

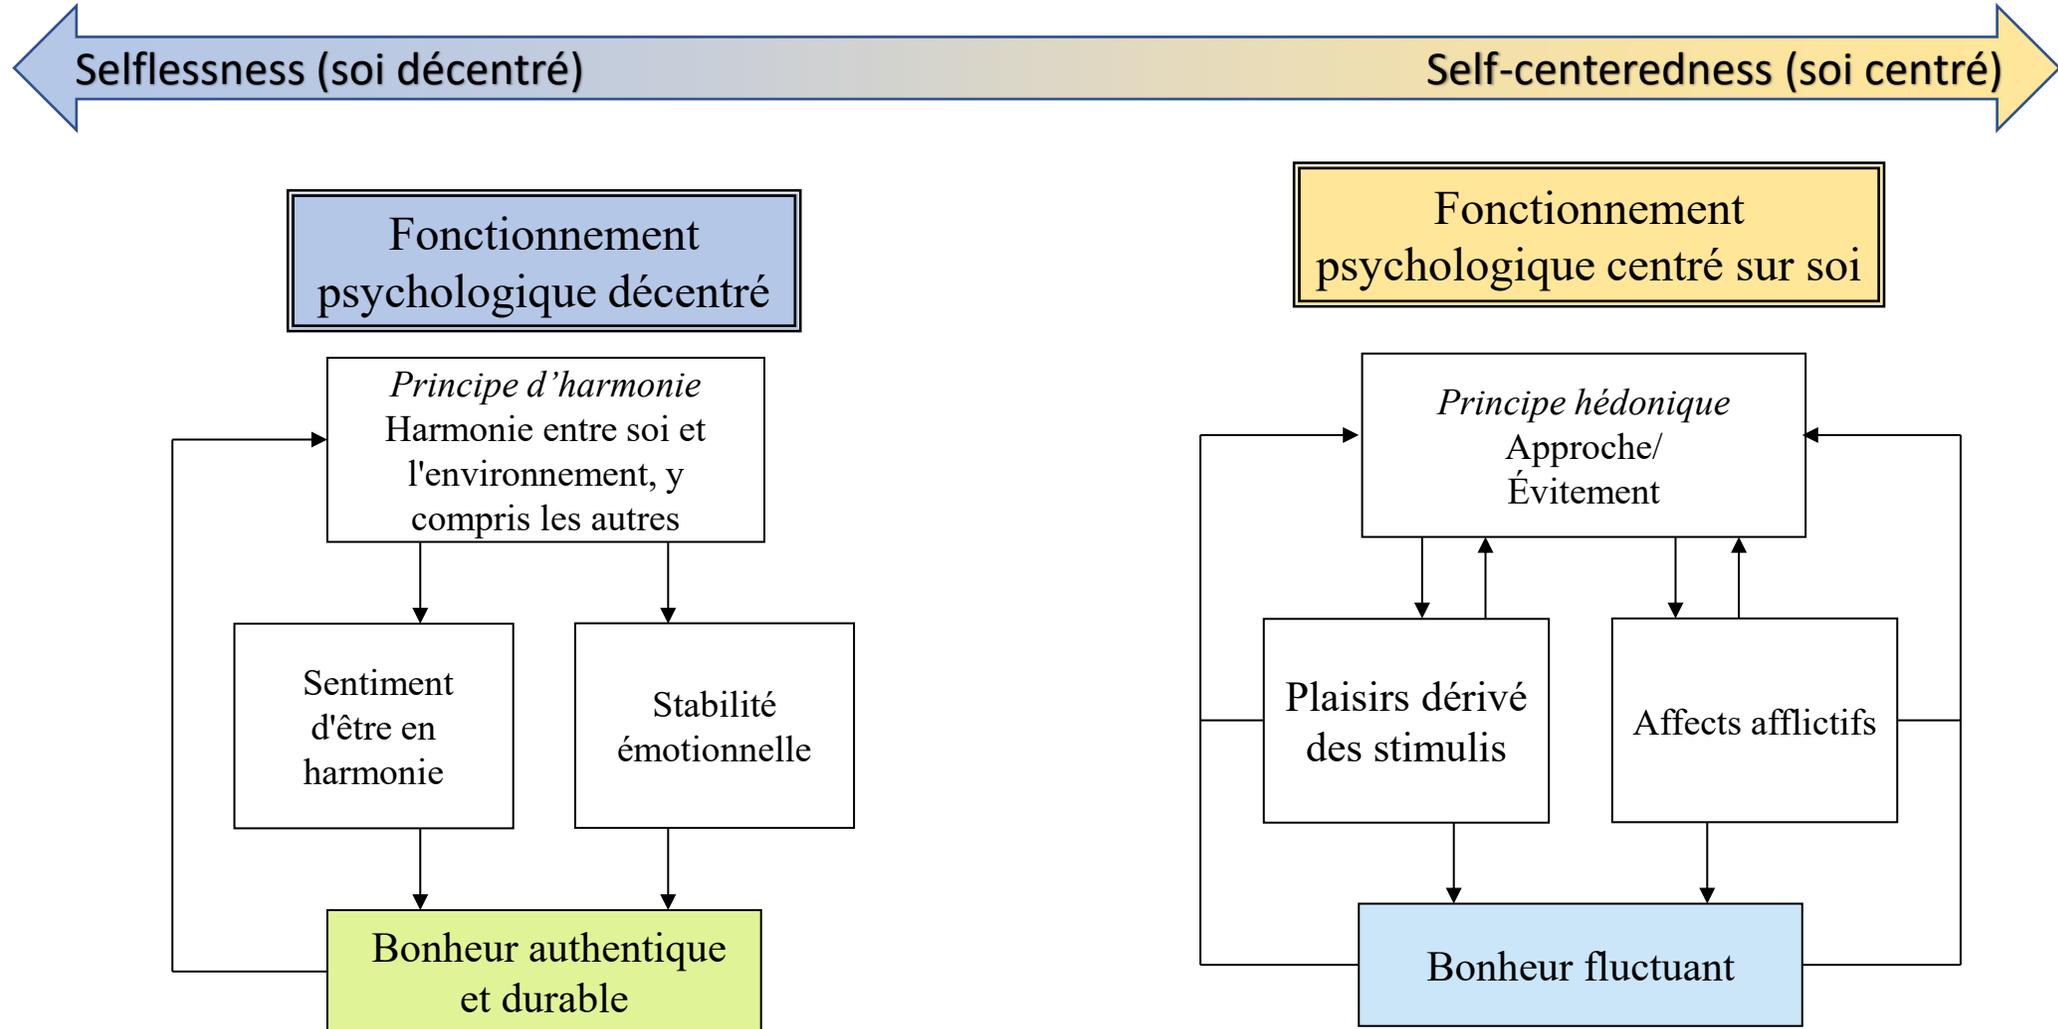
# Modélisation à temps continu du lien entre la centration du soi et le bonheur

Nicolas Pellerin, Lucas David, Eric Raufaste, Michaël Dambrun

Modevaiaa – 2025



# Le modèle du bonheur basé sur le soi centré / décentré



# Études antérieures :

## Étude corrélacionnelle via questionnaires auto-rapportés (Dambrun, 2017):

- Les analyses factorielles montrent que le soi centré et le soi décentré sont des construits relativement distincts
- Les hypothèses de médiation sont corroborées

## Études expérimentales :

- La méditation affecte le bien-être via la dilution des frontières corporelles (Dambrun, 2016)
- La méditation affecte le sentiment d'être en harmonie via un sentiment d'unité plus important (Dambrun, 2019)

## Limites :

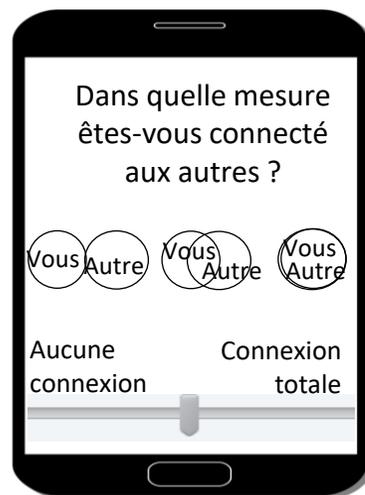
- Ces études mesurent le bonheur « rappelé »
- le soi centré/décentré devrait être relié au bien-être « expérimenté »

D'où l'idée d'utiliser la technique d'échantillonnage des expériences (ESM)

(Csikszentmihalyi & Hunter, 2003)

# La structure du soi centré/décentré au niveau minimal

Etudes par sondage quotidien	Etude 1 (Pellerin et al., 2020)	Etude 2 (Pellerin et al., 2022)
<i>N</i>	64, $M_{age} = 26.3$ , 70% femme	102, $M_{age} = 42.8$ , 85.1% femme
Nombre d'occasion	5 fois par jour pendant 2 jours	7 fois par jour pendant 5 jour
Total données collectées	507/640	1687/3570

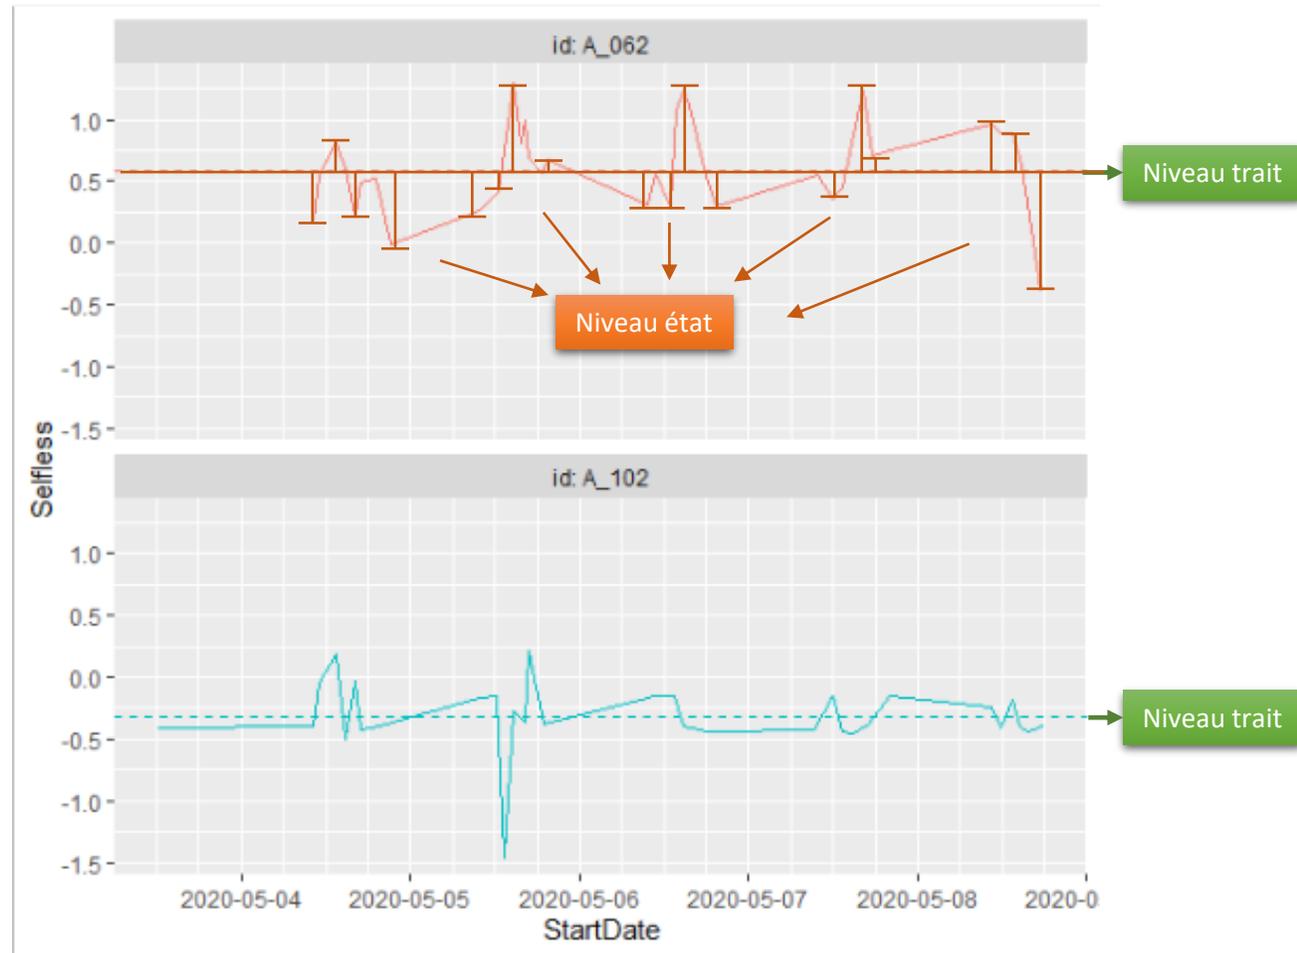


- ❖ Fiabilité de la mesure :
  - ❖ Niveau inter-sujet :  $\alpha = 0.68$
  - ❖ Niveau intra-sujet :  $\alpha = 0.59$
- ❖ Modèle au niveau intra-individuel :
  - ❖ CFI = 0.99, SRMR = 0.06, RMSEA = 0.04



# Résultats des études par sondage quotidien (Etude 2)

- H1 : Association avec le bonheur au niveau « trait »
- H2 : Association avec le bonheur au niveau « état »



# Résultats des études par sondage quotidien (Etude 2)

H3: association avec la stabilité du- bonheur

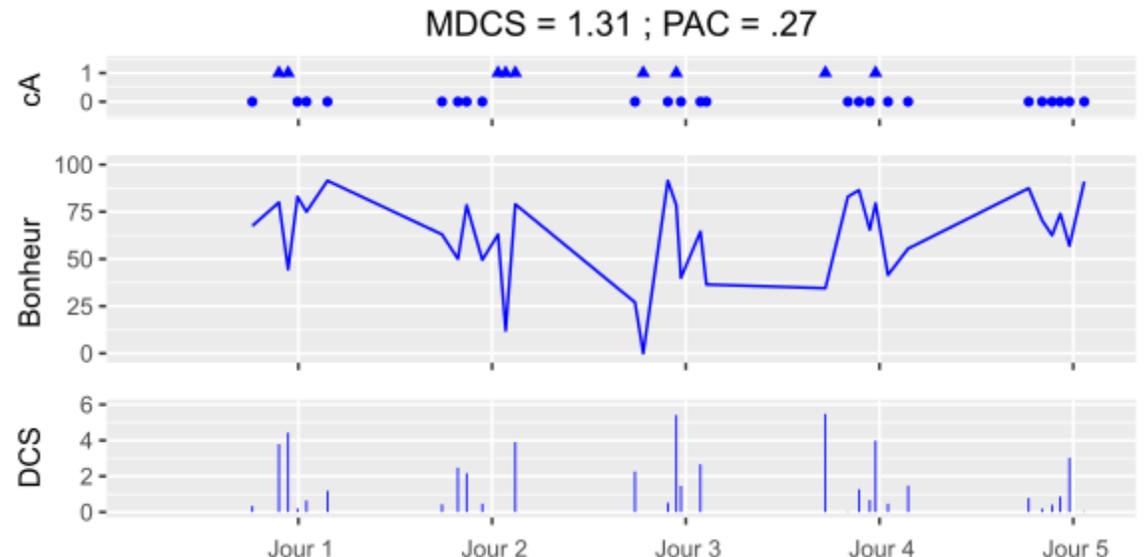
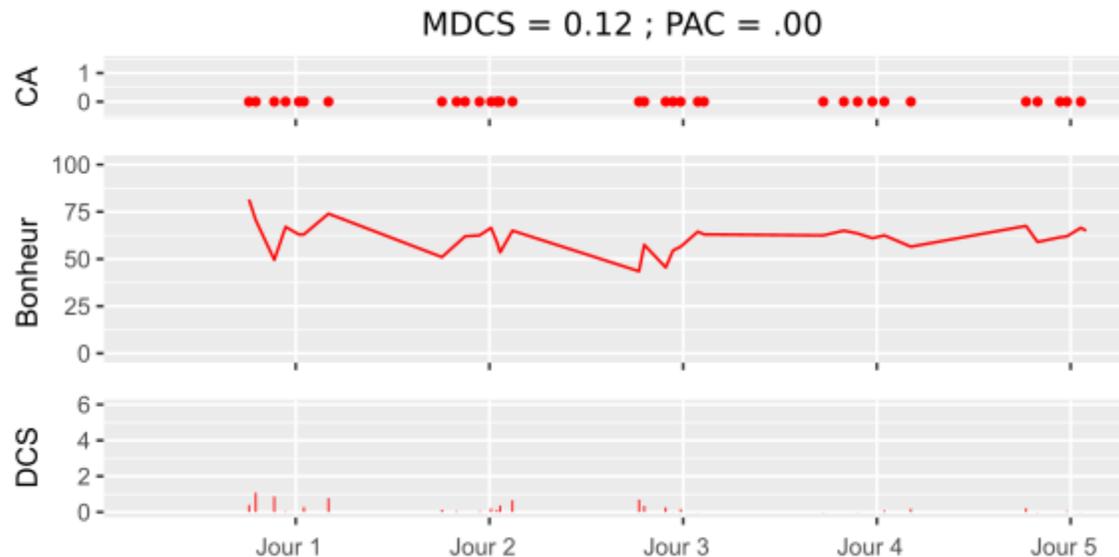
CDS = Carré des différences successives

