brut pour les 20-64 ans (`crude_rate_20_64`)

Question de recherche : l'expansion Medicaid a-t-elle réduit la mortalité ?

Application 2: Medicaid Expansion

Partie 1 — Préparation des données

1) Importez les données (`county_mortality_data_cleaned.rds`) et stockez dans `data`. Créez les variables suivantes :

- `treat` : vaut 1 si l'état a adopté Medicaid avant 2019 ou en 2019, 0 sinon
- `treat_year` : année d'adoption de l'état, égal à 0 si jamais adoptant ou adoptant après 2019
- `time_to_treat` : nombre d'années par rapport à l'adoption ($= t - g$), égal à $-\infty$ pour les non-adoptants
- `post` : vaut 1 si l'année de traitement est supérieure ou égale à 2014, 0 sinon

2) Tracez l'évolution du taux de mortalité moyen au cours du temps selon le groupe de traitement. Que remarquez-vous ?

- *Hints: utiliser la variable `crude_rate_20_64` et les poids `set_wt`*

Application 2: Medicaid Expansion

Partie 2 — DiD 2×2 de référence

- 3) Restreignez l'échantillon aux comtés des états adoptant en **2014** et des états **jamais adoptants**. Appelez ce sous-échantillon `data_2x2`.
- 4) Sur `data_2x2`, calculez le taux de mortalité moyen par groupe (adoptants 2014 / non-adoptants) et par période (avant 2014 / après 2014). Calculez l'estimateur DiD 2×2 à la main puis par régression OLS avec `feols()`. Interprétez.

Partie 3 — Estimation TWFE sur toutes les cohortes

- 5) Sur l'ensemble des données `data`, estimez le TWFE suivant avec `feols()`. Interprétez.
- 6) Réalisez une **event-study** en estimant : `crude_rate_20_64 ~ i(time_to_treat, ref = -1) | county_code + year`
Représentez graphiquement les coefficients $\hat{\beta}_k$ avec leurs intervalles de confiance à 95%.
Que nous apprend ce graphique sur l'hypothèse de tendances parallèles ? Sur l'effet du traitement?

Solution: Medicaid Expansion

1) Importez les données (`county_mortality_data_cleaned.rds`) et stockez dans `data` . Créez les variables suivantes :

- `treat` : vaut 1 si l'état a adopté Medicaid avant 2019 ou en 2019, 0 sinon
- `treat_year` : année d'adoption de l'état, égal à 0 si jamais adoptant ou adoptant après 2019
- `time_to_treat` : nombre d'années par rapport à l'adoption ($= t - g$), égal à $-\infty$ pour les non-adoptants
- `post` : vaut 1 si l'année de traitement est supérieure ou égale à 2014, 0 sinon

```
data = readRDS("data/county_mortality_data_cleaned.rds") %>%
  mutate(treat = ifelse(!is.na(yaca) & yaca ≤ 2019, 1, 0),
         treat_year = ifelse(!is.na(yaca) & yaca ≤ 2019, yaca, 0),
         time_to_treat = ifelse(treat = 1, year - treat_year, -Inf),
         post = ifelse(year ≥ 2014, 1, 0))
```

Solution: Medicaid Expansion

1) Importez les données (`county_mortality_data_cleaned.rds`) et stockez dans `data`. Créez les variables suivantes :

- **treat** : vaut 1 si l'état a adopté Medicaid avant 2019 ou en 2019, 0 sinon
- `treat_year` : année d'adoption de l'état, égal à 0 si jamais adoptant ou adoptant après 2019
- `time_to_treat` : nombre d'années par rapport à l'adoption ($= t - g$), égal à $-\infty$ pour les non-adoptants
- `post` : vaut 1 si l'année de traitement est supérieure ou égale à 2014, 0 sinon

```
data = readRDS("data/county_mortality_data_cleaned.rds") %>%  
  mutate(treat = ifelse(!is.na(yaca) & yaca ≤ 2019, 1, 0),  
         treat_year = ifelse(!is.na(yaca) & yaca ≤ 2019, yaca, 0),  
         time_to_treat = ifelse(treat = 1, year - treat_year, -Inf),  
         post = ifelse(year ≥ 2014, 1, 0))
```

