

Analyse de données bio-médicales

Recherche reproductible et modélisation mathématique

Li-Thiao-Té Sébastien

LAGA UMR 7539, Université Paris 13

Habilitation à diriger des recherches
soutenue le 23 novembre 2021



Plan

Curriculum Vitae

Recherche reproductible

Modélisation et analyse de données

Estimation paramétrique avec données manquantes

Vitesse de propagation d'après une endoscopie



Parcours scientifique

- 2005-2009 : Doctorat en Mathématiques Appliquées, ENS Cachan et Institut Pasteur.
Caractérisation et Détection de Signaux Protéiques en Spectrométrie de Masse
- 2009-2010 : Post-doctorat dans l'Équipe Statistique et Génome, UMR 518 AgroParisTech/INRA
Estimation du nombre d'espèces en métagénomique
- 2010- : Maître de conférences en mathématiques appliquées, LAGA UMR 7539, Université Paris 13



Parcours scientifique

2010- : Maître de conférences en mathématiques appliquées, LAGA UMR 7539, Université Paris 13

- 2014-2018 : traitement d'images biomédicales avec F Dibos, M Luong, JM Rocchisani, DV Tran (doctorant)
- 2014-2018 : programme interdisciplinaire Imageries du Vivant (Pres SPC, Universités P5, P7 et P13)
- 2014- traitement du signal en spectroscopie RPE avec Y Frapart, DN Tran (doctorant)
- 2018- traitement d'images et modèles EDP pour les maladies inflammatoires intestinales avec H Zaag, J Chaussard, X Treton, E Ogier-Denis, S Al Ali (doctorante)



Problématiques rencontrées

- travail collaboratif et dialogue interdisciplinaire
- pour les applications, difficulté de s'approprier les méthodes et logiciels mathématiques
- pour les mathématiques, difficulté de valider les hypothèses de modélisation et les résultats de l'analyse de données



Plan

Curriculum Vitae

Recherche reproductible

Modélisation et analyse de données

Estimation paramétrique avec données manquantes

Vitesse de propagation d'après une endoscopie



Qu'est-ce que la reproductibilité ?



Obstacles à la reproductibilité numérique

- le générateur de nombres aléatoires
- l'environnement logiciel
- l'opérateur



Contrôler l'environnement logiciel

- Environnement = versions des librairies, logiciels, compilateurs, etc.
- variable et évolutif
- il faut le contrôler :
 - décrire : approches de type provenance, guix
 - fournir : machines virtuelles, container, packages snap/flatpak



Contrôler l'opérateur

L'opérateur doit :

- écrire ce qu'il fait sans erreur/oubli
=> remplacer l'opérateur par un "robot" programmable
- décrire ce qu'il fait pour qu'on le comprenne
=> documentation du programme avant le code source



Logiciel Lepton : format et documentation

```
Documentation
<<chunk_name options>>=
source code
@
```

Documentation

Code chunk 1 : «chunk_name»

```
source code
```



Logiciel Lepton : opérations

quatre opérations de base :

- `-write` permet d'écrire sur le disque
- `-exec interpreter` permet d'exécuter le code
- `-chunk format -output format` contrôle le format de sortie
- `<<chunk_ref>>` permet de réutiliser un autre bloc



Logiciel Lepton : python

Fonction $x \mapsto x^2$ en Python :

Code chunk 2 : «python»

```
[i**2 for i in range(0,3)]
```

Interpret with python3

```
[0, 1, 4]
```



Logiciel Lepton : Ocaml

Fonction $x \mapsto x^2$ en Ocaml :

Code chunk 3 : «ocaml»

```
let f = fun x -> x*x in  
List.map f [0;1;2];;
```

Interpret with ocaml

```
- : int list = [0; 1; 4]
```



Logiciel Lepton : C/shell

Code chunk 4 : «main.c»

```
#include <stdio.h>
int main() {
    printf("Hello world.\n");
}
```

Code chunk 5 : «shell»

```
gcc main.c
./a.out
```

Interpret with shell

```
Hello world.
```



Logiciel Lepton : état actuel

Code source libre publié sur Github :
<https://github.com/slithiaote/lepton>

Publication associée :

Lepton : An automaton for Literate Executable Papers, 2019,
Journal of Open Source Software, <https://doi.org/10.21105>

Mais : Écrire un document compréhensible est difficile. Il faut
du travail et de la méthode.