CA = changement accru (5% des différences extrêmes)

MCDS = Moyenne des CDS (pour un individu donné)

PCA = Probabilité de changement accru

(Jahng et al., 2008)



## Niveau trait

Personnes décentrées → Niveau de bonheur expérimenté



→ Stabilité intra-journalière



→ Stabilité inter-journalière



CDS  
CA

## Niveau état

Moments de décentration → Niveau de bonheur expérimenté



→ Stabilité intra-journalière



→ Stabilité inter-journalière

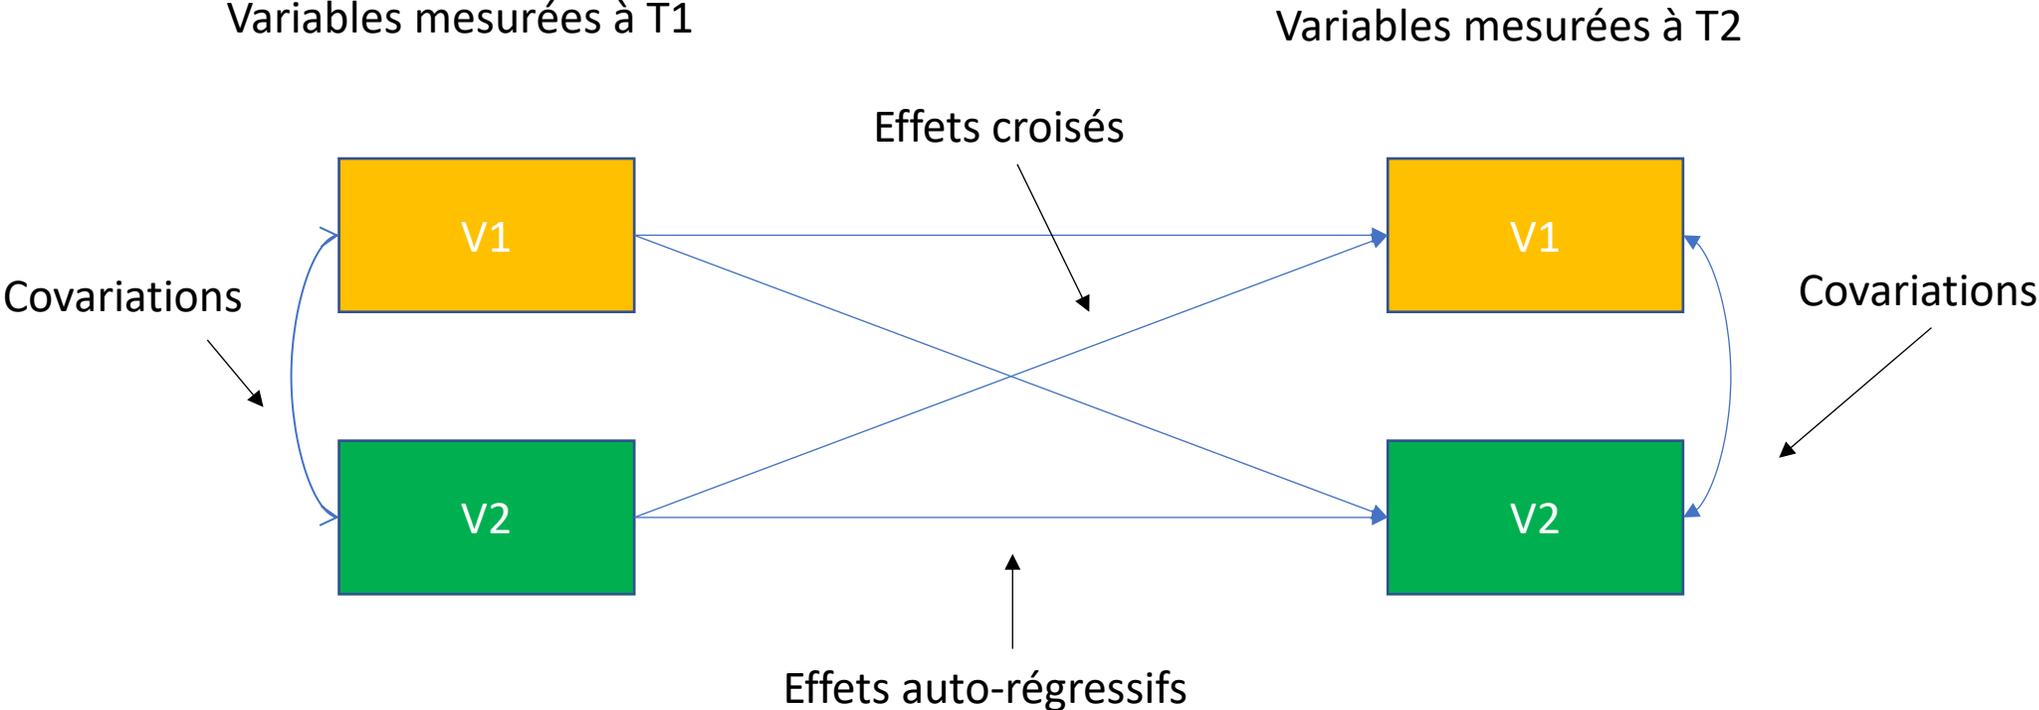


CDS  
CA

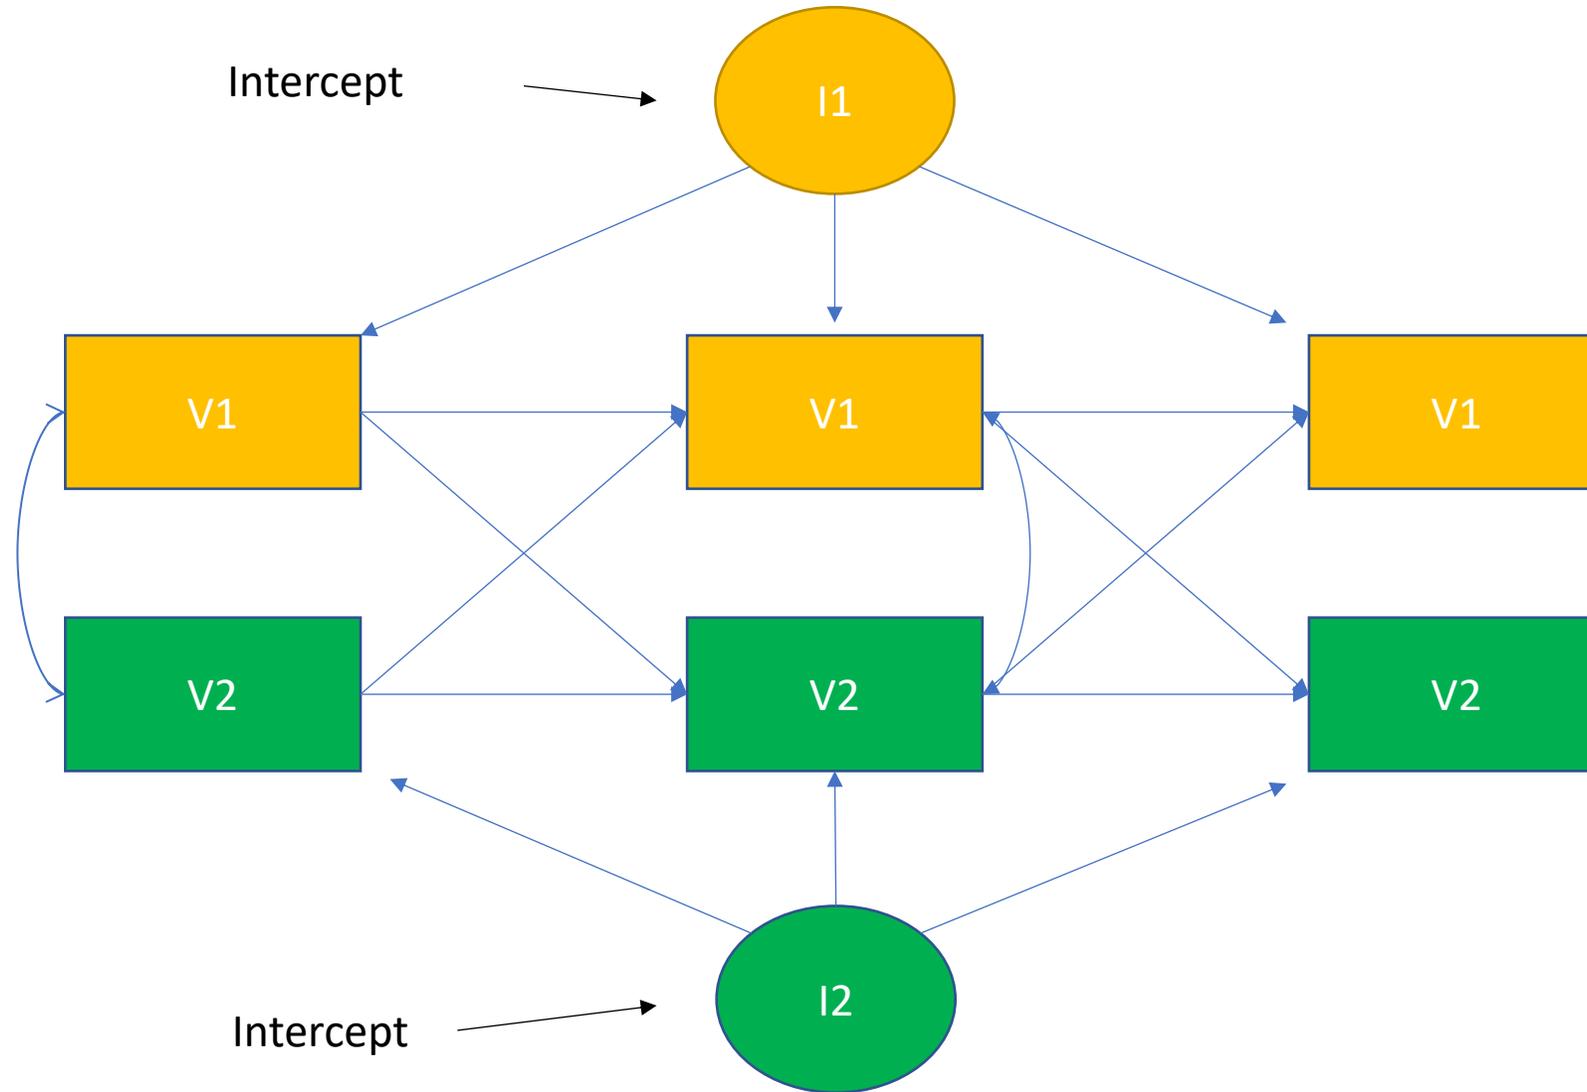
# Conclusion

- Le soi décentré est relié au bonheur expérimenté aux niveaux trait et état
- Le soi décentré est relié à la stabilité du bonheur dans certains cas
- Cela contribue à vérifier le MBSCD mais des nuances théoriques sont nécessaires
- Mais que dire du lien temporel entre les deux variables ?

# Cross-lagged panel analysis (CLPM)



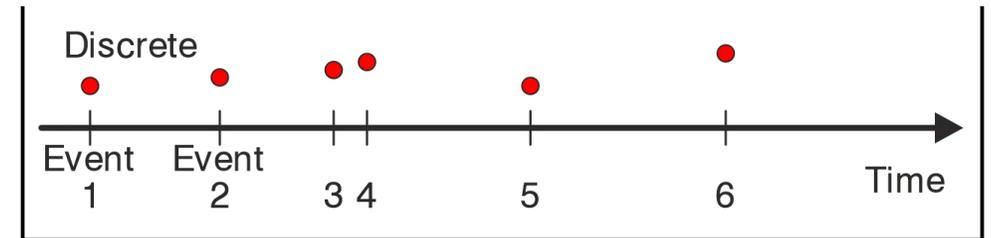
# Random Intercept - Cross-lagged panel analysis (RI-CLPM)



# Estimation du lien croisé dans le temps

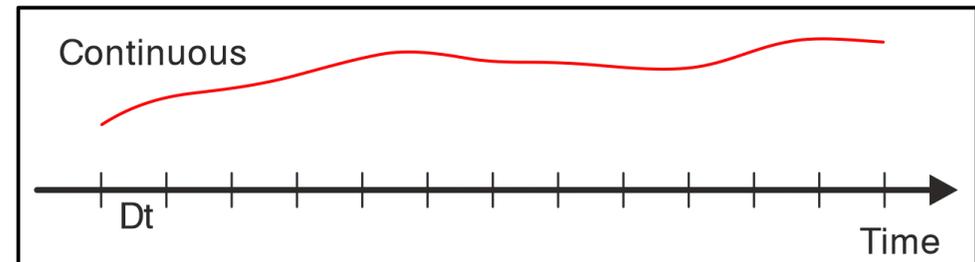
Problèmes avec les analyses longitudinales classiques (CLPM, RI-CLPM, LGCA...) :

- Les intervalles de temps sont discrètes
- Contrainte : construire des protocoles avec des intervalles de temps égaux entre chaque mesure
- Les études ayant des intervalles de temps variables ou aléatoires ne peuvent pas être analysées, ou des biais sont introduits



