

Inférences de changements passés des tailles de population à partir de données génétiques: Test d'une nouvelle méthode

Raphaël Leblois, Champak R. Beeravolu & François Rousset
+ Renaud Vitalis, Pierre Pudlo

interface graphique : Julien Veyssier

Séminaires du Centre de Biologie pour la Gestion des populations (CBGP)
Montpellier
18/11/2014

Inférences démographiques & historiques

tailles de population / densités, migration, dispersion, temps de divergence, ...

Comment estimer ces paramètres démographiques en population naturelles :

Parfois avec des méthodes démographiques (directes) (e.g.
CMR, suivis, balises, ...)

- bonnes données mais que paramètres actuels, court terme et très chronophage

vs. Méthodes indirectes (Génétique/Génomique des populations)

- explosion dans les années 90-2000 et plus récente NGS (progrès biotech + statistique)

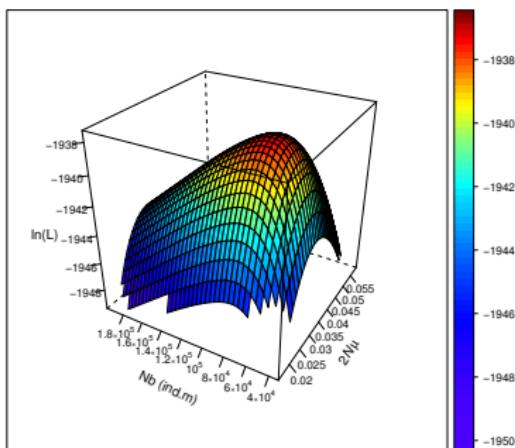
+ Méthodes indirectes permettent de retracer l'histoire démographique des populations à partir d'échantillons contemporains...

... ! mais avec certaines limites !

Le projet MIGRAINE

(F. Rousset & R. Leblois)

- Inférences démographiques et historiques à partir de données génétiques par maximum de vraisemblance fondées sur la simulation par coalescence
- Développement d'un logiciel avec interface utilisateur et sorties graphiques

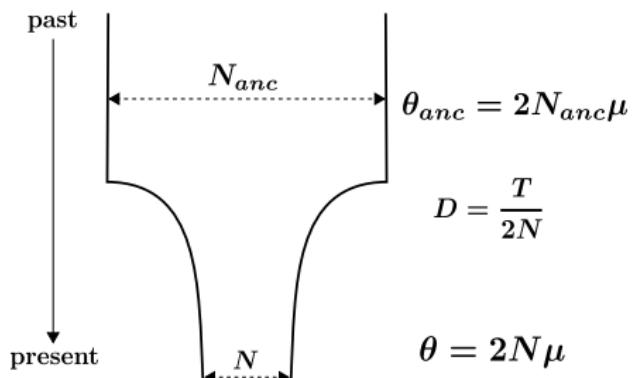


Les modèles implémentés à ce jour :

- Analyse spatiale de la dispersion : Isolement par la distance
- Migration entre 2-3 populations
- Changement passé de la taille d'une population

Le modèle démographique : OnePopVarSize

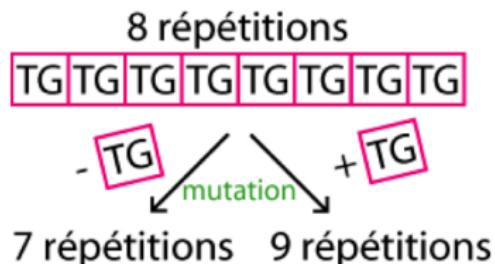
- une population isolée et panmictique ayant subit une contraction ou une expansion de taille dans le passé (changement exponentiel, linéaire ou discret)



- 4 paramètres naturels (N , T , N_{anc} et μ)
- 3 paramètres "à l'échelle" (diffusion/coalescent) : θ , D , θ_{anc}

Les modèles mutationnels : SMM, GSM, ISM

- Initialement, considération de locus microsatellites car très polymorphes → bcp d'information
- Première implémentation : le modèle de mutation par pas strict (SMM)
- Puis, implémentation d'un modèle par pas plus général (GSM)