Next steps

Architecture d'un projet de recherche

- Assets
- Source code
- Scripts
- Artefacts
- Reports

Mise en place progressive dans mes projets de recherche.



Next steps

Propriétés supplémentaires :

- modularité : découper les projets en petits morceaux
- utilisation explicite des différents éléments
- incrémentalité : garder en mémoire les calculs
- intégration continue : tests exhaustifs
- exécution distante : garantie d'universalité



Plan

Curriculum Vitae

Recherche reproductible

Modélisation et analyse de données

Estimation paramétrique avec données manquantes

Vitesse de propagation d'après une endoscopie



Analyse de données

Pour apporter une "preuve mathématique", il faut savoir :

- Que sont les données ? que sont les modèles ?
- Que sont les énoncés scientifiques ?
- Où est contenue l'information ?

À cause des problèmes de reproductibilité (bruit), on ne peut pas utiliser simplement la théorie de la démonstration.



Analyse de données : définitions

- \mathcal{E} = ensemble des données
- L'information est portée par l'observation de certains éléments de \mathcal{E} , par opposition aux autres éléments.
- \mathcal{M} = ensemble des modèles
- L'information est portée par les modèles compatibles, par opposition aux autres modèles possibles.

\mathcal{M} et \mathcal{E} sont reliés par : un modèle d'observation, une distance, une similarité, etc.



Analyse de données : reconnaissance faciale

- \mathcal{M} = ensemble de noms
- noms compatibles avec l'image, par opposition aux autres noms possibles.
- \mathcal{E} = ensemble des images
- observation d'une certaine image, par opposition aux autres images possibles.

MONA \mapsto



Problème direct et problème inverse

- Problème direct : le vrai modèle $m \in \mathcal{M}$ est connu.
Par exemple générer des observations sous m .

MONA \mapsto 

- Problème inverse : les observations $e \in \mathcal{E}$ sont connues.
On souhaite trouver le(s) modèle(s) correspondant(s),
c'est-à-dire l'image réciproque de e dans \mathcal{M} par
l'opération du modèle d'observation.

MONA, LISA, ADELE \leftarrow 

Attention : dans beaucoup d'applications, l'espace \mathcal{M} , ainsi que le modèle d'observation sont inconnus et choisis arbitrairement.



Hypothèse de modélisation

C'est le choix de \mathcal{E} ou de \mathcal{M} , ou de la relation entre \mathcal{E} et \mathcal{M} .
=> choix d'un sous-ensemble d'objets partageant des propriétés communes.

Cas particulier des propriétés imposées par l'observateur :

- elles sont justifiables
- invariance par groupes de transformation
e.g. dans le cas des images : isométries, groupe projectif
- schéma d'expérience, échantillonnage



Hypothèse de modélisation

Certains choix conduisent à des problèmes triviaux.

Proposition

- on observe une loi empirique $d\mathbb{P}_Y \in \mathcal{E}$,
- \mathcal{M} est l'ensemble des variables aléatoires à valeurs dans \mathcal{Y}
- similarité définie par l'espérance $\mathbb{E}[d(M, Y)]$

Alors

$$\mathbb{E}[d(M, Y)] \geq \inf_{m \in \mathcal{Y}} \int d(m, y) d\mathbb{P}_Y$$

En particulier, la masse de Dirac en m_0 est le modèle d'espérance minimale donc de similarité maximale.

Démonstration : Conséquence de l'indépendance entre modèles et observations



Énoncé scientifique

C'est un sous-ensemble $\mathcal{S} \subset \mathcal{E}$ ou $\mathcal{S} \subset \mathcal{M}$:

- point \rightarrow estimation paramétrique,
- un ensemble / fonction indicatrice \rightarrow test statistique,
- une partition de \mathcal{E} ou de $\mathcal{M} \rightarrow$ classification.

Un énoncé inconnu peut être appris par un algorithme de machine learning.