# Estimation du lien croisé dans le temps

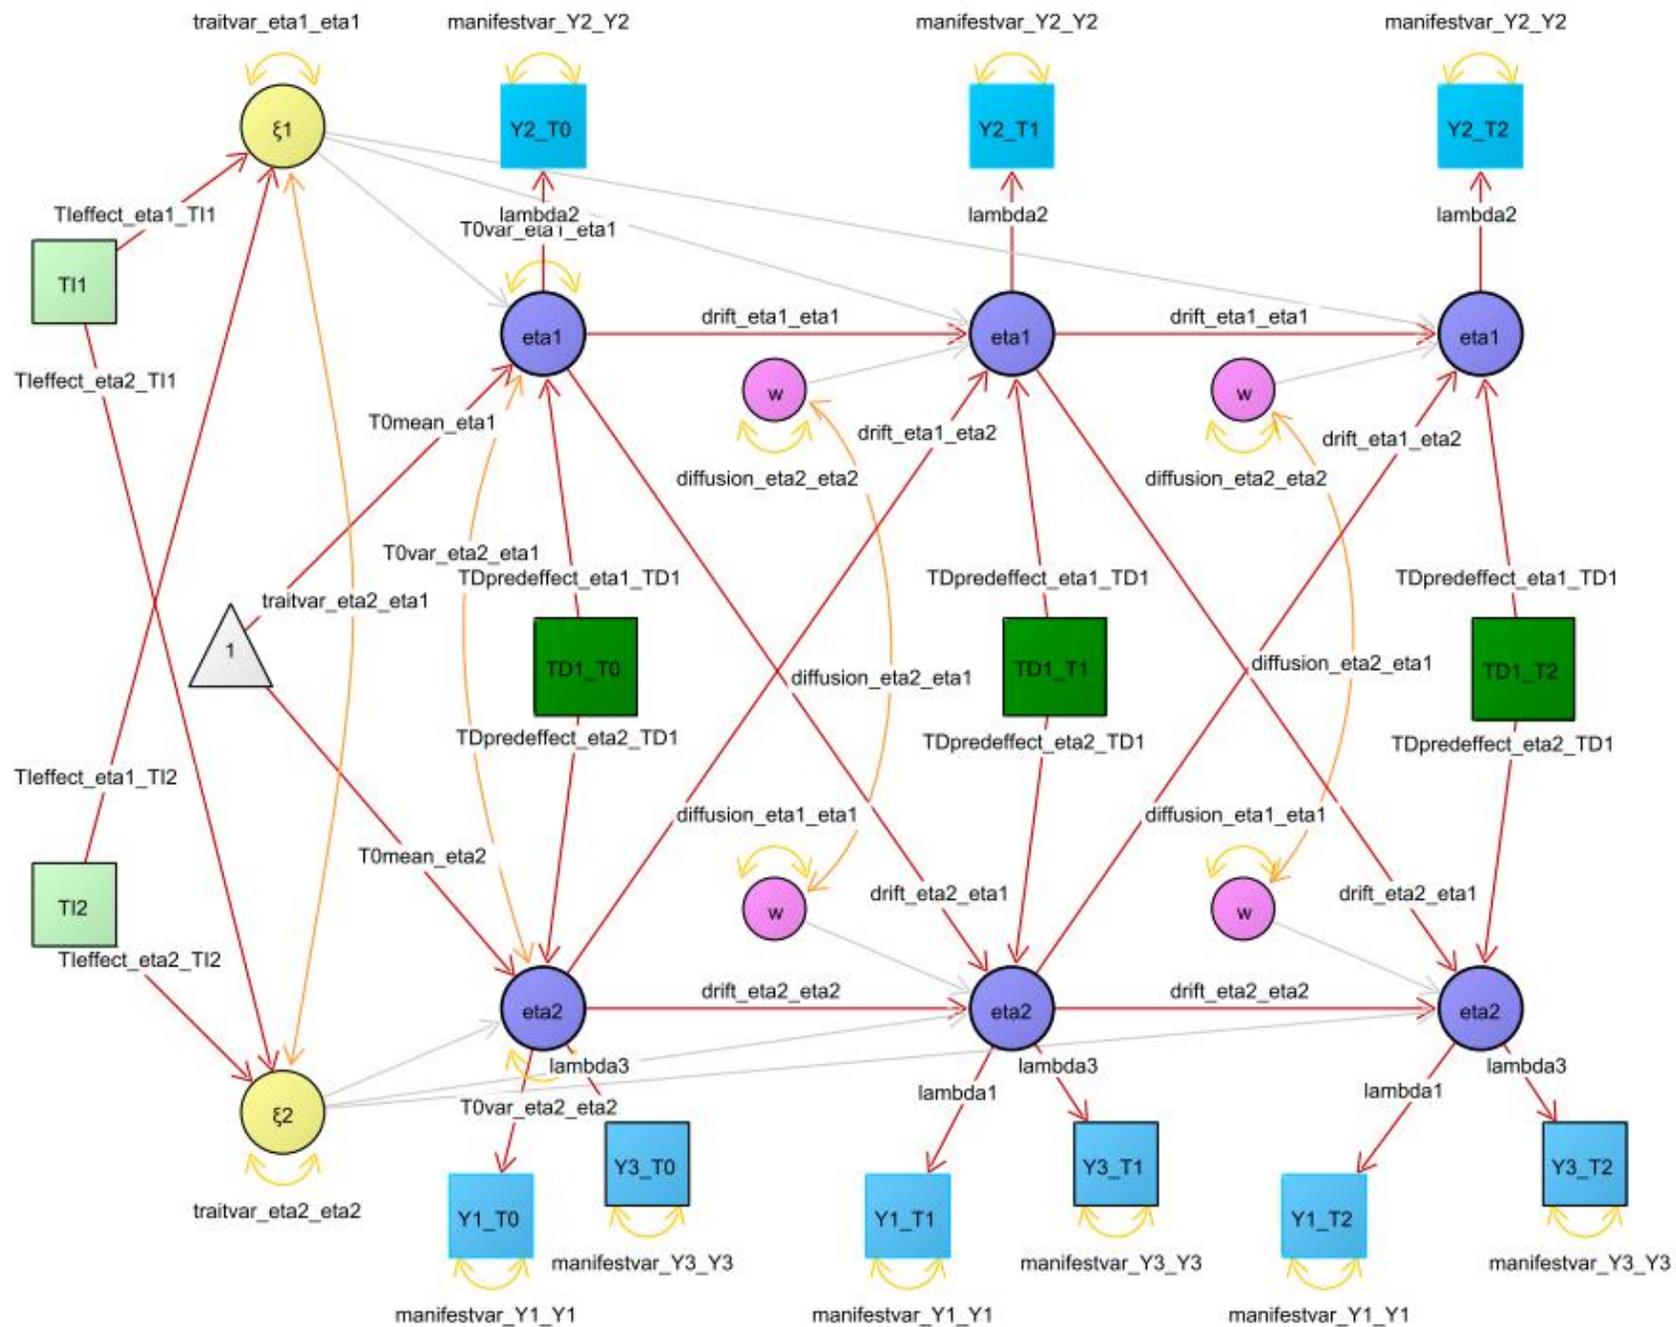
Principe de la modélisation à temps continu : prise en compte de la longueur de l'intervalle de temps entre deux mesures longitudinales.



Cela a plusieurs avantages :

- Permet d'estimer les effets en fonction du temps, et donc d'interroger l'intervalle de temps optimal pour l'observer (Dormann & Griffin, 2015)
- Les intervalles de temps randomisées (ESM) deviennent riches d'informations
- Possibilité d'évaluer l'intervalle de temps optimal
- Particulièrement adapté pour les études longitudinales intensives

# Modélisation dynamique hiérarchique bayésienne à temps continu (Driver & Voelkle, 2018)



# Modélisation à temps continu

Sur R : package ctsem (CRAN)

Même principe que les équations structurelles mais implémentant le temps continu comme paramètre.

## **Etapas préalables :**

- Disposer de nombreuses données longitudinales, au format long (1 ligne par observation)
- Disposer d'une variable de temps continue (nommée 'time')
- Nommer la variable de cluster 'id' (individus dans notre cas)
- Standardiser les variables ( $M=0$ ,  $ET=1$ )

# Modélisation à temps continu

## Etape 1 : spécification du modèle

```
model1 <- ctModel(type='stanct', n.latent = 2, n.manifest = 2,  
                 latentNames = c("Selfless", "Happiness"),  
                 manifestNames = c(" Selfless ", " Happiness " ),  
                 LAMBDA = diag(2))
```

Nombre de variables



Nom des variables



## Etape 2 : calcul des estimations

```
ctmodel <- ctStanFit(datalong = dat, ctstanmodel = model1)
```

# Modélisation à temps continu

Etape 3 : Prédire les valeurs sur un intervalle de temps donné

```
fullpredict<-ctStanDiscretePars(ctmodel,  
  times = seq(from = 0, to = 30, by = 0.1))
```

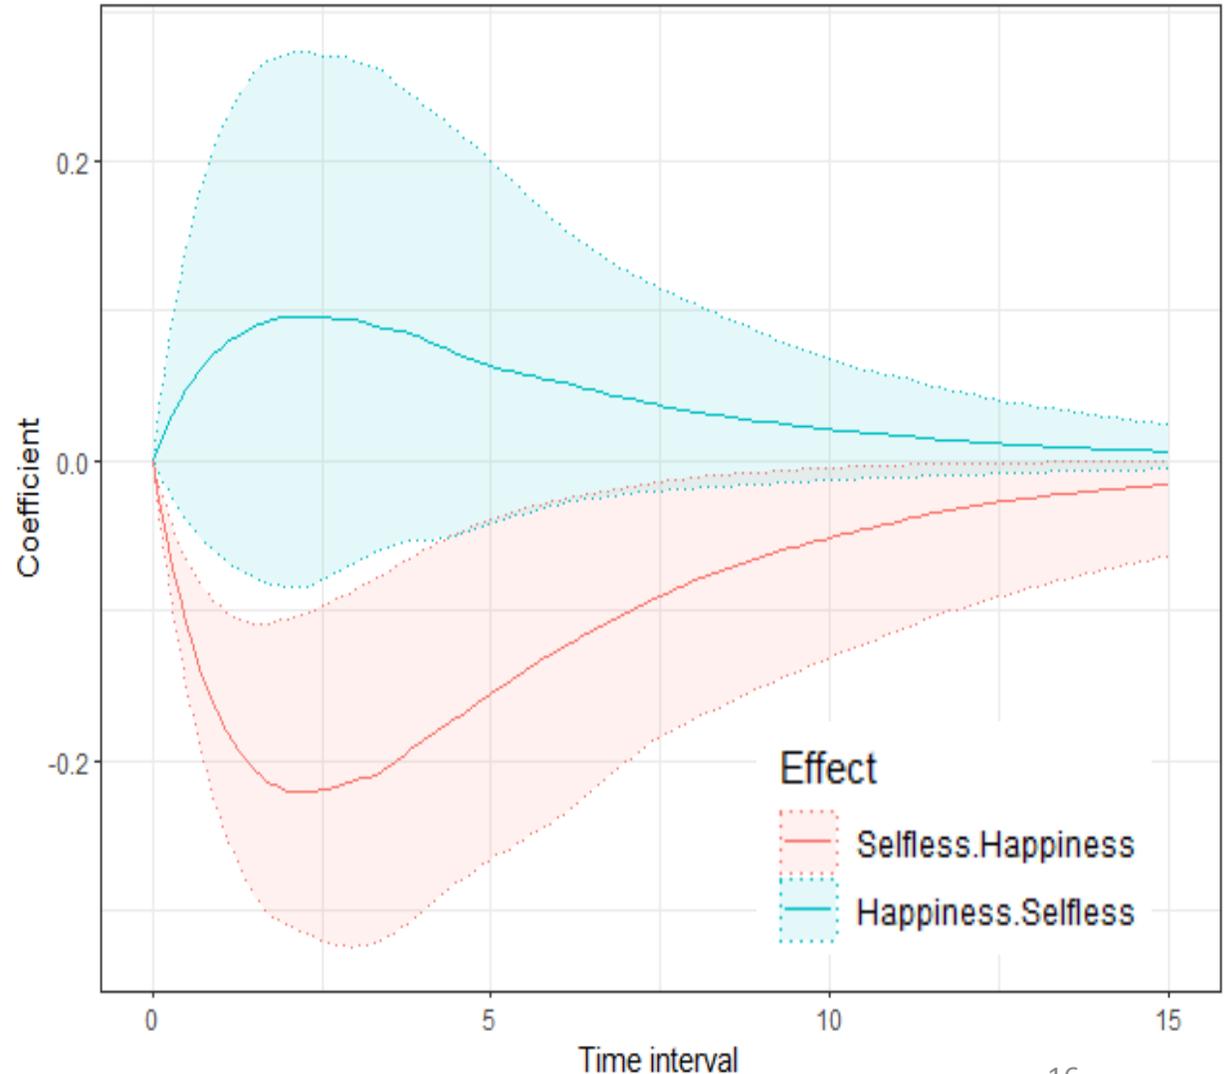
Etape 4 : Générer le graphique de ces prédictions

- Effets auto-regressifs (AR)

```
ctStanDiscreteParsPlot(fullpredict, indices = " AR ")
```

- Effets croisés (Cross Lagged = CR)

```
ctStanDiscreteParsPlot(fullpredict, indices = " CR ")
```



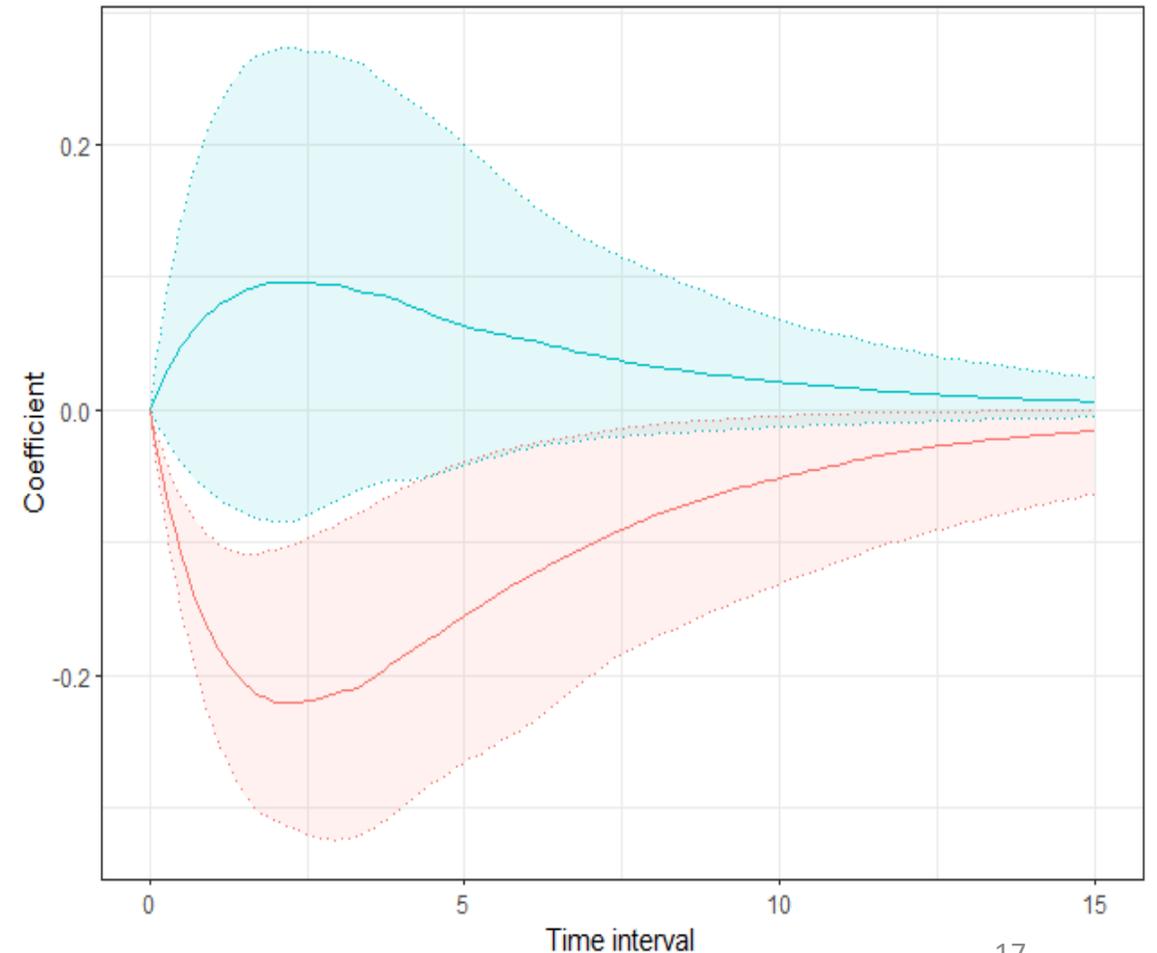
# Modélisation à temps continu

Etape 5 : Obtenir les indices à un moment spécifique

```
summary(ctmodel,timeinterval=2.4)
```

\$popmeans	mean	sd	2.5%	50%	97.5%
T0m_Selfless	-0.1527	0.0852	-0.3181	-0.1535	0.0056
T0m_Happiness	-0.0864	0.0996	-0.2782	-0.0869	0.1126
drift_Selfless	-0.1773	0.0957	-0.4146	-0.1558	-0.0568
drift_Selfless_Happiness	-0.2868	0.0542	-0.3974	-0.2862	-0.1843
drift_Happiness_Selfless	0.2270	0.1408	-0.0571	0.2338	0.4829
drift_Happiness	-0.8025	0.1177	-1.0323	-0.8010	-0.5880
diff_Selfless	0.4919	0.0412	0.4185	0.4892	0.5788
diff_Happiness_Selfless	0.5779	0.0738	0.4194	0.5815	0.7122
diff_Happiness	0.8146	0.0594	0.6986	0.8138	0.9270
mvarSelfless	0.3933	0.0260	0.3460	0.3921	0.4488
mvarHappiness	0.2391	0.0604	0.1405	0.2301	0.3725
mm_Selfless	0.0242	0.0899	-0.1474	0.0223	0.1948
mm_Happiness	-0.0351	0.0742	-0.1729	-0.0349	0.1095