Solution: Medicaid Expansion

1) Importez les données (`county_mortality_data_cleaned.rds`) et stockez dans `data` . Créez les variables suivantes :

- `treat` : vaut 1 si l'état a adopté Medicaid avant 2019 ou en 2019, 0 sinon
- **`treat_year` : année d'adoption de l'état, égal à 0 si jamais adoptant ou adoptant après 2019**
- `time_to_treat` : nombre d'années par rapport à l'adoption ($= t - g$), égal à $-\infty$ pour les non-adoptants
- `post` : vaut 1 si l'année de traitement est supérieure ou égale à 2014, 0 sinon

```
data = readRDS("data/county_mortality_data_cleaned.rds") %>%  
  mutate(treat = ifelse(!is.na(yaca) & yaca ≤ 2019, 1, 0),  
         treat_year = ifelse(!is.na(yaca) & yaca ≤ 2019, yaca, 0),  
         time_to_treat = ifelse(treat = 1, year - treat_year, -Inf),  
         post = ifelse(year ≥ 2014, 1, 0))
```

Solution: Medicaid Expansion

1) Importez les données (`county_mortality_data_cleaned.rds`) et stockez dans `data` . Créez les variables suivantes :

- `treat` : vaut 1 si l'état a adopté Medicaid avant 2019 ou en 2019, 0 sinon
- `treat_year` : année d'adoption de l'état, égal à 0 si jamais adoptant ou adoptant après 2019
- **`time_to_treat` : nombre d'années par rapport à l'adoption ($= t - g$), égal à $-\infty$ pour les non-adoptants**
- `post` : vaut 1 si l'année de traitement est supérieure ou égale à 2014, 0 sinon

```
data = readRDS("data/county_mortality_data_cleaned.rds") %>%  
  mutate(treat = ifelse(!is.na(yaca) & yaca ≤ 2019, 1, 0),  
         treat_year = ifelse(!is.na(yaca) & yaca ≤ 2019, yaca, 0),  
         time_to_treat = ifelse(treat = 1, year - treat_year, -Inf),  
         post = ifelse(year ≥ 2014, 1, 0))
```

Solution: Medicaid Expansion

1) Importez les données (`county_mortality_data_cleaned.rds`) et stockez dans `data` . Créez les variables suivantes :

- `treat` : vaut 1 si l'état a adopté Medicaid avant 2019 ou en 2019, 0 sinon
- `treat_year` : année d'adoption de l'état, égal à 0 si jamais adoptant ou adoptant après 2019
- `time_to_treat` : nombre d'années par rapport à l'adoption ($= t - g$), égal à $-\infty$ pour les non-adoptants
- **`post` : vaut 1 si l'année de traitement est supérieure ou égale à 2014, 0 sinon**

```
data = readRDS("data/county_mortality_data_cleaned.rds") %>%  
  mutate(treat = ifelse(!is.na(yaca) & yaca ≤ 2019, 1, 0),  
         treat_year = ifelse(!is.na(yaca) & yaca ≤ 2019, yaca, 0),  
         time_to_treat = ifelse(treat = 1, year - treat_year, -Inf),  
         post = ifelse(year ≥ 2014, 1, 0))
```

Solution: Medicaid Expansion

2) Tracez l'évolution du taux de mortalité moyen au cours du temps selon le groupe de traitement. Que remarquez-vous ?