Un énoncé connu peut être démontré par accumulation

- d'observations $e \in \mathcal{S}$
- ou de modèles $m \in \mathcal{S}'$



Preuves mathématiques

Le processus d'accumulation aboutit à un ensemble de modèles compatibles ou à un paysage dans l'ensemble des modèles.

On montre que

- l'ensemble des modèles compatibles est calculable,
- il fournit une analyse complète,
- on peut en déduire des énoncés intéressants.



Plan

Curriculum Vitae

Recherche reproductible

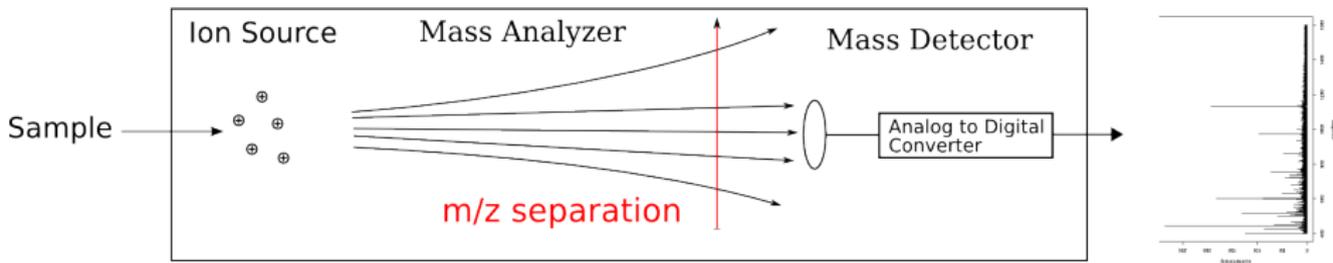
Modélisation et analyse de données

Estimation paramétrique avec données manquantes

Vitesse de propagation d'après une endoscopie



Exemple inspiré d'un spectromètre de masse



Exemple inspiré d'un spectromètre de masse

On considère le modèle

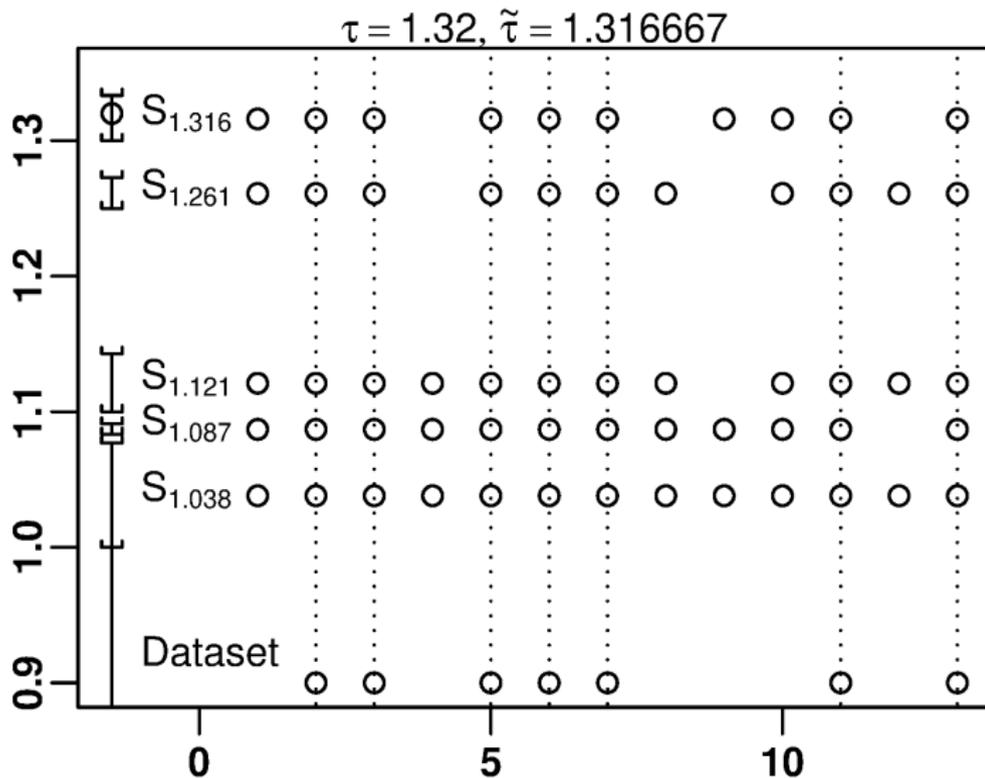
$$Y = \lfloor \tau X \rfloor$$

où le signal observé Y est obtenu à partir d'un nombre d'ions X après amplification d'un facteur de gain τ et troncature.