SL -> Bonheur  
Bonheur -> SL



# Modélisation à temps continu

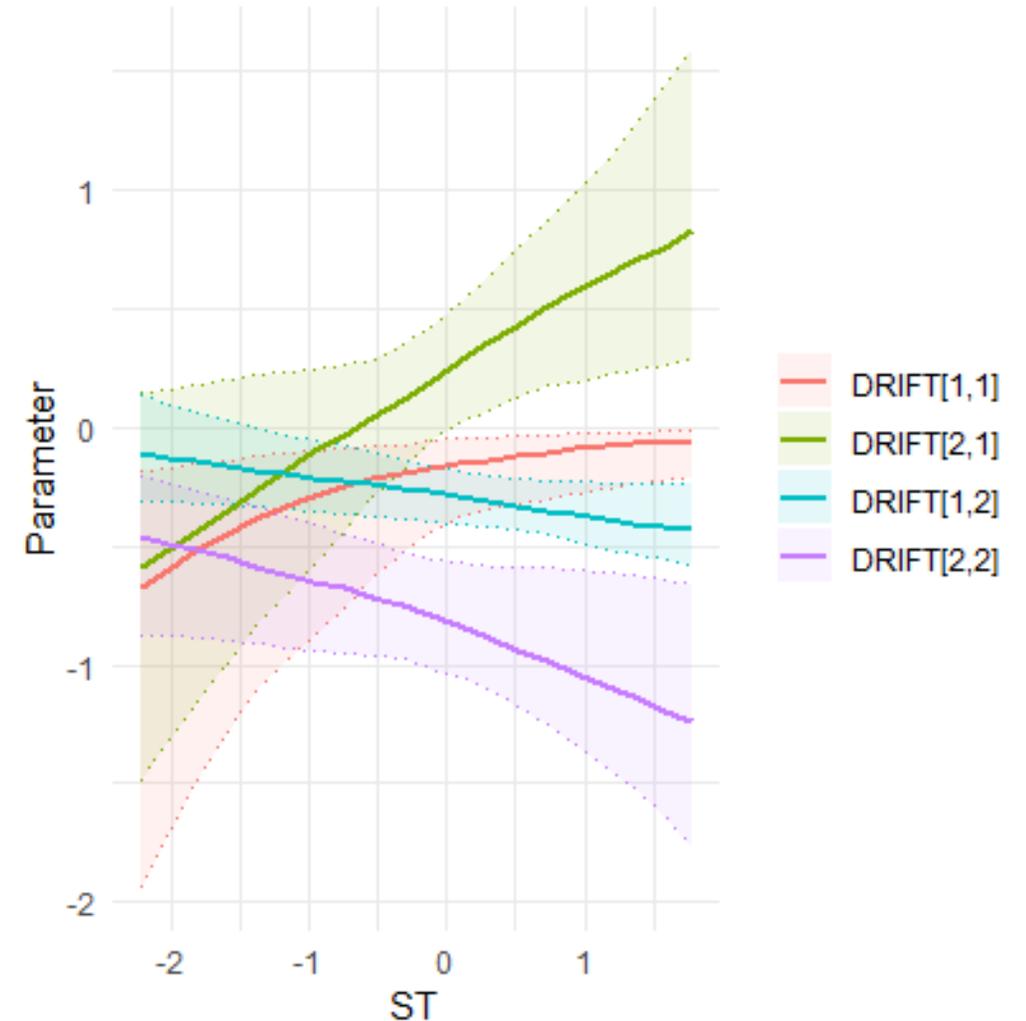
## Ajout d'un prédicteur « trait » (Time Independent = TI)

```
ctmodel <- ctModel(type='stanct', n.latent = 2, n.manifest = 2,  
  latentNames = c("Selfless", "Happiness"),  
  manifestNames = c(" Selfless ", " Happiness " ),  
  LAMBDA = diag(2),  
  TIpredNames =c("ST"))
```

Variable « trait »

## Estimation des indices en fonction de la variable inter-sujet pour un intervalle de temps donné

```
ctStanTIpredEffects (ctmodel, plot = TRUE,  
  whichpars= c ('DRIFT'), timeinterval = 2.4, whichTIpreds = 1)
```



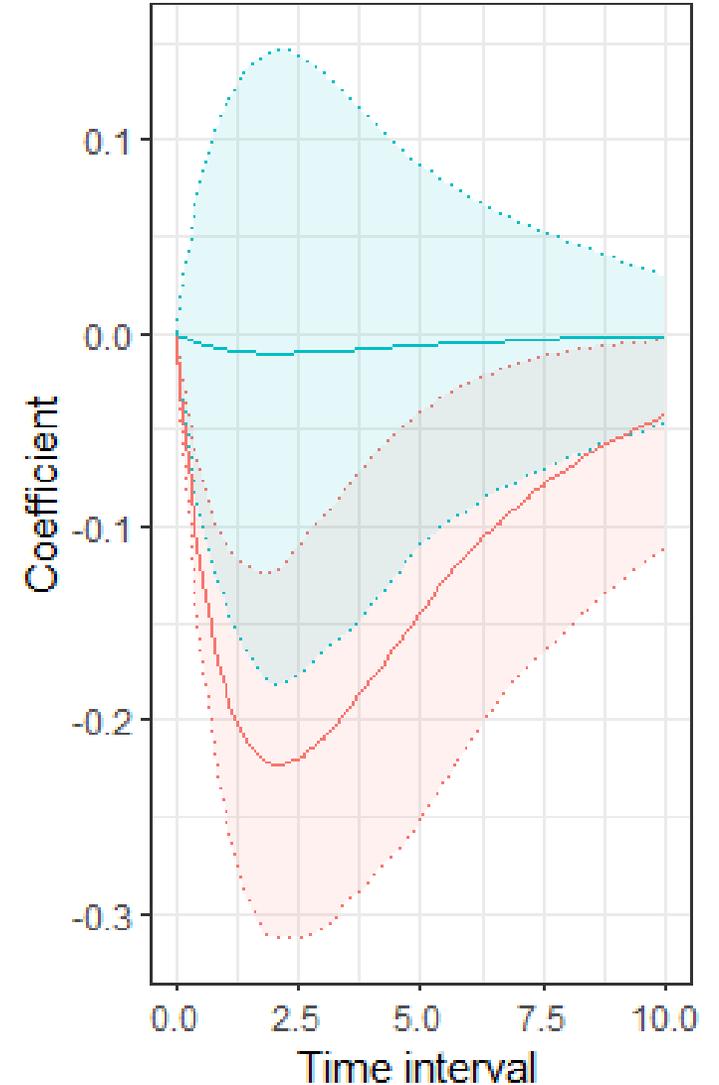
# Modélisation à temps continu

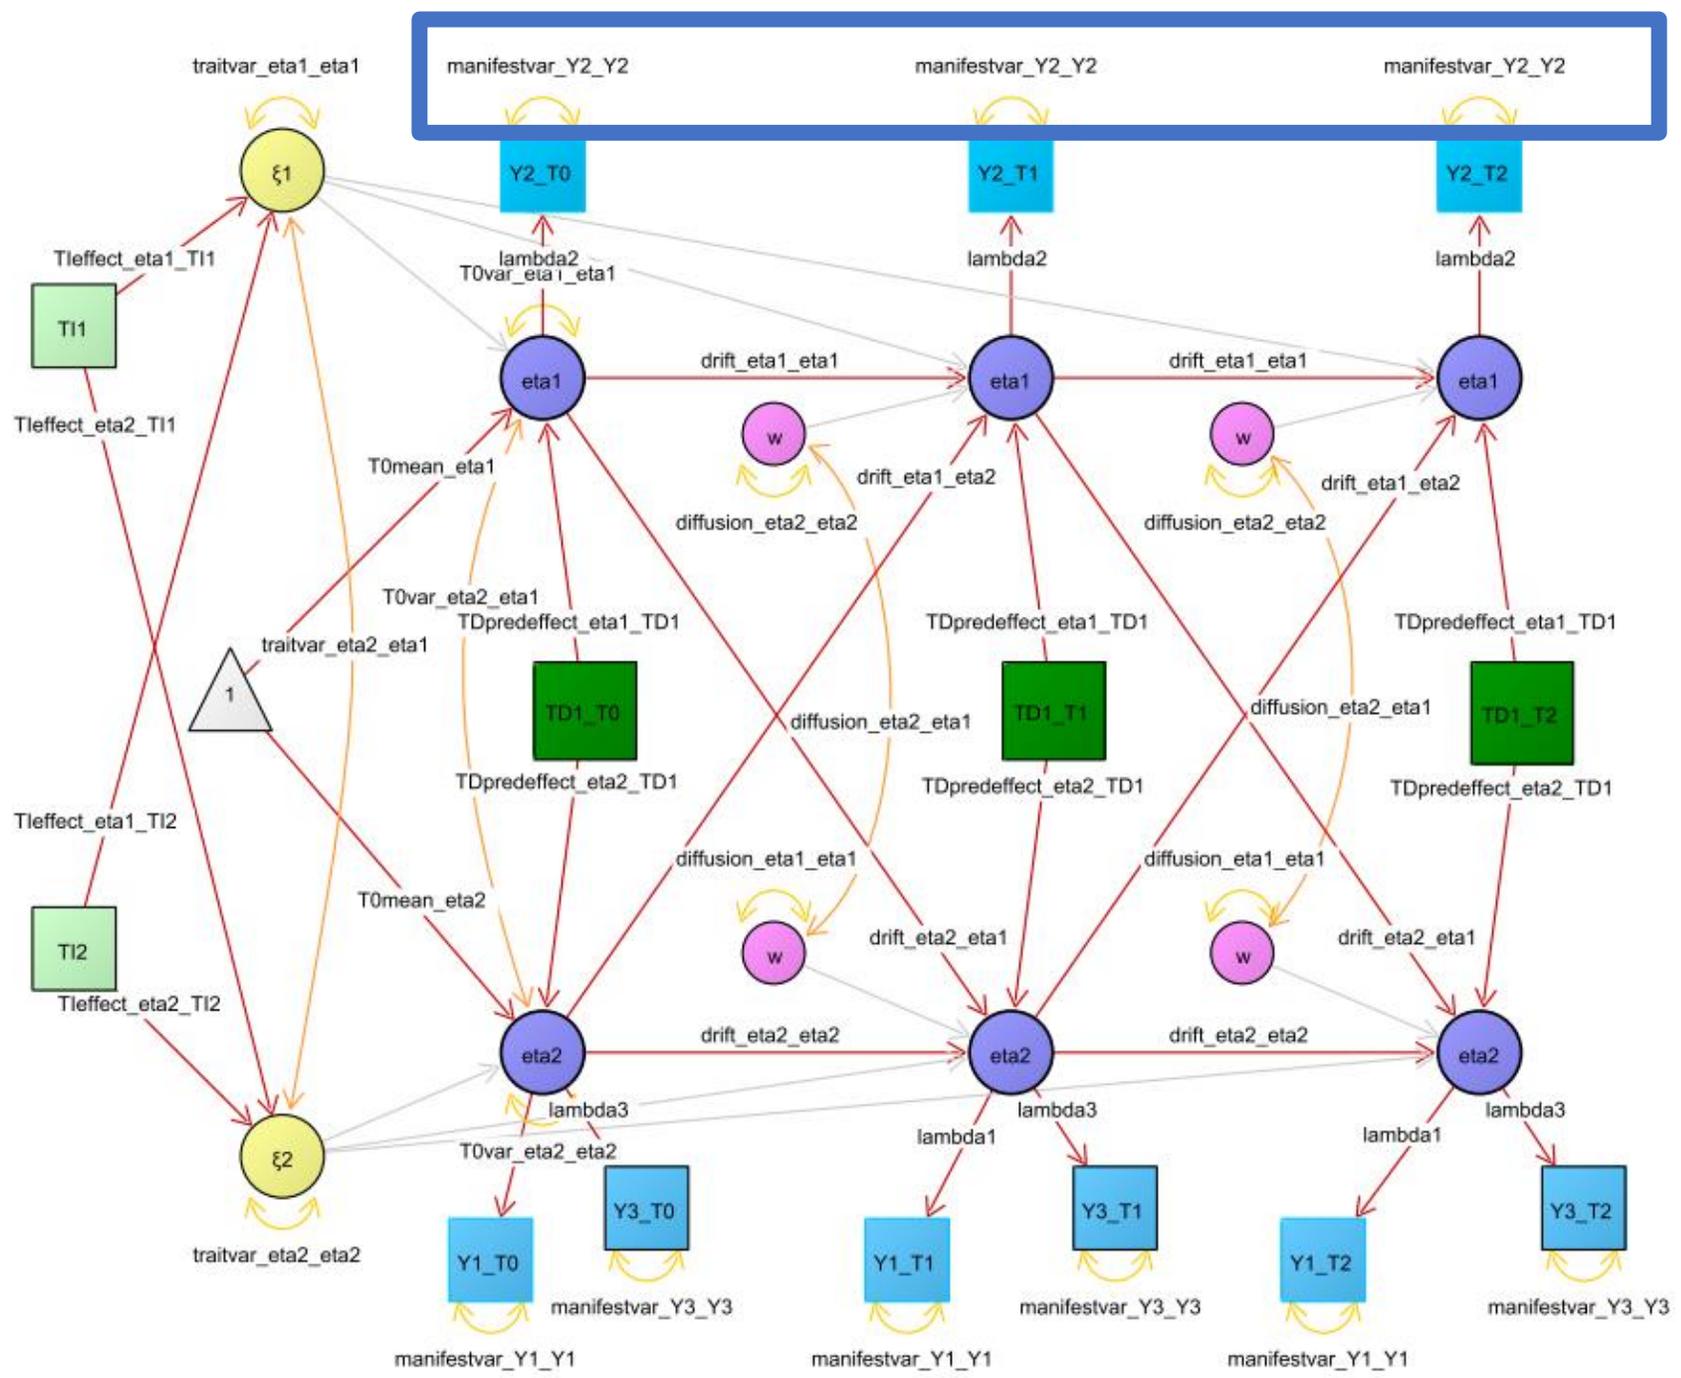
Ajout d'un prédicteur « état » (Time Dependent = TD)

```
ctmodel <- ctModel(type='stanct', n.latent = 2, n.manifest = 2,  
  latentNames = c("Selfless", "Happiness"),  
  manifestNames = c(" Selfless ", " Happiness " ),  
  LAMBDA = diag(2),  
  TDpredNames = c("Event_val"))
```

Variable « état »

```
$popmeans  
td_Selfless_Event_val      mean    sd    2.5%    50%    97.5%  
td_Happiness_Event_val    -0.3376 0.0164 -0.3703 -0.3372 -0.3078
```





# Modélisation à temps continu

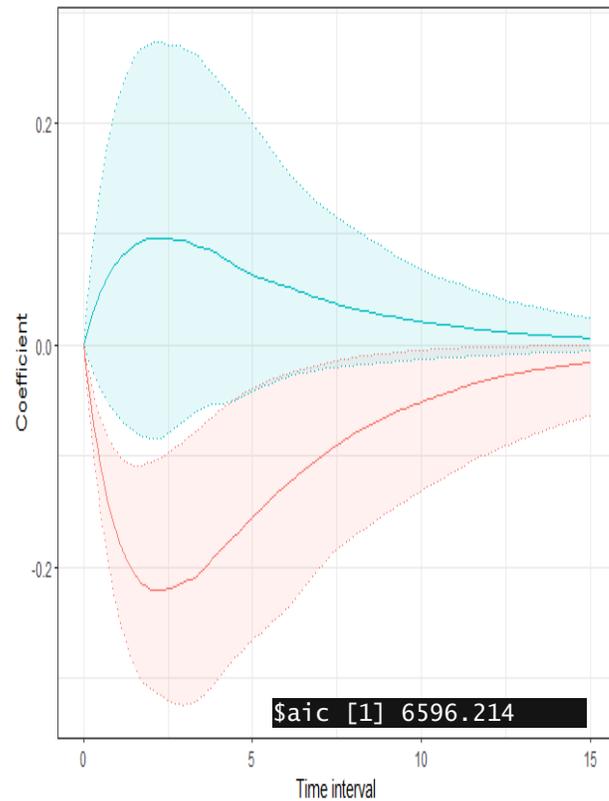
Paramètres aléatoires : Laisser libre les variations de certains paramètres à l'intérieur des clusters (individus)

Variance manifeste des variables :