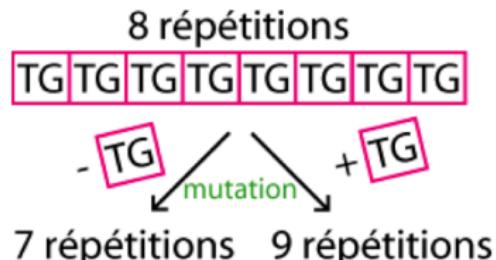
GSM (Pritchard et al. 1999)

Modèle de mutation par pas généralisé (Generalized Stepwise Model) : chaque mutation ajoute ou retire X répétitions, avec $X \sim \text{Geom}(p_{GSM})$

Meilleure approximation des processus mutationnels des microsatellites que le SMM mais ajoute un paramètre, p_{GSM} (\nearrow temps de calculs)

Les modèles mutationnels : SMM, GSM, ISM

- Initialement, considération de locus microsatellites car très polymorphes → bcp d'information
- Première implémentation : le modèle de mutation par pas strict (SMM)
- Puis, implémentation d'un modèle par pas plus général (GSM)



- Champak R. Beeravolu : ajout du modèle ISM (modèle à nombre infini de sites, i.e. pas de recombination intra-locus, pas de mutation multiple à un site) pour l'analyse de séquences ADN
- & Analyse multimarqueurs (e.g. microsats + séquences : SMM & GSM & ISM)

La méthode statistique : l'échantillonnage pondéré (IS) des généralogies

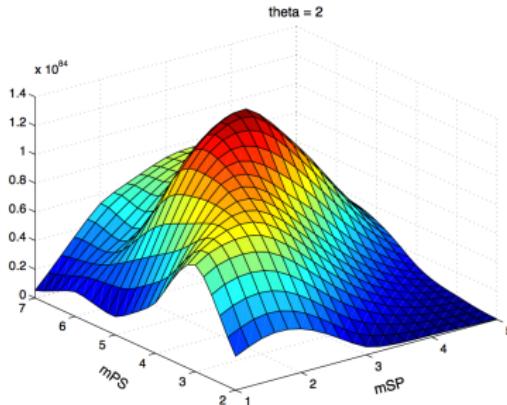
Deux algorithmes fondés sur la simulation par coalescence pour estimer la vraisemblance d'un échantillon de gène :

IS (Griffiths *et al.*) :

- Chaines de Markov absorbantes dans l'espace des généralogies
- Exploration indépendantes de l'espace des paramètres

MCMC (Felsenstein *et al.*) :

- Monte Carlo par chaînes de Markov sur l'espace des généralogies et des paramètres



La méthode statistique : l'échantillonnage pondéré (IS) des généralogies

Deux algorithmes fondés sur la simulation par coalescence pour estimer la vraisemblance d'un échantillon de gène :

IS (Griffiths *et al.*) :

- Chaines de Markov absorbantes dans l'espace des généralogies
 - Exploration indépendantes de l'espace des paramètres
- + Difficile à implémenter, que pour des modèles simples
- + Très peu utilisé : GeneTree et **Migraine** uniquement

MCMC (Felsenstein *et al.*) :

- Monte Carlo par chaînes de Markov sur l'espace des généralogies et des paramètres
- + Plus facile à implémenter, peut gérer des modèles plus complexes
- + Très largement utilisé : e.g. Lamarc, Migrate, Batwing, IM, **MsVar**, ...

Performances des analyses 'OnePopVarSize' dans MIGRAINE

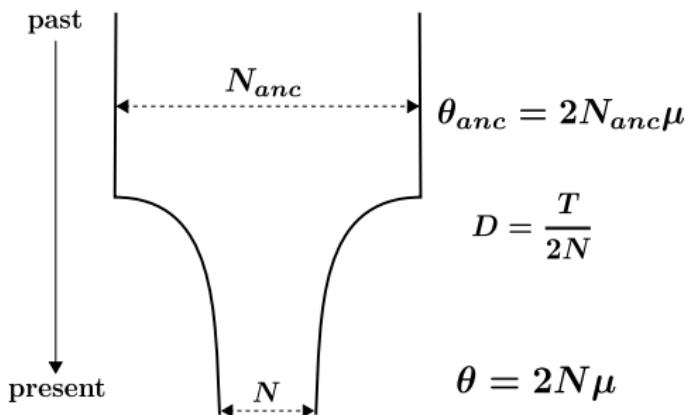
Rappels : modèle démographique

- Population unique isolée et panmictique
- Commence à se contracter il y a T générations, de façon exponentielle, jusqu'au présent (= échantillonnage)