- Espace des données $\mathcal{E} =$ sous-ensembles de \mathbb{N}
- Espace des modèles $\mathcal{M} = \{\tau \in \mathbb{R}\}$
 \Leftrightarrow sous-ensemble généré $\mathcal{S}_\tau = \lfloor \tau \mathbb{N} \rfloor \subset \mathbb{N}$
- Un modèle τ est compatible si l'observation $Y \subset \mathcal{S}_\tau$
i.e. aucune contradiction dans les observations.



Modèles compatibles avec les données



Résultats

L'ensemble des modèles compatibles est calculable explicitement :

- c'est une union d'intervalles
- majorée par $\frac{\max Y+1}{n}$ où n est le nombre d'entiers distincts observés
- la largeur des intervalles est minorée par $\frac{1}{(\max Y)^2}$

On peut retrouver tous les intervalles par échantillonnage.



Résultats

L'ensemble des modèles compatibles fournit un estimateur précis pour τ :

- tous les modèles sont acceptables
- les grandes valeurs de τ sont cohérentes avec un faible nombre de données manquantes
- on prend $\hat{\tau}$ la plus grande valeur compatible
- on échantillonne en descendant à partir du majorant
- mieux : on prend $\hat{\tau} = \frac{a+b}{2}$ où $[a, b[$ est le dernier intervalle de l'ensemble des valeurs compatibles



Énoncés scientifiques

Un énoncé est une partie de \mathcal{E} ou de \mathcal{M} :

- "est-ce que l'on observe uniquement des nombres entiers?" i.e. τ multiple de 2
- "est-ce que τ est égal à 3.14?"
- "est-ce que τ appartient à un l'intervalle $[1, 2]$?"

On démontre par accumulation

- on a plusieurs observations et toutes vérifient l'énoncé
- tous les modèles compatibles vérifient l'énoncé