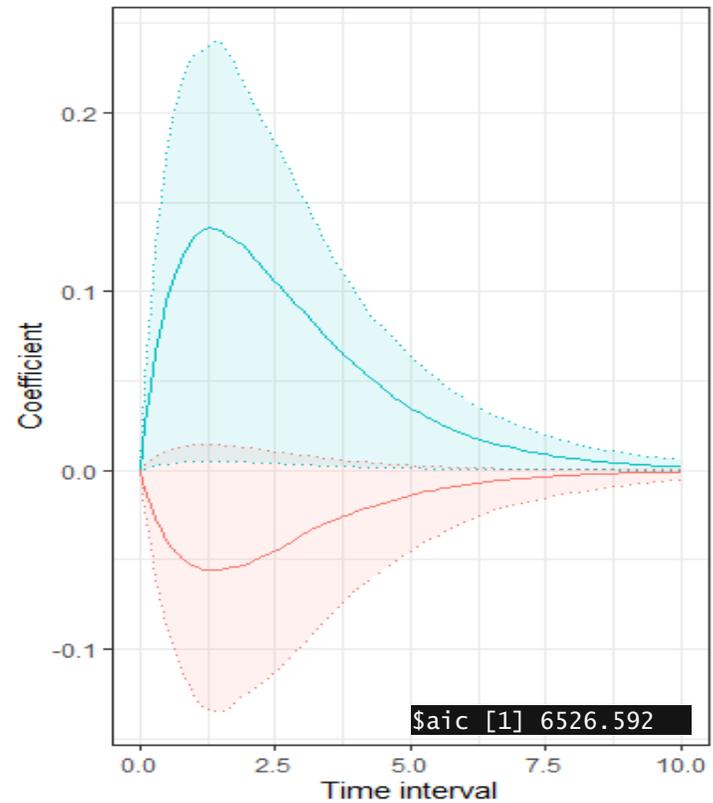
```
model1$pars$indvarying[(model2$pars$matrix %in% c('MANIFESTVAR'))] <- TRUE
```

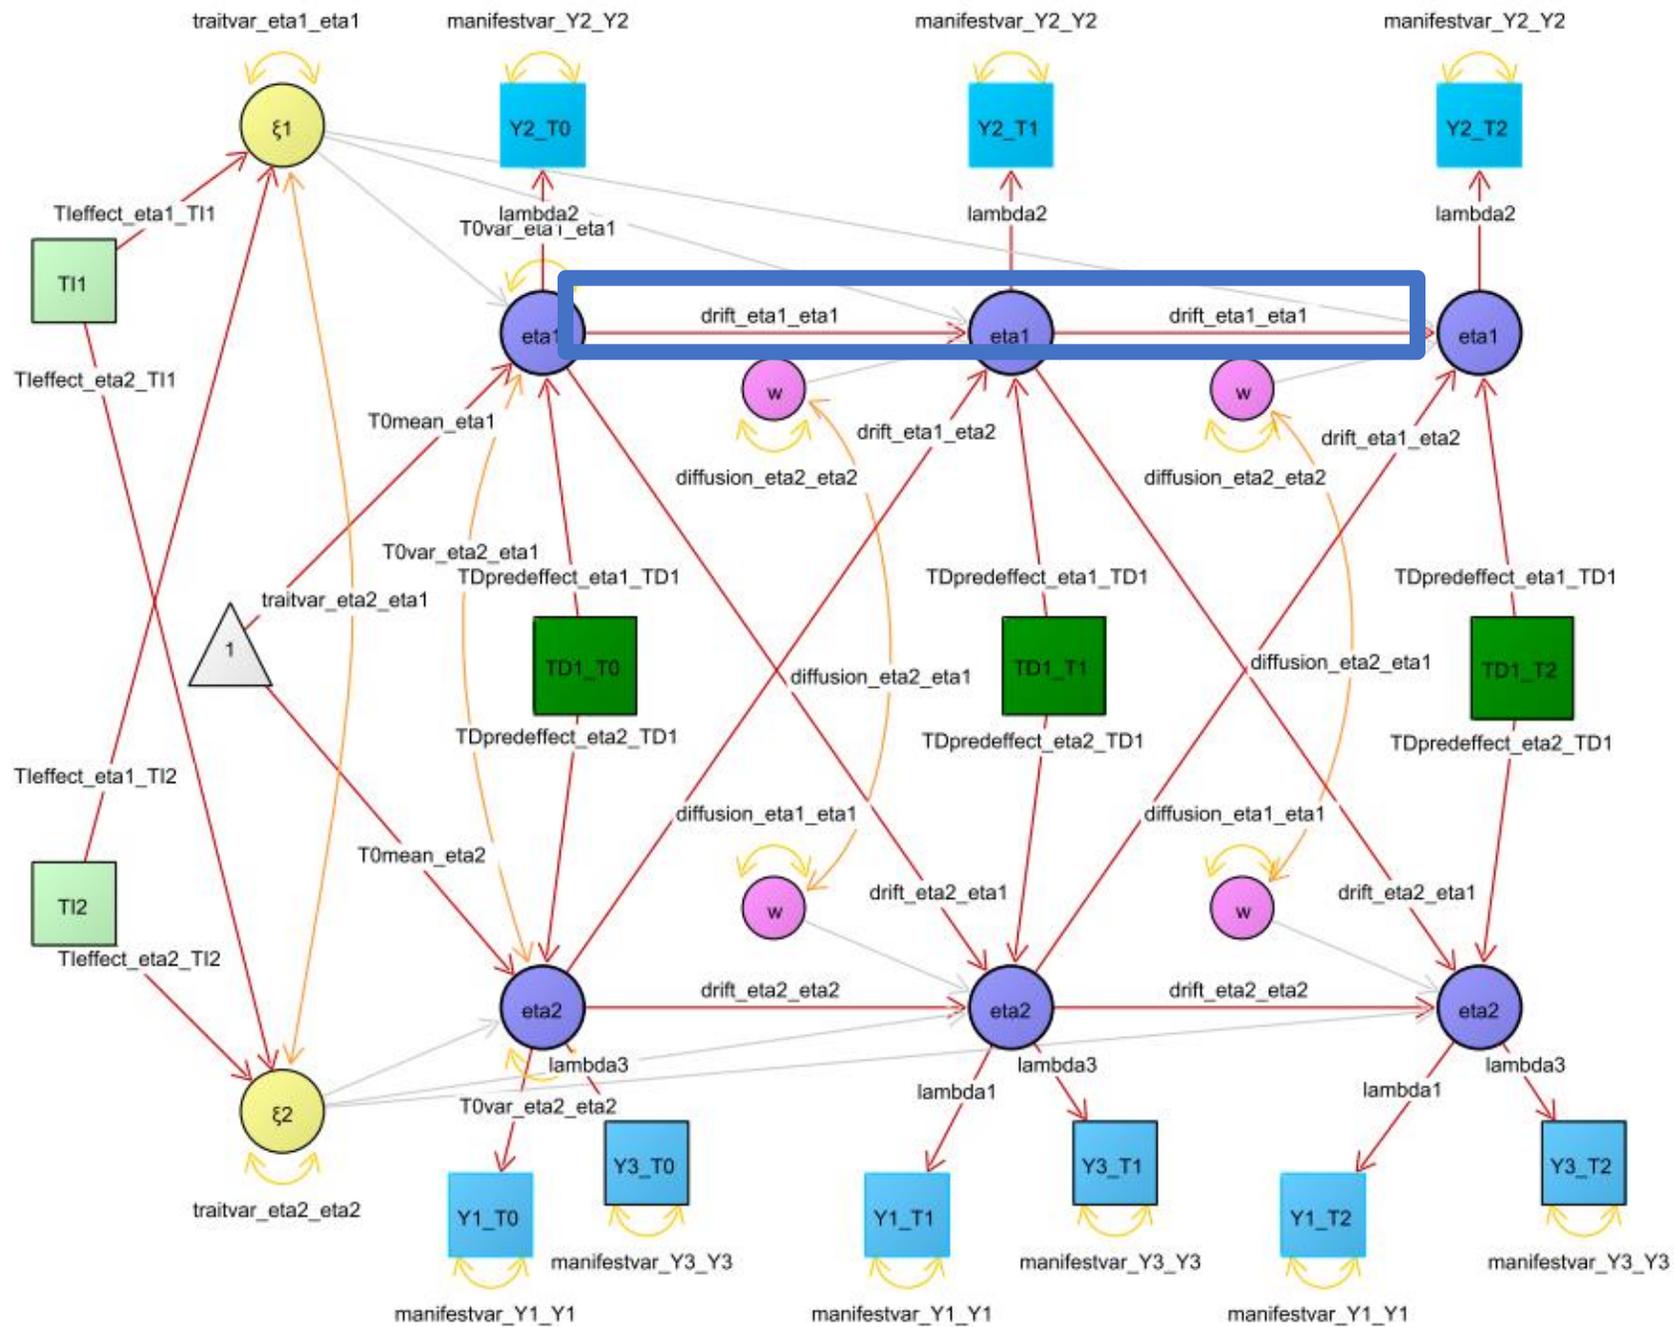
SL -> Bonheur

Bonheur -> SL



Variance manifeste  
aléatoire





# Modélisation à temps continu

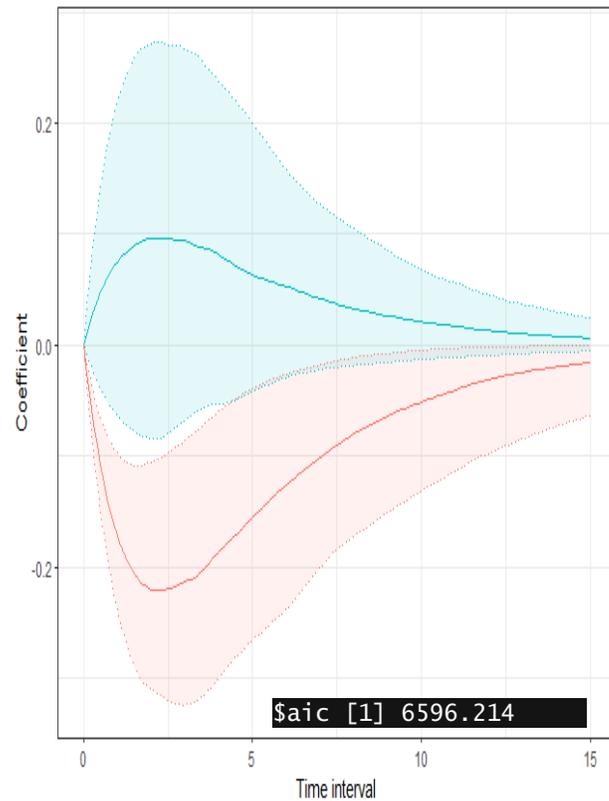
Paramètres aléatoires : Laisser libre les variations de certains paramètres à l'intérieur des clusters (individus)

Effets croisés et autoregressifs (DRIFT) :

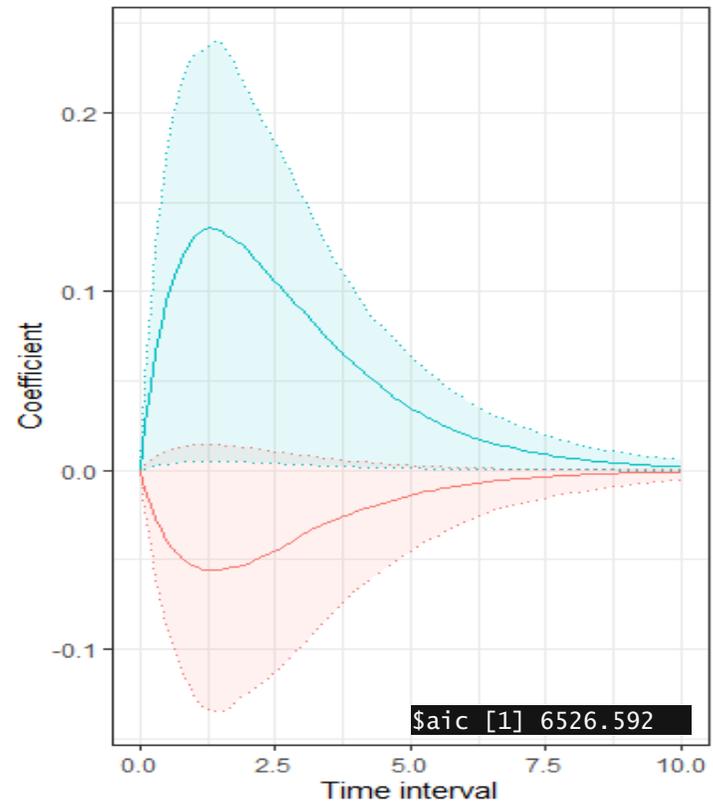
```
model1$pars$indvarying[ (model2$pars$matrix %in% c('DRIFT'))] <- TRUE
```

SL -> Bonheur

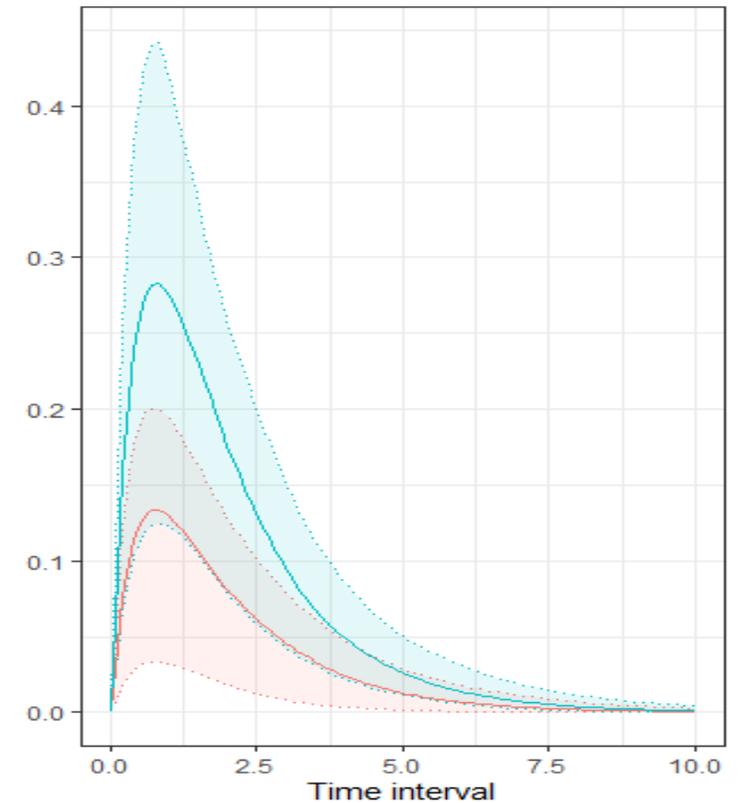
Bonheur -> SL



Variance manifeste  
aléatoire



Drift aléatoire



# Modélisation à temps continu

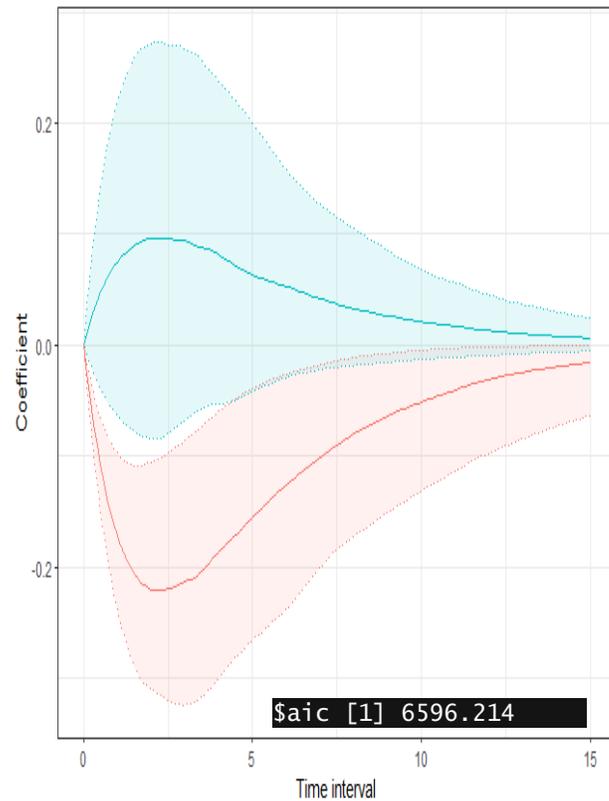
Paramètres aléatoires : Laisser libre les variations de certains paramètres à l'intérieur des clusters (individus)

Effets croisés et autoregressifs (DRIFT) :