Paramètres biologiques

vs. mis à l'échelle

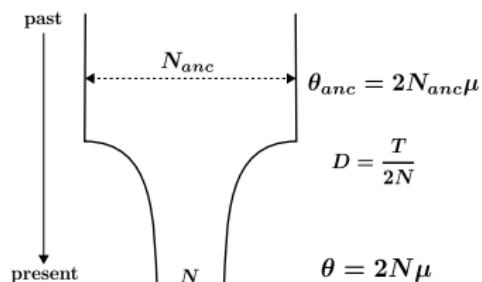
- Tailles de populations :
 - N gènes ($\theta = 2N\mu$),
 - N_{anc} gènes ($\theta_{anc} = 2N_{anc}\mu$)
- Temps (durée) :
 - T générations ($D = T/2N$)



Performances des analyses 'OnePopVarSize' dans MIGRAINE

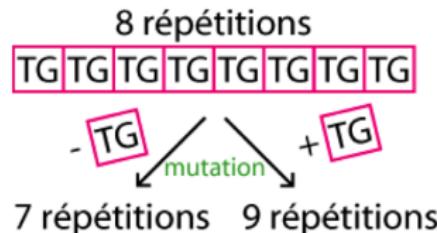
Rappels : modèle démographique

- Population unique isolée et panmictique
- Commence à se contracter il y a T générations, de façon exponentielle, jusqu'au présent



Modèle mutationnel

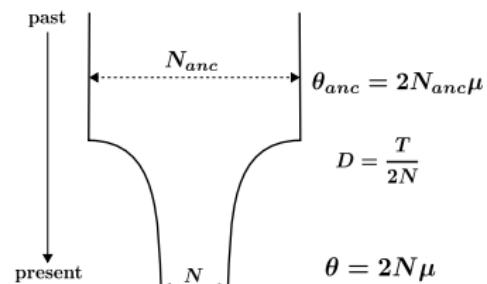
- Données alléliques (microsatellites)
- Modèle simple : SMM
- Taux de mutation : $\mu = 10^{-3}$



Performances des analyses 'OnePopVarSize' dans MIGRAINE

Rappels : modèle démographique

- Population unique isolée et panmictique
- Commence à se contracter il y a T générations, de façon exponentielle, jusqu'au présent



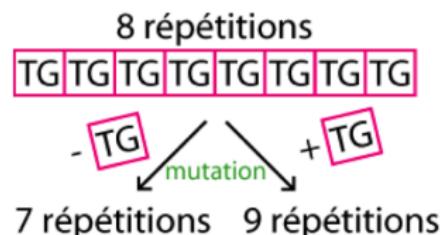
Modèle mutationnel

- Données alléliques (microsatellites)
- Modèle simple : SMM
- Taux de mutation : $\mu = 10^{-3}$

Autre méthode disponible :

MsVar (M. Beaumont)

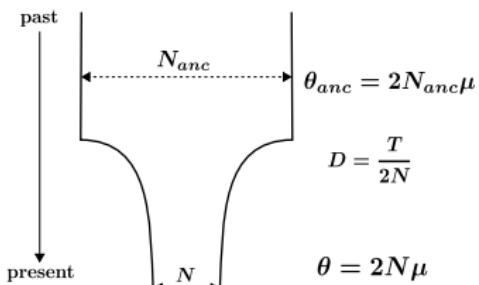
- Simulations coalescence
- Algorithme MCMC
- Implementation Bayesienne



Performances des analyses 'OnePopVarSize' dans MIGRAINE

Rappels : modèle démographique

- Population unique isolée et panmictique
- Commence à se contracter il y a T générations, de façon exponentielle, jusqu'au présent

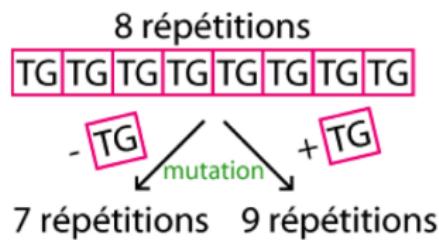


Modèle mutationnel

- Données alléliques (microsatellites)
- Modèle simple : SMM
- Taux de mutation : $\mu = 10^{-3}$