Plan

Curriculum Vitae

Recherche reproductible

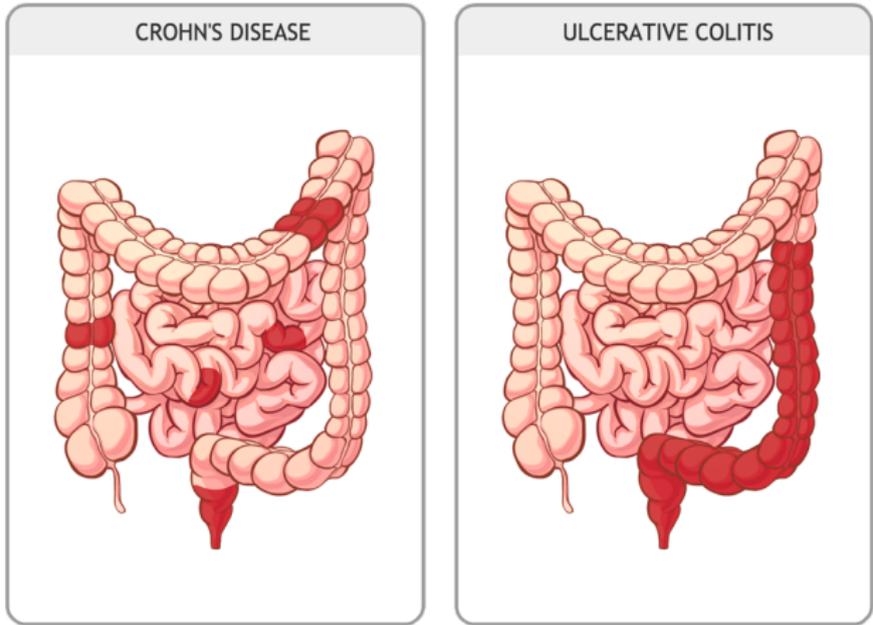
Modélisation et analyse de données

Estimation paramétrique avec données manquantes

Vitesse de propagation d'après une endoscopie



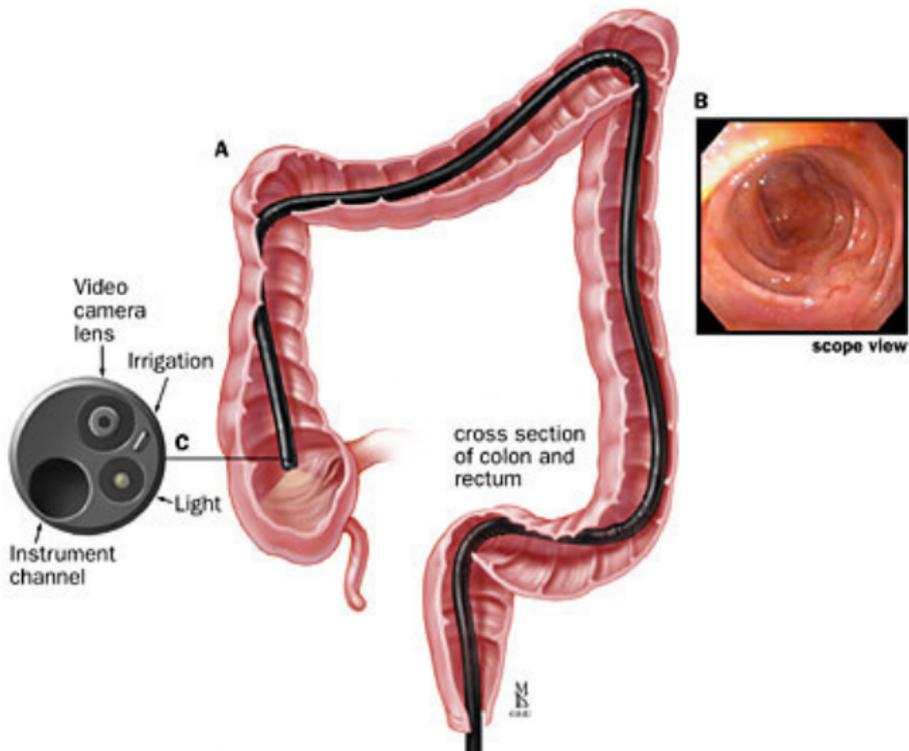
Maladies inflammatoires chroniques de l'intestin




- Collaboration avec H Zaag, J Chaussard, X Treton, E Ogier-Denis
- Encadrement de la thèse de Safaa Al Ali
- Analyse d'image
- Modélisation par EDP