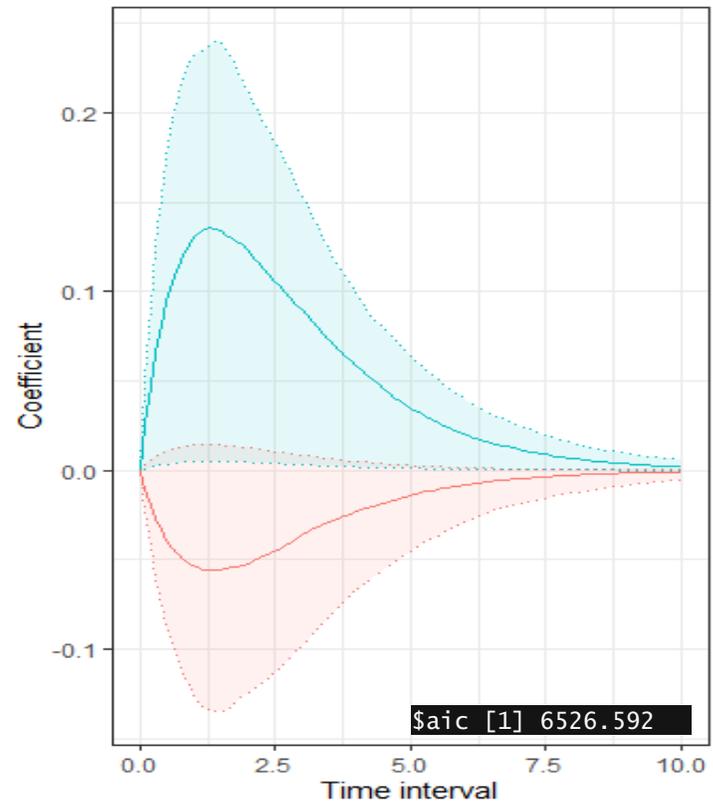
```
model1$pars$indvarying[ (model2$pars$matrix %in% c('DRIFT'))] <- TRUE
```

SL -> Bonheur

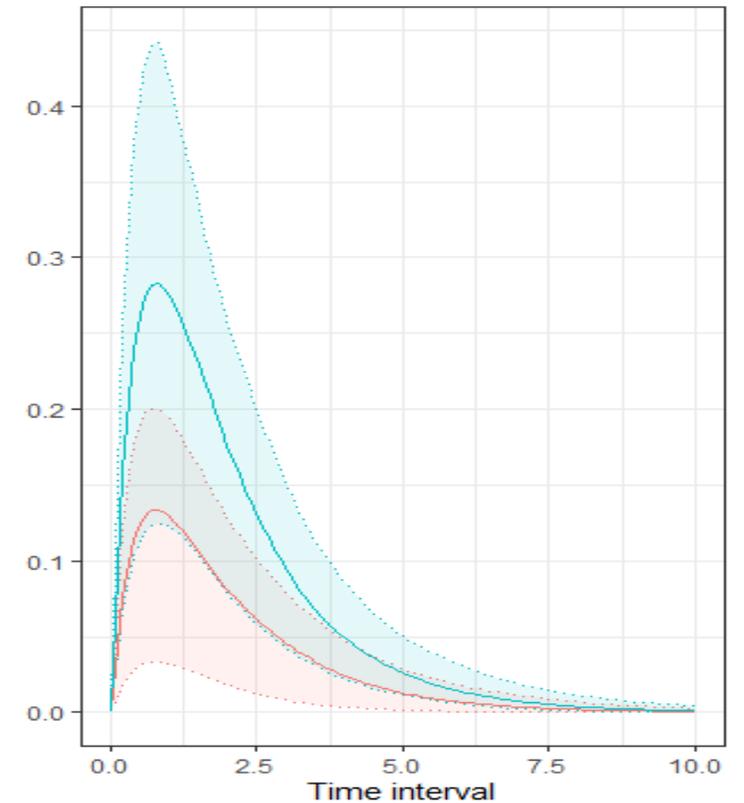
Bonheur -> SL



Variance manifeste  
aléatoire

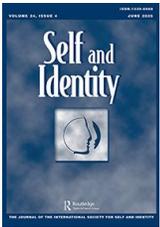


Drift aléatoire



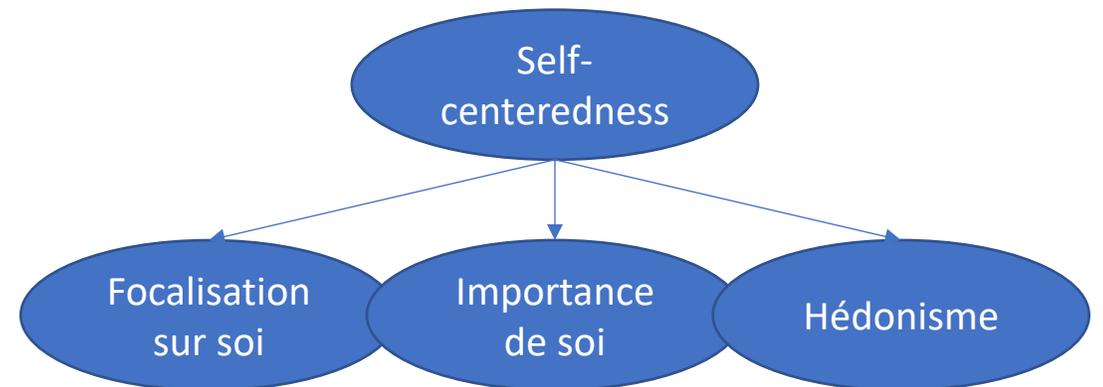
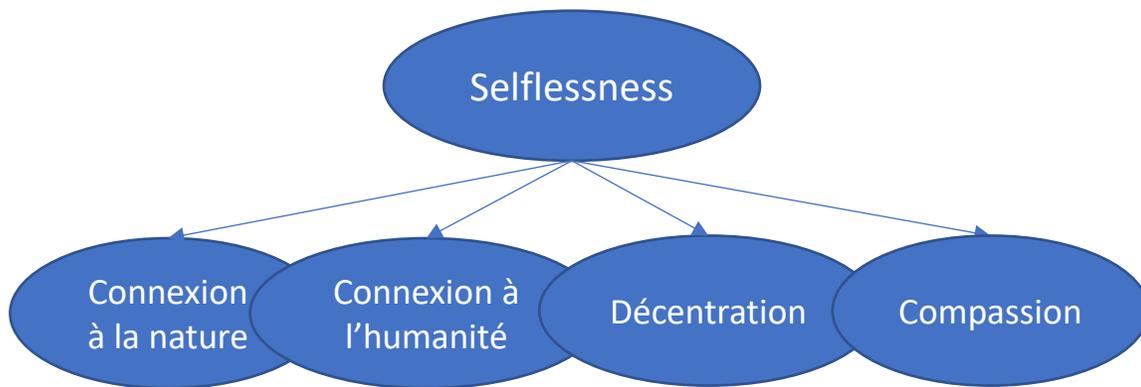
# Modélisation à temps continu (partie 2)

Thèse de Lucas David (sous la direction de Michaël Dambrun)



Development of the selflessness/self-centeredness Inventory – trait (SSI-T)

Lucas David, Nicolas Pellerin & Michaël Dambrun (2025)



# Modélisation à temps continu (partie 2)

## Etude ESM de Lucas Davis

- Cinq mesures par jour sur quatre jours (janvier 2025)
- Étudiants en psychologie ( $N = 168$ , 657 jours, 2573 observations)