Echantillon génétique

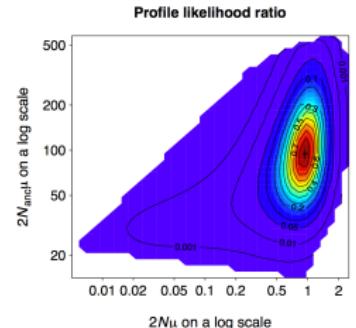
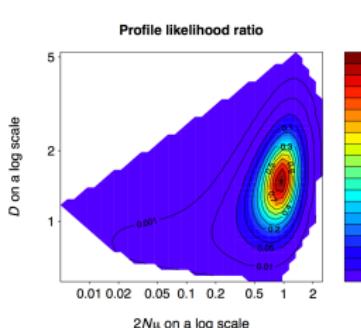
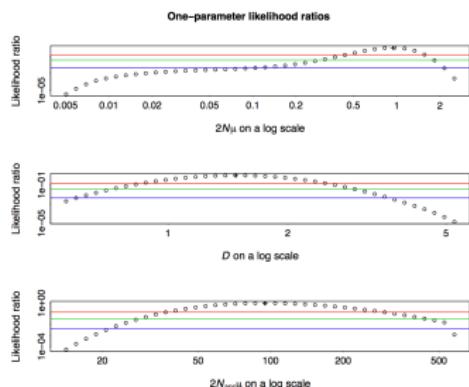
- 100 copies de gènes échantillonnées
- 10 loci génotypés



Sortie de MIGRAINE pour les analyses 'OnePopVarSize'

sur un jeu de données

Profiles de vraisemblance 1D et 2D



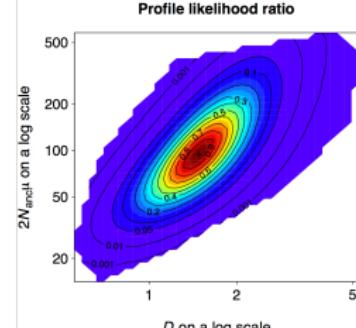
Résumé des résultats sous forme d'estimateur ponctuels et CI :

*** Confidence intervals ***

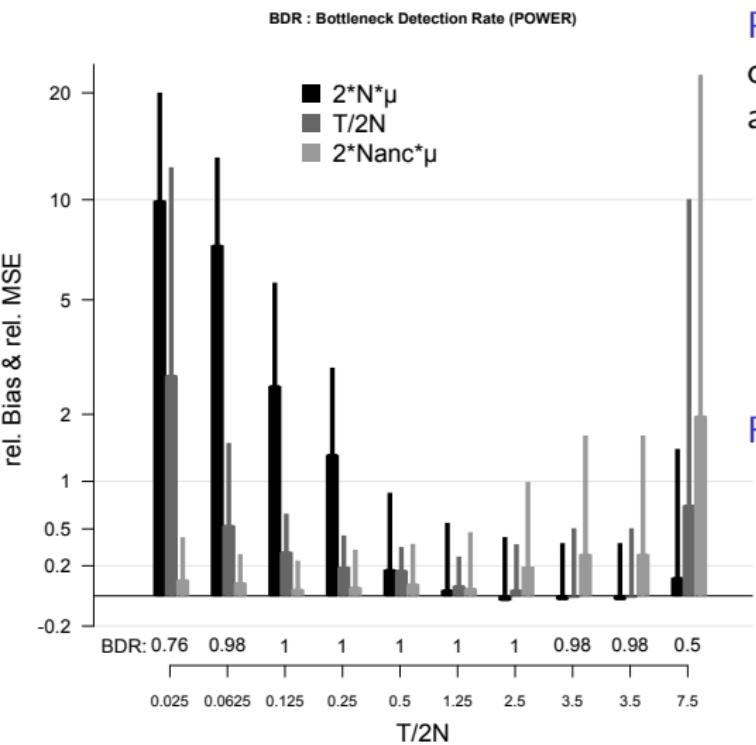
```
95%-coverage confidence interval for twoNmu : [ 0.441 -- 1.573 ]
95%-coverage confidence interval for D : [ 0.857 -- 2.502 ]
95%-coverage confidence interval for twoNancmu : [ 36.76 -- 295.6 ]
95%-coverage confidence interval for Nratio : [ 0.00329 -- 0.0268 ]
```