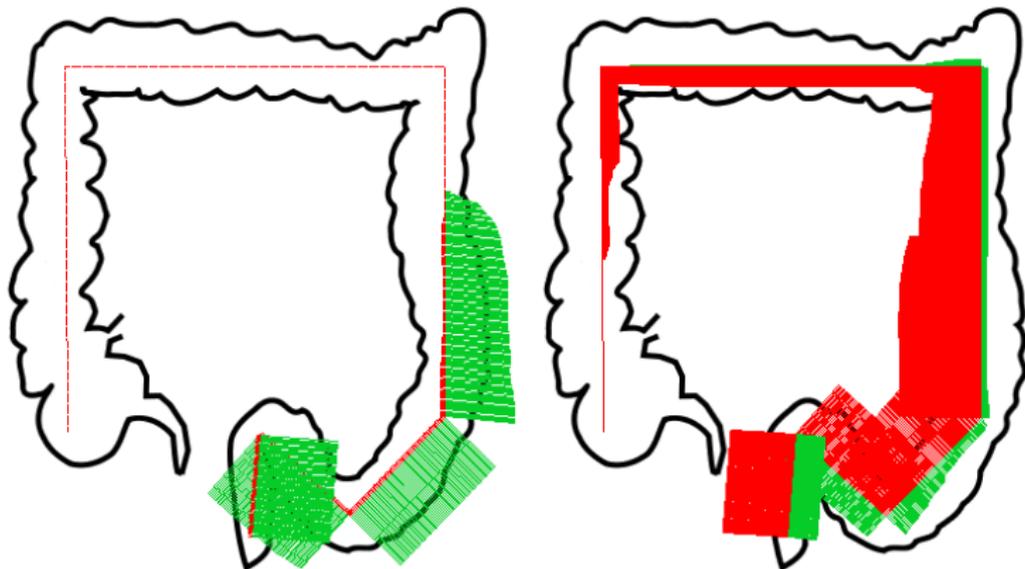
Vidéos de coloscopie



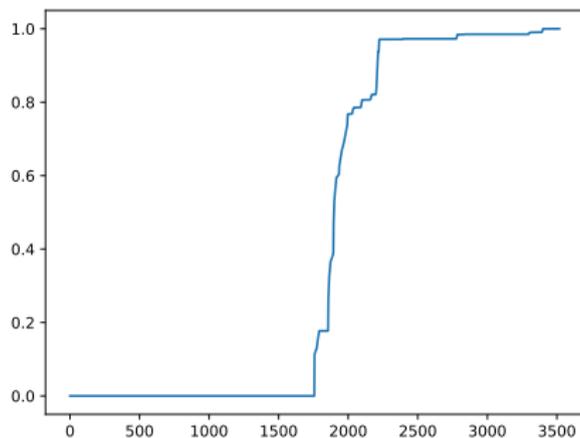
Lésions de la paroi intestinale



Profil des lésions



Distribution spatiale des lésions



- une observation est un profil $p(s) : [0, 1] \rightarrow \mathbb{R}$ (un patient)
- un modèle est une fonction $u(s) : [0, 1] \rightarrow \mathbb{R}$
- hypothèse 1 : distance L_2 entre \mathcal{E} et \mathcal{M}
- hypothèse 2 : \mathcal{M} est restreint à l'ensemble des solutions d'une équation de réaction-diffusion (FKPP)



Équation de FKPP

$$\frac{\partial}{\partial t} u - D \frac{\partial^2}{\partial s^2} u = u(1 - u), \quad t \geq 0, s \in \mathbb{R}$$

L'espace \mathcal{M} est paramétré par les couples (D, u_0) où D est le paramètre de diffusion et u_0 la condition initiale.



Résultats

L'espace des modèles est réduit à une dimension.

- les patients sont observés en régime asymptotique
- Pour $D = 1$, le profil de la solution de FKPP converge vers un front d'onde W_c de vitesse 2, indépendant de u_0 .
- Les autres fronts s'obtiennent à partir de W_c par dilatation

Conclusion : $\mathcal{M} = \left\{ \sqrt{D}.W_c \quad \text{pour} \quad D \in \mathbb{R}^+ \right\}$



Résultats

On obtient l'ensemble des modèles compatibles par recalage.

- recalage à translation et dilatation près
- on échantillonne les modèles, i.e. les valeurs de D
- le meilleur modèle $D^* = \arg \min L_2(D, \text{patient})$
- les modèles compatibles
 $\{D \text{ t.q. } L_2(D, \text{patient}) < 1.05 L_2(D^*, \text{patient})\}$