- *Hints: utiliser la variable `crude_rate_20_64` et les poids `set_wt`*

```
data %>%
  mutate(treat_year = ifelse(treat_year == 0, "Counties non adoptants", as.character(treat_year))) %>%
  group_by(treat_year, year) %>%
  summarize(mortality = weighted.mean(crude_rate_20_64, set_wt)) %>%
  ggplot(aes(x = year, y = mortality, group = as.factor(treat_year), color = as.factor(treat_year))) +
  geom_point(size = 2) + geom_line(linewidth = 1) +
  scale_color_manual(values = c("#7C7189", "#D04E59", "#BC8E7D", "#2F3D70", "#CABEE9")) +
  scale_x_continuous(breaks = 2009:2019) +
  labs(x = "", y = "Mortalité (20-64) \n pour 100,000 habitants") +
  theme(legend.position = 'bottom',
        axis.title.y = element_text(hjust = 0.5, vjust = 0.5, angle = 360),
        strip.text = element_text(size = 14),
        panel.border = element_rect(color = "black", fill = NA, linewidth = 1),
        legend.title = element_blank(),
        panel.background = element_rect(fill = "#FAFAFA", color = "#FAFAFA"),
        plot.background = element_rect(fill = "#FAFAFA", color = "#FAFAFA"),
        axis.title = element_text(size = 12),
        axis.text = element_text(size = 10))
```

Solution: Medicaid Expansion

2) Tracez l'évolution du taux de mortalité moyen au cours du temps selon le groupe de traitement. Que remarquez-vous ?

- Hints: utiliser la variable `crude_rate_20_64` et les poids `set_wt`



Solution: Medicaid Expansion

3) Restreignez l'échantillon aux comtés des états adoptant en **2014** et des états **jamais adoptants**. Appelez ce sous-échantillon `data_2x2`.

4) Sur `data_2x2`, calculez le taux de mortalité moyen par groupe (adoptants 2014 / non-adoptants) et par période (avant 2014 / après 2014). Calculez l'estimateur DiD 2x2 à la main puis par régression OLS avec `feols()`. Interprétez.

```
data_2x2 = data %>%
  filter(treat_year %in% c(0, 2014))

did = data_2x2 %>%
  group_by(treat_year, post) %>%
  summarise(mortality = weighted.mean(crude_rate_20_64, set_wt)) %>%
  ungroup()

did_estimate = (did[did$treat_year == 2014 & did$post == 1, "mortality"] - did[did$treat_year == 2014 & did$post == 0, "mortality"]) - (did[did$treat_year == 0 & did$post == 1, "mortality"] - did[did$treat_year == 0 & did$post == 0, "mortality"])

did_estimate_ols = summary(feols(crude_rate_20_64 ~ treat*post, data = data_2x2, weights = ~set_wt))$coeftable["treat_2014:post_1"]
```

Solution: Medicaid Expansion

5) Sur l'ensemble des données `data`, estimez le TWFE suivant avec `feols()`. Interprétez.

```
data$post_all = ifelse(data$treat == 1 & data$year ≥ data$treat_year, 1, 0)

twfe = feols(crude_rate_20_64 ~ post_all | county_code + year, data = data, weights = ~ as.numeric(set_wt), cluster =
etable(twfe)
```

```
##                               twfe
## Dependent Var.: crude_rate_20_64
##
## post_all          -0.9352 (2.177)
## Fixed-Effects:  -----
## county_code              Yes
## year                    Yes
## -----
## S.E.: Clustered by: county_code
## Observations          28,644
## R2                     0.93863
## Within R2              6.52e-5
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Solution: Medicaid Expansion

6) Réalisez une **event-study** en estimant : `crude_rate_20_64 ~ i(time_to_treat, ref = -1) | county_code + year`

Représentez graphiquement les coefficients $\hat{\beta}_k$ avec leurs intervalles de confiance à 95%.

Que nous apprend ce graphique sur l'hypothèse de tendances parallèles ? Sur l'effet du traitement?

```
es = feols(crude_rate_20_64 ~ i(time_to_treat, treat, ref = -1) | county_code + year, data = data, weights = ~ set_wt)

coefs_es = broom::tidy(es, conf.int = TRUE) %>%
  filter(str_detect(term, "time_to_treat")) %>%
  mutate(k = as.numeric(str_extract(term, "-?[0-9]+"))) %>%
  bind_rows(tibble(k = -1, estimate = 0, conf.low = 0, conf.high = 0)) %>%
  arrange(k)