### Analyse factorielle multi-niveaux

CFI = 0.95, TLI = 0.92, SRMR = 0.03, RMSEA = 0.06

Selflessness

Connection with humanity  
Connection with nature  
Compassion  
Decentering

Self-  
centeredness

Self-importance  
Hedonic process  
**Self-focus**

Bonheur

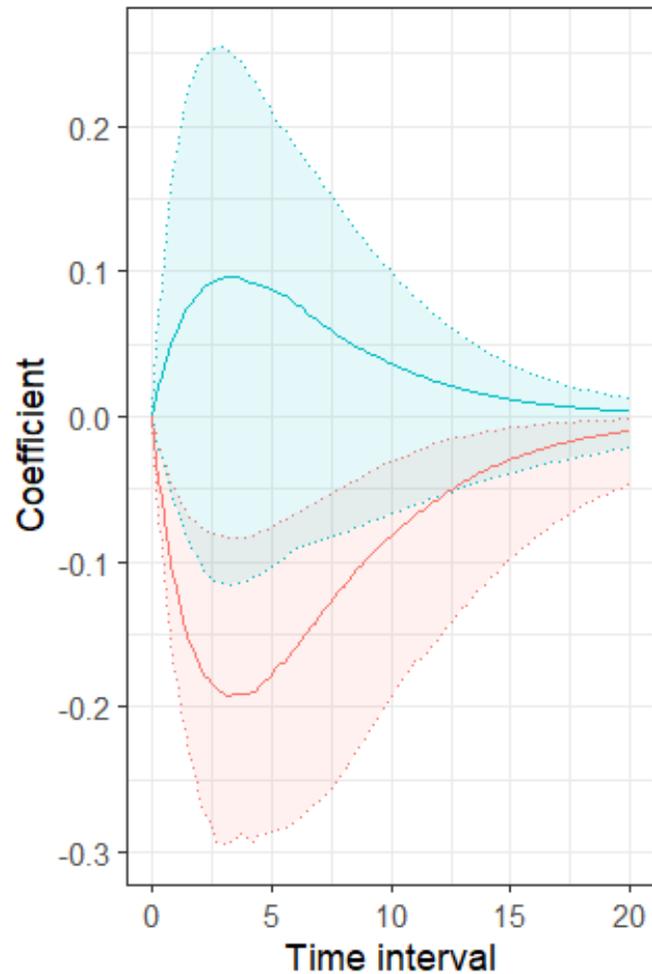
Bonheur  
Calme intérieur

Détresse

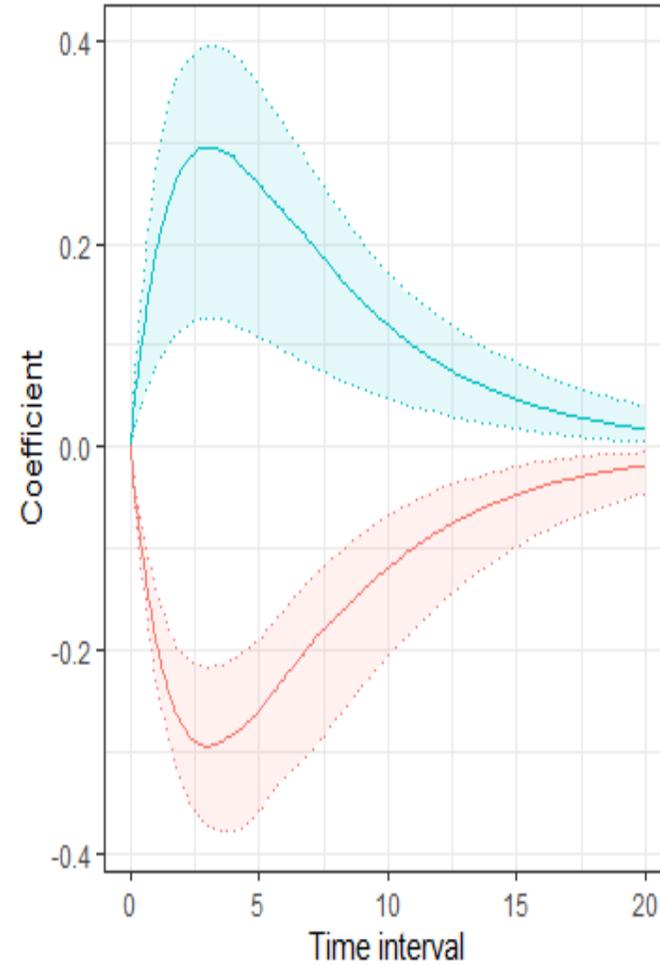
Stress  
Déprime

# Modélisation à temps continu (partie 2)

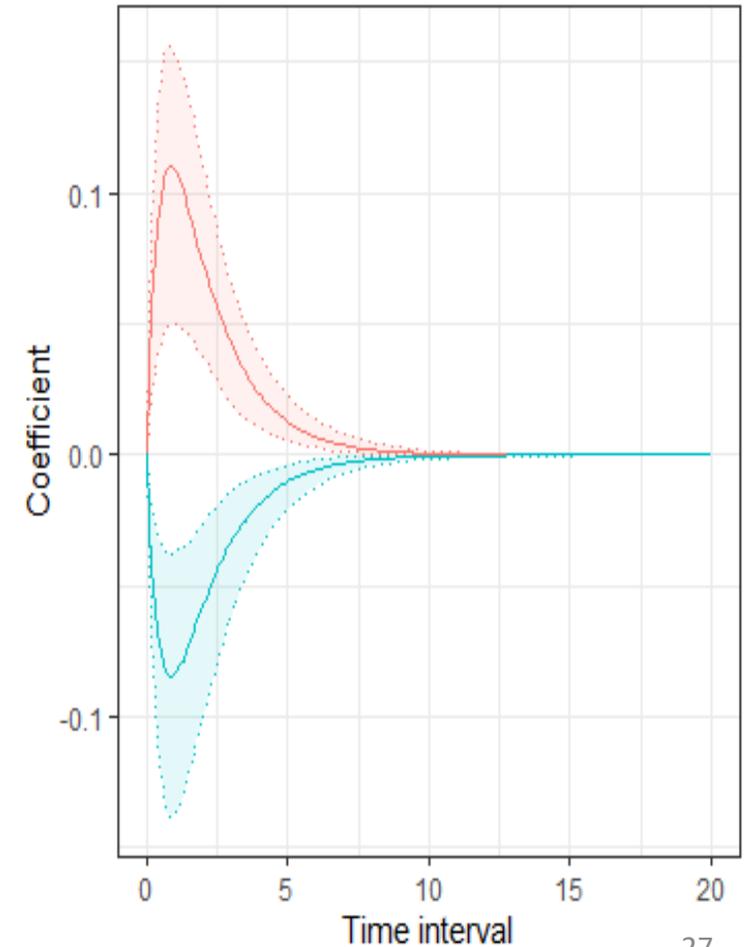
SL -> Bonheur  
Bonheur -> SL



Variable manifeste  
aléatoire

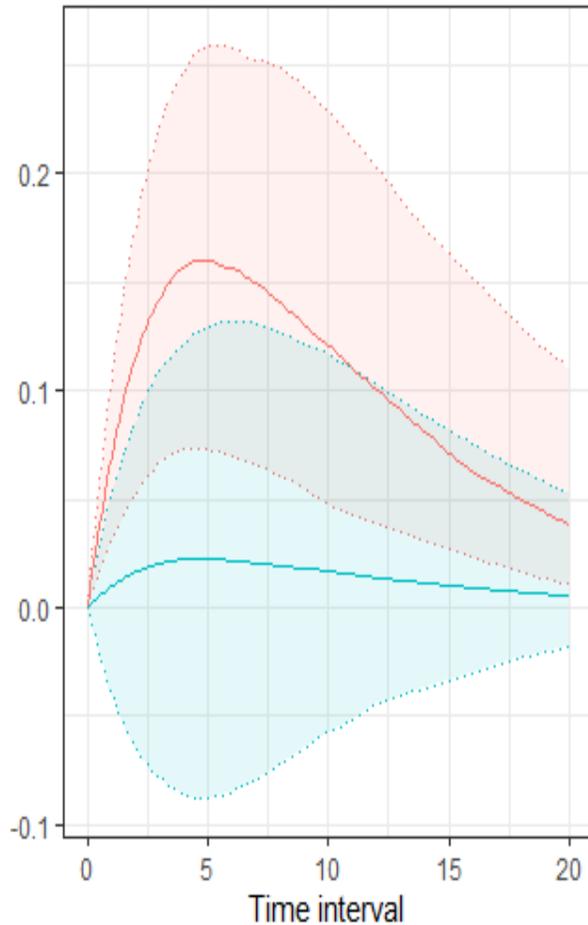


Drift aléatoire

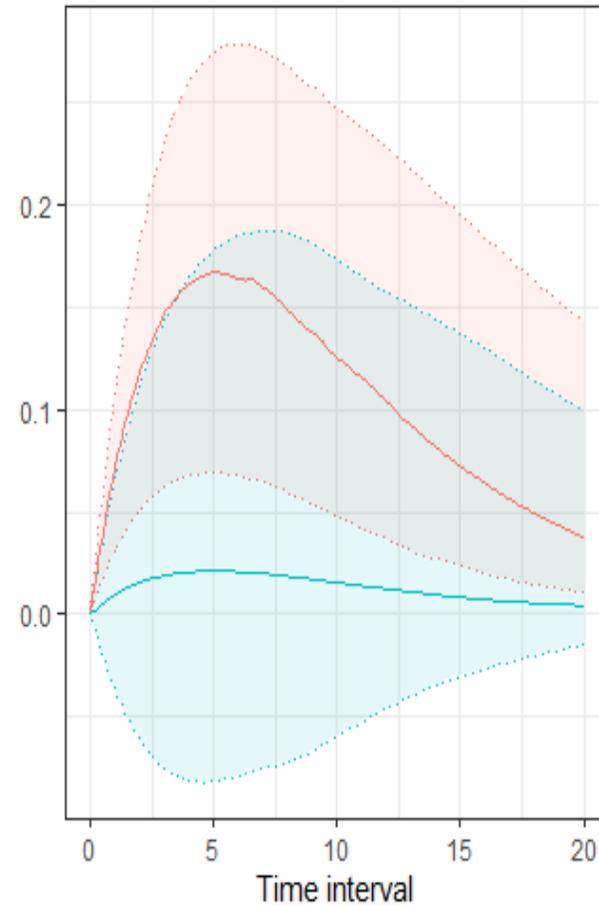


# Modélisation à temps continu (partie 2)

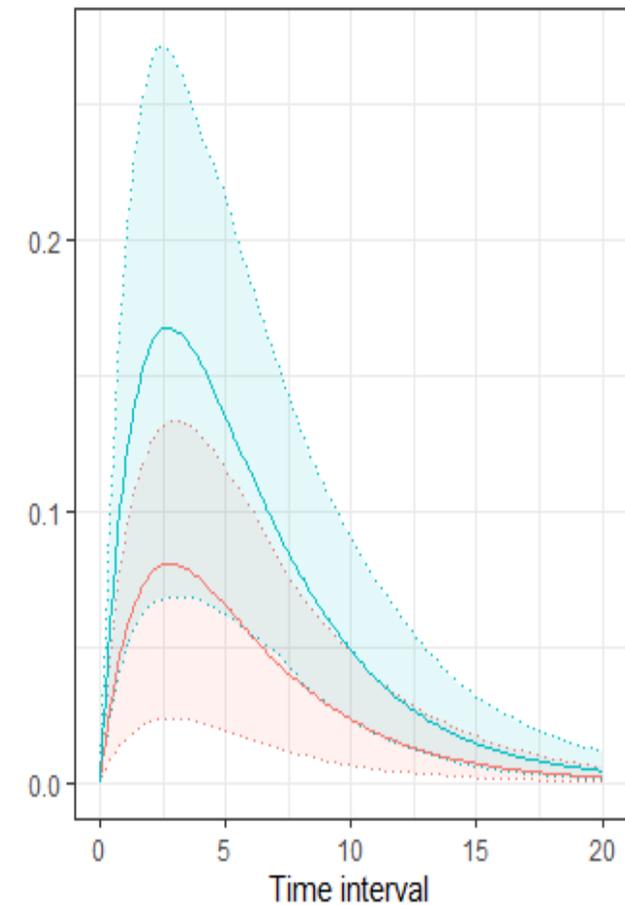
SL -> Détresse  
Détresse -> SL



Variable manifeste  
aléatoire



Drift aléatoire

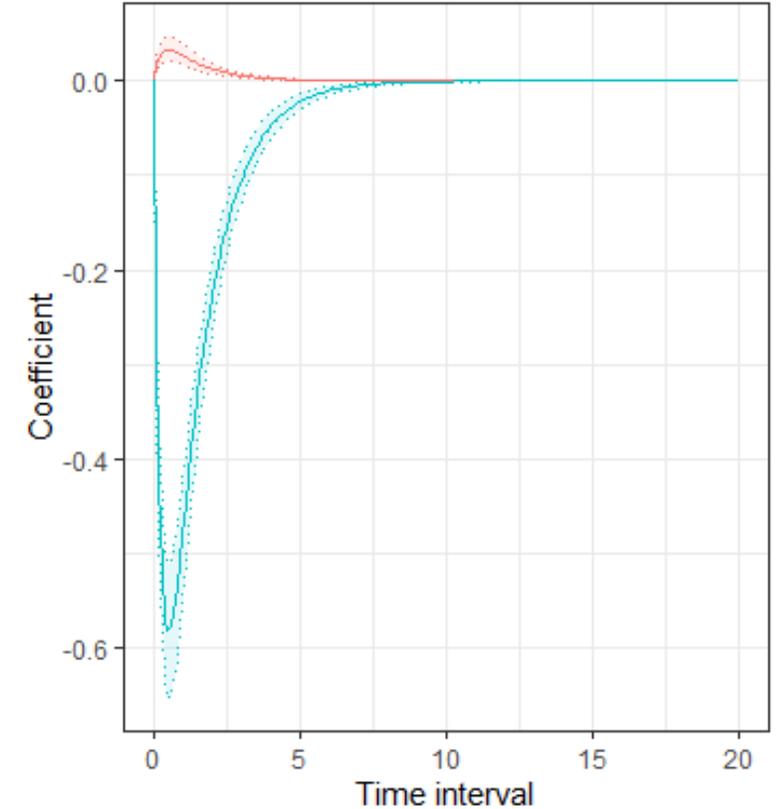
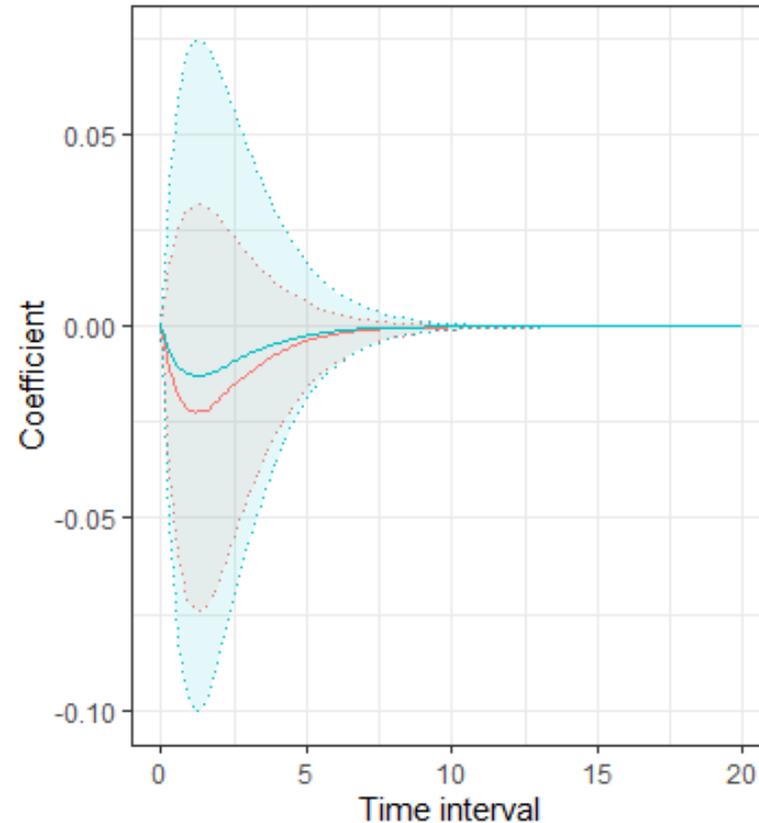
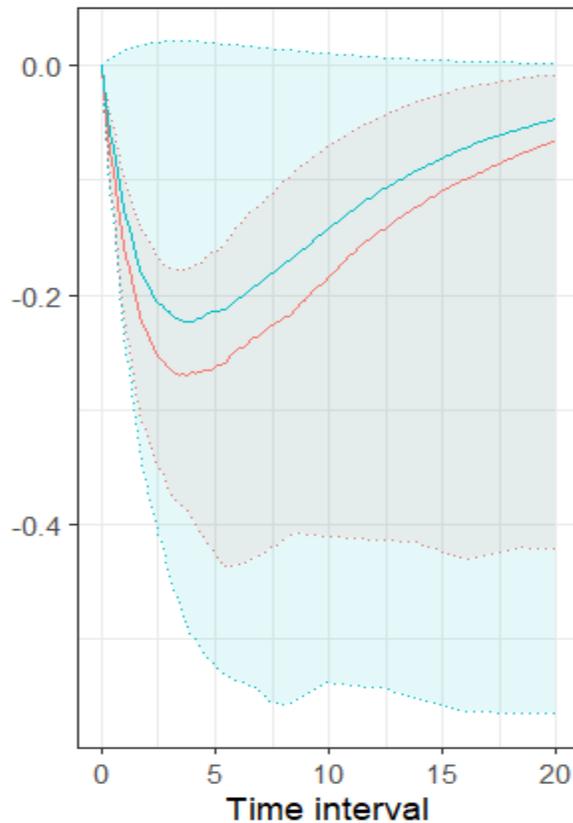