*** Point estimates ***

	twoNmu	T	D	twoNancmu
	0.937	0	1.48	94.67



Influence de l'ancienneté du changement démographique



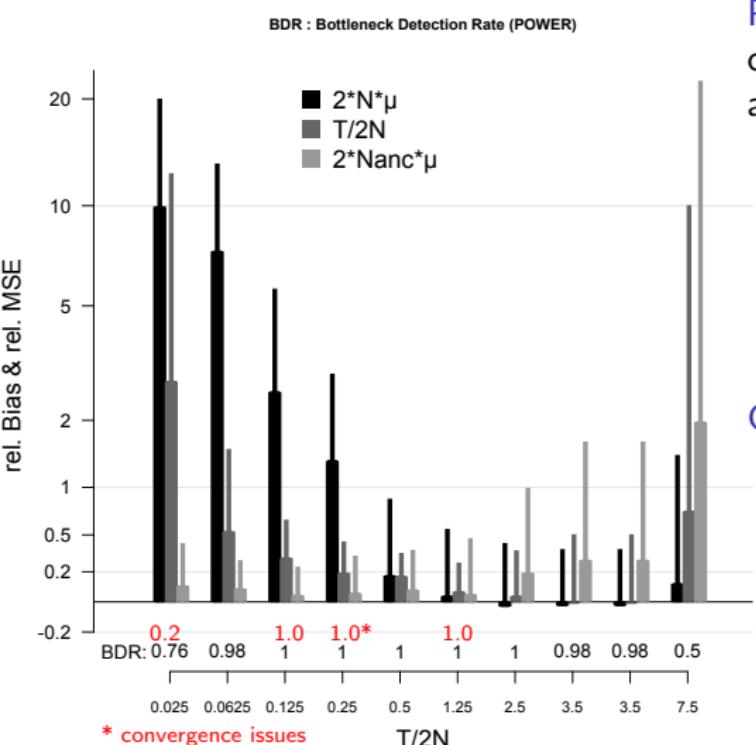
Performances attendues pour des contraction de très récentes à très anciennes :

- T de 10 à 3000 générations ($D = T/2N$ de 0.025 à 7.5)
- $N = 200$, $N_{anc} = 20\,000$ ($\theta = 0.4$, $\theta_{anc} = 40.0$)

Résultats

- Très bons taux de détections des contractions
- Inférences relativement précises (variable selon les paramètres)
- Forte influence du scénario sur la précision

Influence de l'ancienneté du changement démographique



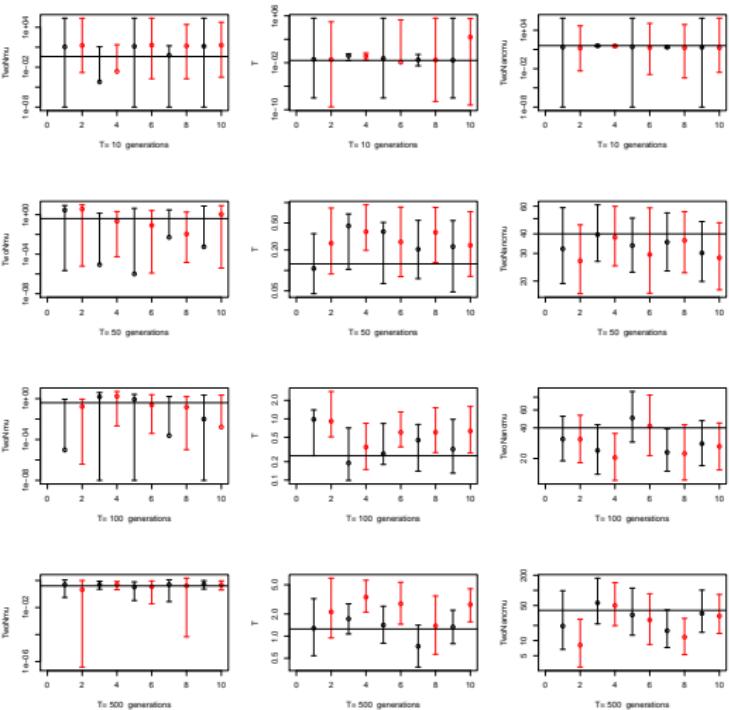
Performances attendues pour des contraction de très récentes à très anciennes :