Résultats

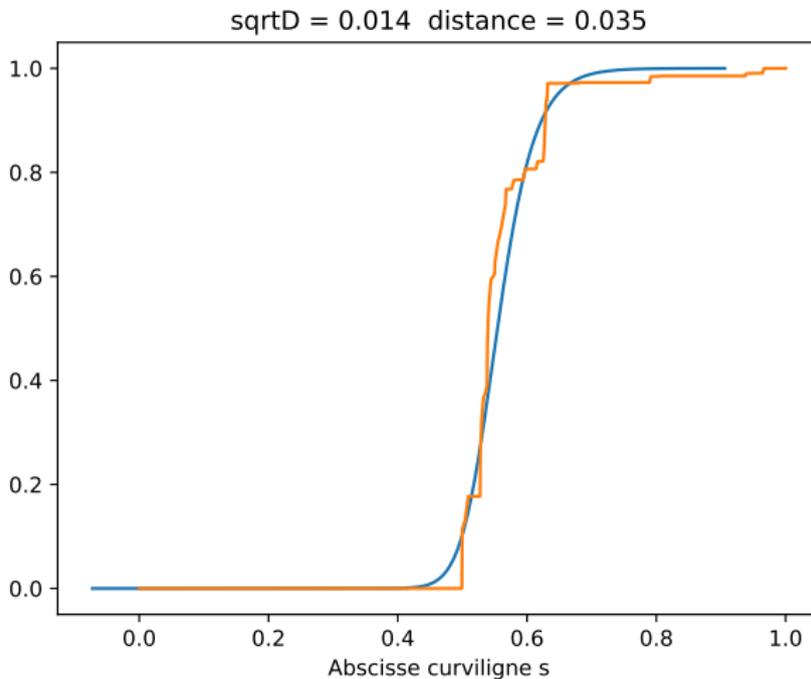


Figure – Recalage du front d'onde $\sqrt{D}.W_c$ sur le patient 23 avec un coefficient de diffusion $D = 0.014^2$.



Résultats

On peut calculer la vitesse de propagation du front $\sqrt{D} \cdot W_c$

- le front se propage à une vitesse $v = 2\sqrt{D}$
- on obtient l'ensemble des vitesses compatibles
- ou la durée d'invasion

Code chunk 6 : «fkpp_recalage (part 4)»

```
D = np.arange(0.01,0.02,0.0005) ** 2
dists = [fkpp_interp(p,d) for d in D]
alpha, min_dist = 0.05, np.amin(dists)
scompat = 2 * np.sqrt(np.extract(dists<(1+alpha)*min_dist,D))
print('Vitesses compatibles', scompat)
Xp = np.linspace(0,1,num=len(p))
print('Temps d\'invasion',np.round((1-np.trapz(p,dx=Xp[1]-Xp[0]))/scompat))
```

Interpret with python3

```
Vitesses compatibles [0.025 0.026 0.027 0.028 0.029 0.03 0.031]
Temps d'invasion [22.39 21.53 20.73 19.99 19.3 18.66 18.06]
```



Perspectives

- une observation est un profil $[0, 1] \rightarrow \mathbb{R}$ (pour un patient)
=> plusieurs patients
- un modèle est une fonction $[0, 1] \rightarrow \mathbb{R}$
=> autres types de modèles
- hypothèse 1 : distance L_2 entre \mathcal{E} et \mathcal{M}
=> autres distances
- hypothèse 2 : \mathcal{M} est restreint à l'ensemble des solutions d'une équation de réaction-diffusion (FKPP)
=> autres sous-espaces de fonctions



Conclusion

Un travail sur les outils pour l'analyse de données

- Logiciel Lepton
- Mise en oeuvre de la recherche reproductible
 - documents exécutables, faciles à réutiliser
 - documents complets, transparents, faciles à comprendre
- Ce n'est pas uniquement un problème "logiciel"
 - documents de qualité supérieure
 - changements de pratique, compétence à acquérir
- Perspectives
 - recommandations sur l'architecture des projets
 - propriétés supplémentaires : modularité, incrémentalité, exécution distante, etc.
 - proposition d'un module de formation doctorale



Conclusion

Un travail sur la notion de modèle et d'énoncé scientifique :

- il faut modéliser
 - les données observées, sous-ensemble des données possibles \mathcal{E} ,
 - les modèles compatibles, sous-ensemble de l'ensemble des modèles \mathcal{M} .
- l'analyse de données est un travail sur des ensembles
 - énoncé scientifique = sous-ensemble de \mathcal{E} ou de \mathcal{M} ,
 - élucider l'ensemble des modèles compatibles et leurs propriétés



Conclusion

Un travail sur la notion de modèle et d'énoncé scientifique :

- C'est faisable, par exemple
 - modèles compatibles
 - propriétés de l'ensemble des images (thèse de DV Tran)
 - propriétés des modèles de spectres RPE (thèse de DN Tran)
 - modélisation de l'aspect des lésions de la RCH et de leur répartition spatiale (thèse de S Al Ali)
- Perspectives
 - zoologie des modèles, en fonction du type des données
 - mise en relation avec les autres thématiques : machine learning, statistiques, etc.
 - énumération des hypothèses pour la chimie