ggplot(coefs_es, aes(x = k, y = estimate)) +
  geom_hline(yintercept = 0, linetype = "dashed", color = "gray50", linewidth = 0.8) +
  geom_vline(xintercept = -0.5, linetype = "dotted", color = "gray50", linewidth = 0.8) +
  geom_ribbon(aes(ymin = conf.low, ymax = conf.high),
    fill = "#f8cdda", alpha = 0.6) +
  geom_line(color = "#D04E59", linewidth = 1) +
  geom_point(color = "#D04E59", size = 2.5) +
  geom_point(data = filter(coefs_es, k == -1),
    shape = 21, fill = "white", color = "#D04E59", size = 3) +
  scale_x_continuous(breaks = seq(-10, 5, by = 1)) +
  labs(
```

Solution: Medicaid Expansion

6) Réalisez une **event-study** en estimant : `crude_rate_20_64 ~ i(time_to_treat, ref = -1) | county_code + year`

Représentez graphiquement les coefficients $\hat{\beta}_k$ avec leurs intervalles de confiance à 95%.

Que nous apprend ce graphique sur l'hypothèse de tendances parallèles ? Sur l'effet du traitement ?



VRAIS effets de l'expansion Medicaid sur la mortalité


Les estimations obtenues sont purement illustratives:

- nos données agrégées au niveau comté diluent l'effet en incluant des populations non éligibles à Medicaid
- elles couvrent une fenêtre post-traitement trop courte pour que les effets sur la mortalité se matérialisent

Miller, Johnson and Wherry (2021, QJE): *individuals in expansion states experienced a 0.132 percentage point decline in annual mortality, a 9.4% reduction over the sample mean, as a result of the Medicaid expansions. The effect is driven by a reduction in disease-related deaths and grows over time.*

Miller et al. (2021, QJE)

Figure II: Effect of the ACA Medicaid Expansions on Annual Mortality



Recap: Méthode des Doubles Différences

Data: Données de pannel

Hypothèses d'identification:

- **Parallel Trends:** en l'absence du traitement, les groupes traités et contrôles auraient évolué de manière similaire ($\mathbb{E}[Y_{i2}(0) - Y_{i1}(0)|D_i = 1] = \mathbb{E}[Y_{i2}(0) - Y_{i1}(0)|D_i = 0]$)
- **Absence d'anticipation:** le traitement n'a pas d'effet avant sa mise en place $Y_{i1}(1) = Y_{i1}(0)$

Modèle TWFE : pour tout individu i et période t ,

$$Y_{it} = \beta D_{it} + \delta_i + \gamma_t + \varepsilon_{it}$$

Implémentation sur R: package `fixest`

- `feols(y ~ i(post, treat, ref = 0) | FE, data = data)`
- de Chaisemartin and d'Hautefeuille (2020), package R `DIDmultiplgtDYN`
- Callaway and Sant'Anna (2021), package R `did`
- Sun and Abraham (2020), `sunab()` argument in `fixest`
- Borusyak, Jaravel and Spiess (2024), package R `didimputation`

Sources

Borusyak, Kirill, Xavier Jaravel, and Jann Spiess, “Revisiting Event Study Designs: Robust and Efficient Estimation,” Review of Economic Studies, 2024

de Chaisemartin, Clément and Xavier D’Haultfœuille, “Two-Way Fixed Effects Estimators with Heterogeneous Treatment Effects,” American Economic Review, 2020, 110 (9), 2964–2996.

Callaway, Brantly and Pedro H. C. Sant’Anna, “Difference-in-Differences with Multiple Time Periods,” Journal of Econometrics, 2021, 225 (2), 200–230.

[Causal inference: The Mixtape, Scott Cunningham](#)

[Panel Data, Peter Hull](#)

[Introduction to DiD with Multiple Time Periods, Callaway and Sant'Anna](#)

[Differences-in-Differences, Florian Oswald, Gustave Kennedy, Pierre Villedieu et Mylène Feuillade](#)

[Interactive reproduction of Difference-in-Differences Designs: A Practitioner's Guide, by Andrew Baker, Brantly Callaway, Scott Cunningham, and Andrew Goodman-Bacon, Journal of Economic Literature](#)

Sun, Liyan and Sarah Abraham, “Estimating Dynamic Treatment Effects in Event Studies with Heterogeneous Treatment Effects,” Journal of Econometrics, 2021, 225 (2).