# Modélisation à temps continu (partie 2)

SC -> Bonheur  
Bonheur -> SC

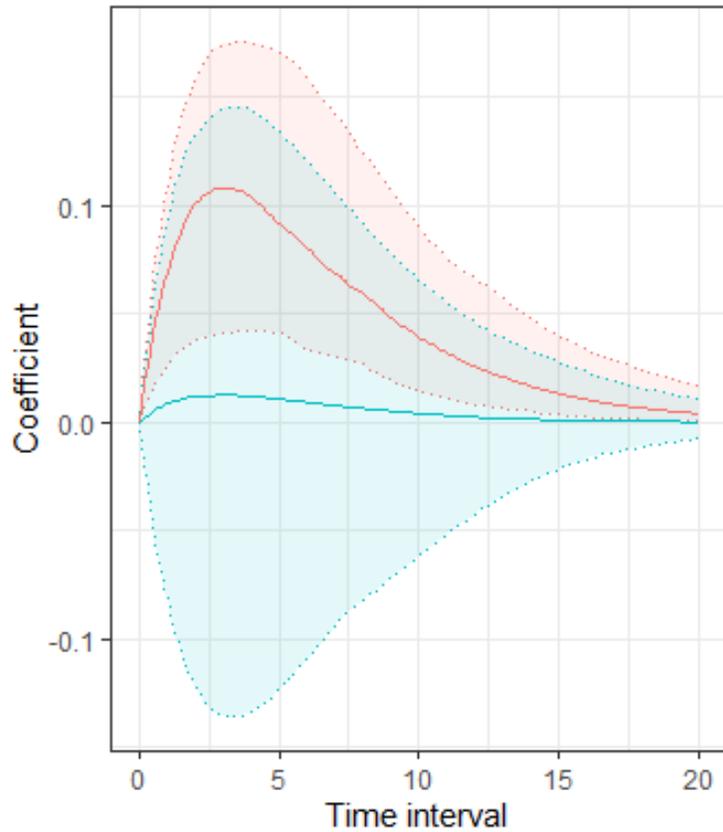
Variable manifeste  
aléatoire

Drift aléatoire

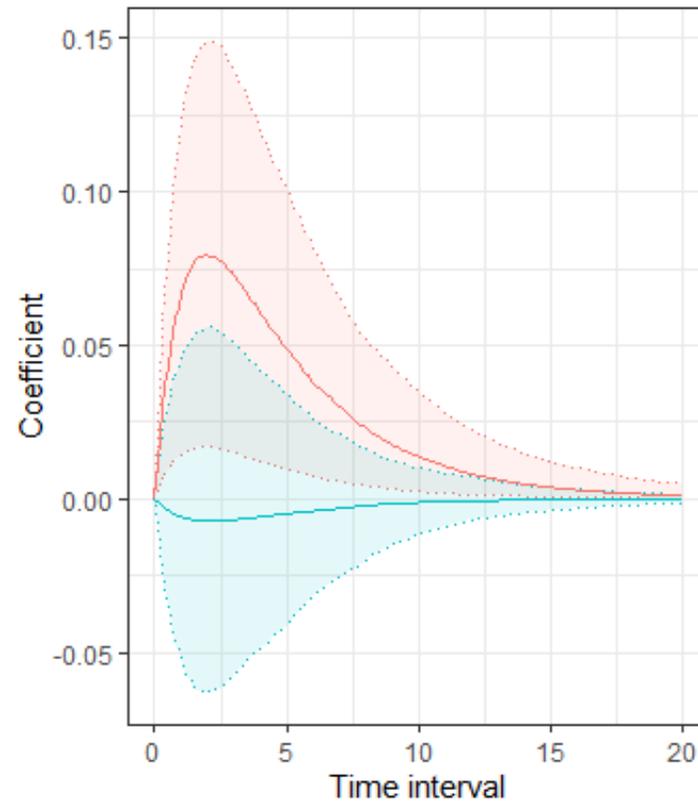


# Modélisation à temps continu (partie 2)

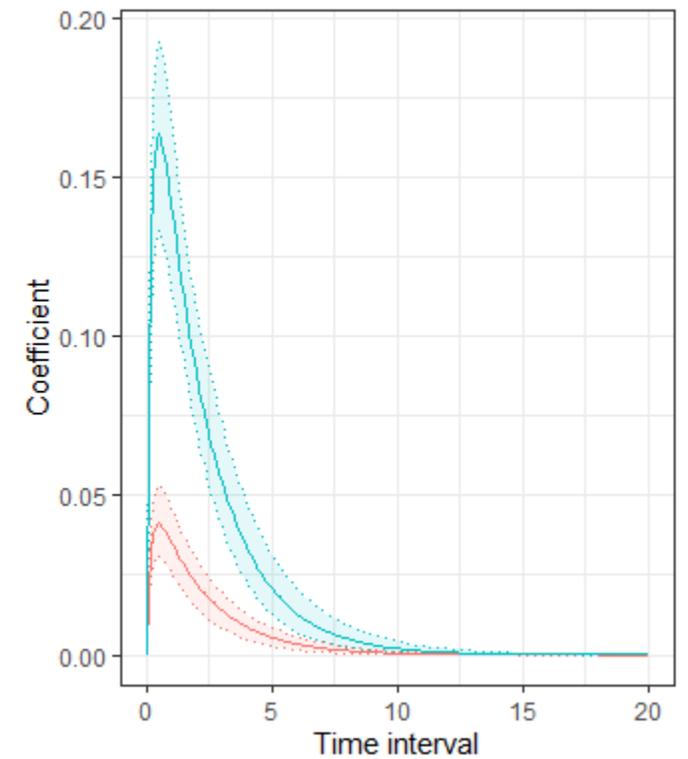
SC-> Détresse  
Détresse -> SC



Variable manifeste  
aléatoire



Drift aléatoire

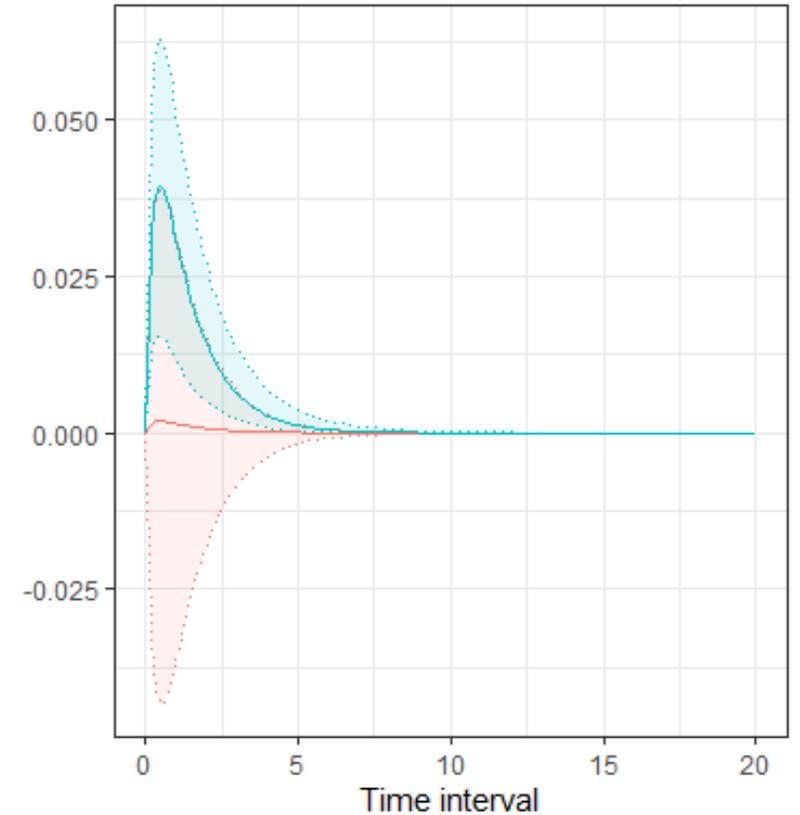
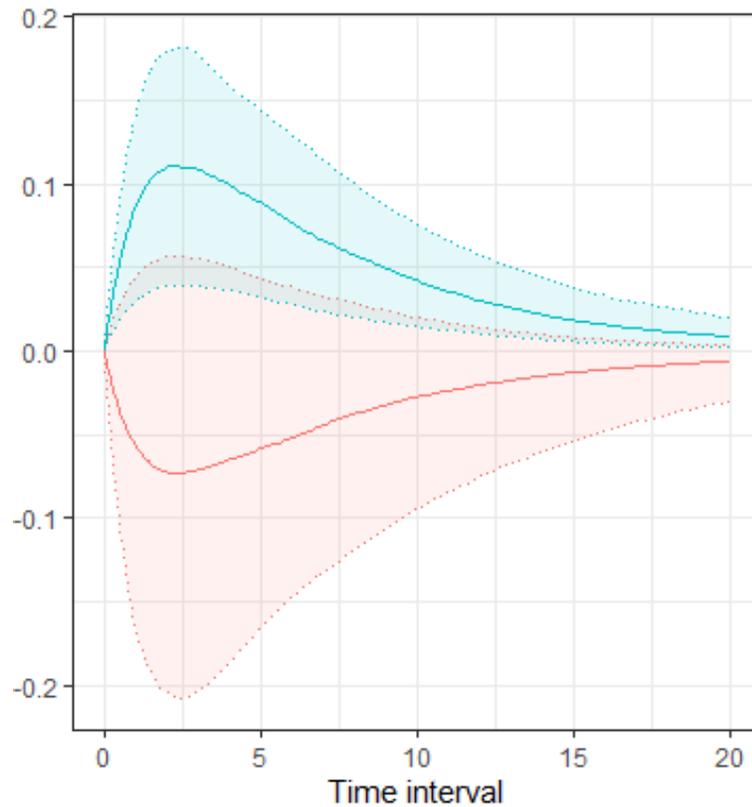
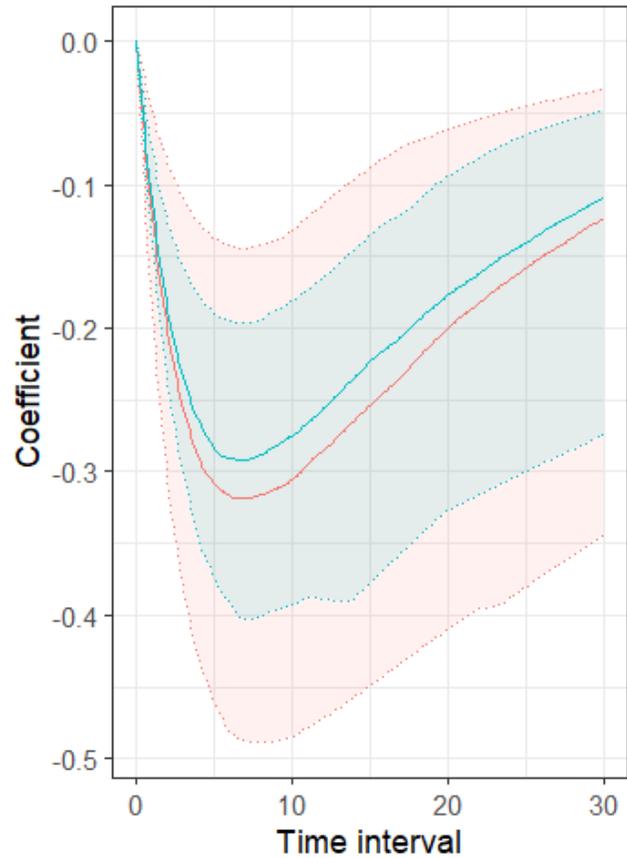


# Modélisation à temps continu (partie 2)

SL -> SC  
SC -> SL

Variable manifeste  
aléatoire

Drift aléatoire

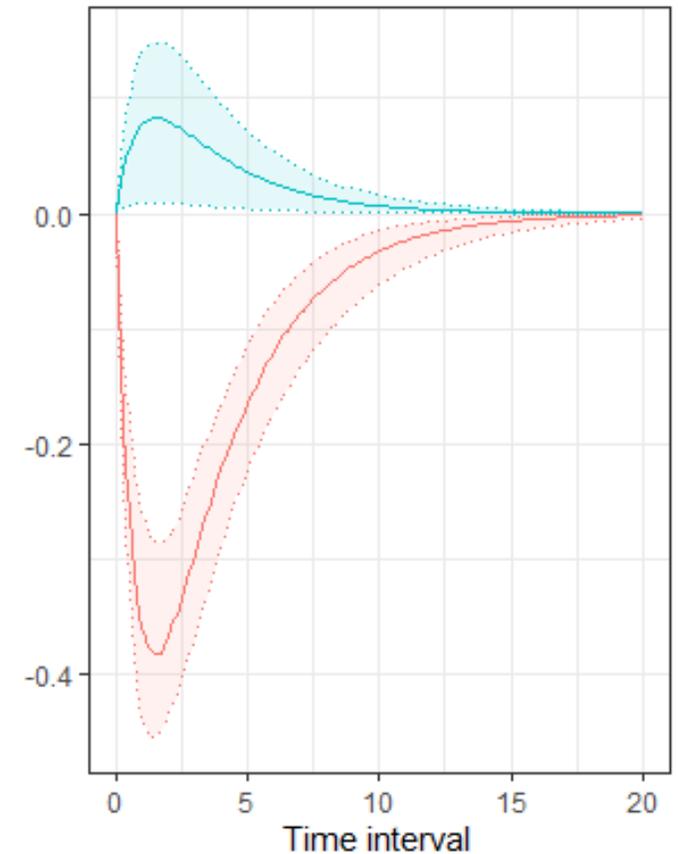
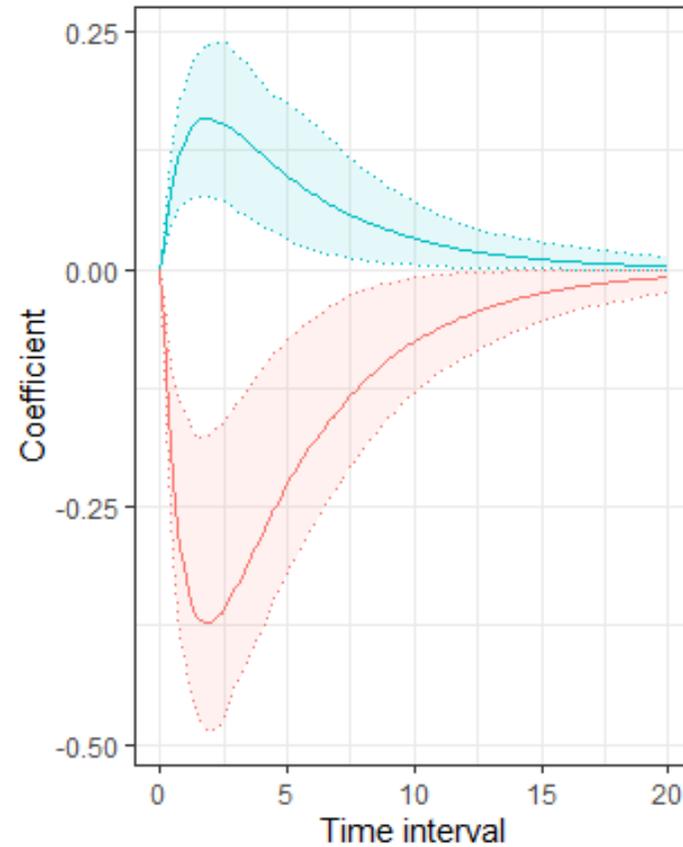
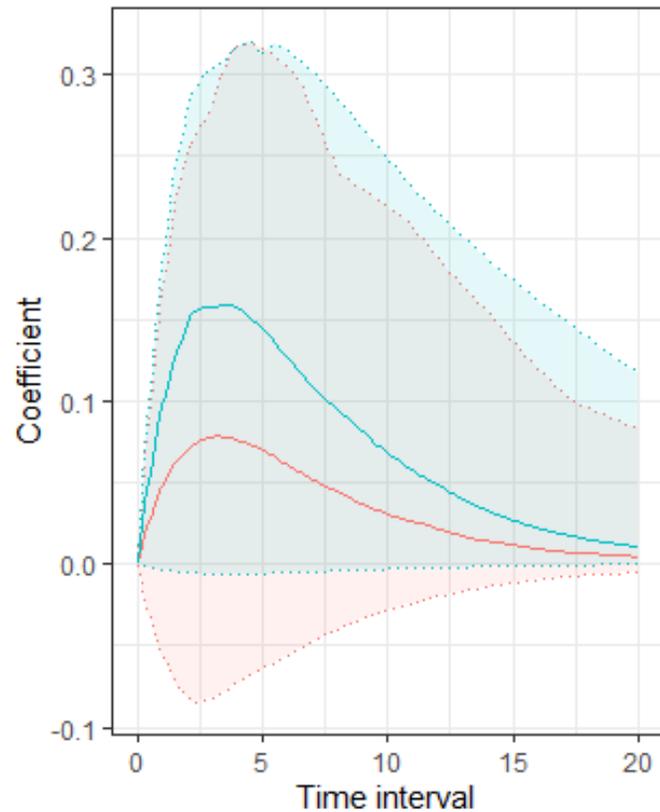


# Modélisation à temps continu (partie 2)

Bonheur -> Détresse  
Détresse -> Bonheur

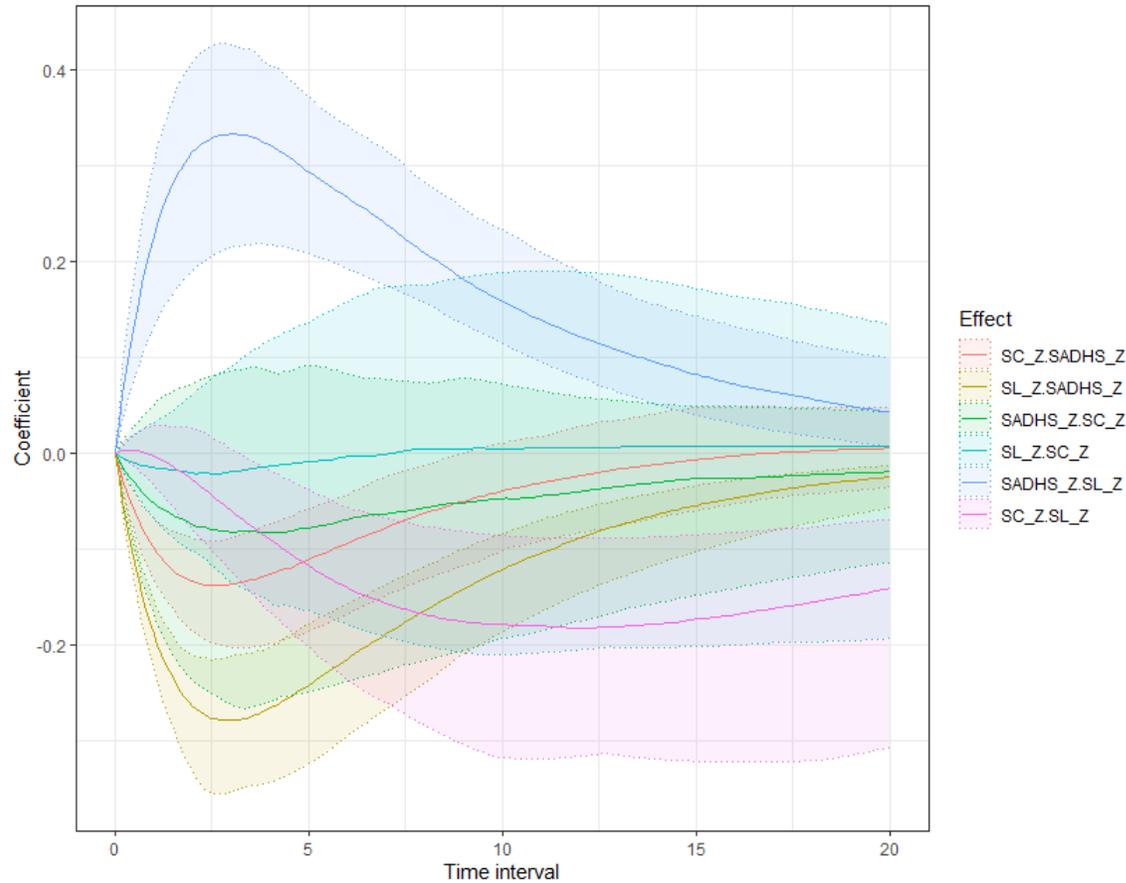
Variable manifeste  
aléatoire

Drift aléatoire

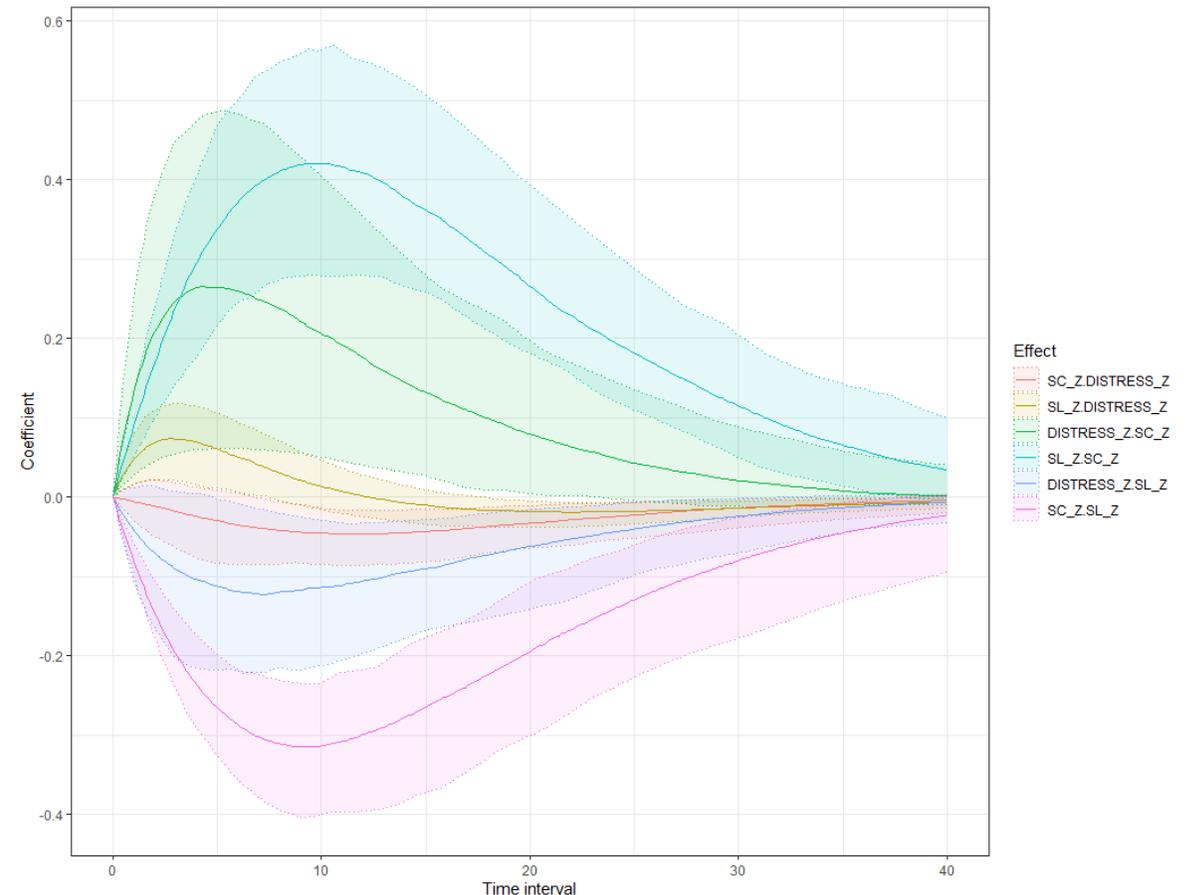


# Modélisation à temps continu (partie 2)

```
ctmodel <- ctModel(type='stanct', n.latent = 3, n.manifest = 3,  
  latentNames = c("SL_Z","SC_Z","SADHS_Z"),  
  manifestNames = c("SL_Z","SC_Z","SADHS_Z"),  
  LAMBDA = diag(3))
```



```
ctmodel <- ctModel(type='stanct', n.latent = 3, n.manifest = 3,  
  latentNames = c("SL_Z","SC_Z","DISTRESS_Z"),  
  manifestNames = c("SL_Z","SC_Z","DISTRESS_Z"),  
  LAMBDA = diag(3))
```



# Conclusion

- Les résultats temporels vont globalement dans le sens du modèle
  - Une augmentation de SL prédit une augmentation de bonheur
  - Le SC prédit la détresse
  - SL et SC sont reliés négativement
- L'intervalle de temps optimal se situe entre 1h30 et 2h30.
  - Quelles implications ?
- Réflexions autour de la façon du paramétrage des modèles

# Merci de votre attention !