- T de 10 à 3000 générations ($D = T/2N$ de 0.025 à 7.5)
- $N = 200, N_{anc} = 20\,000$ ($\theta = 0.4, \theta_{anc} = 40.0$)

Comparaison rapide avec MsVar

- Puissance similaire (BDR) pour les bons scénarios
- Meilleure détection avec MIGRAINE pour les scénarios "non-optimaux"

Influence de l'ancienneté du changement démographique



MIGRAINE vs. MsVar

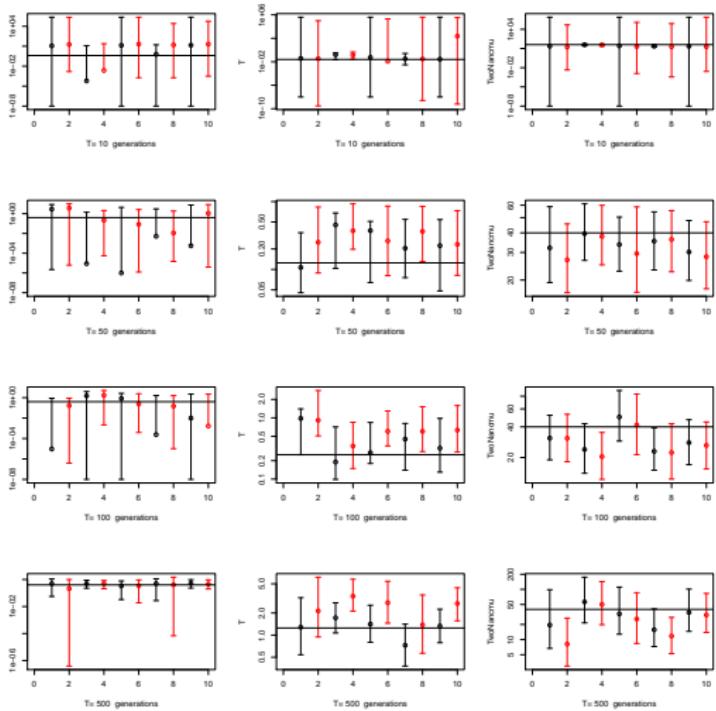
Performances attendues pour des contraction de très récentes à très anciennes :

- T de 10 à 3000 générations ($D = T/2N$ de 0.025 à 7.5)
- $N = 200$, $N_{\text{anc}} = 20\,000$ ($\theta = 0.4$, $\theta_{\text{anc}} = 40.0$)

Comparaison rapide avec MsVar

- Inférences un peu plus précises avec MIGRAINE

Influence de l'ancienneté du changement démographique



MIGRAINE vs. MsVar

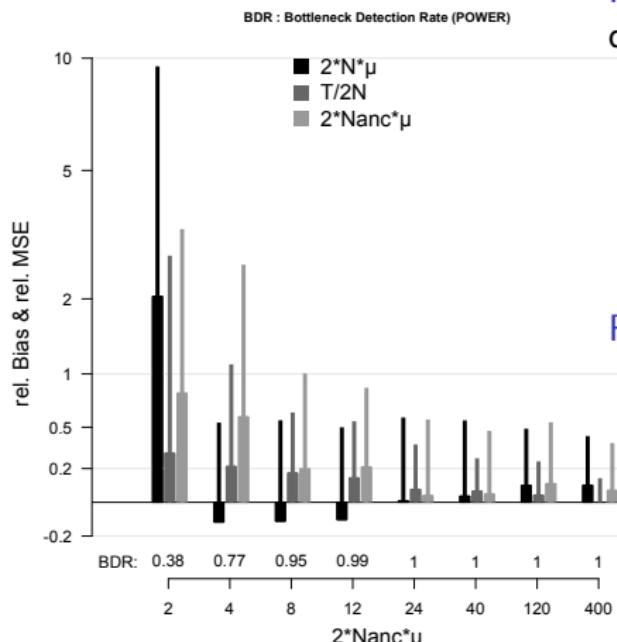
Performances attendues pour des contraction de très récentes à très anciennes :

- T de 10 à 3000 générations ($D = T/2N$ de 0.025 à 7.5)
- $N = 200$, $N_{\text{anc}} = 20\,000$ ($\theta = 0.4$, $\theta_{\text{anc}} = 40.0$)

Comparison avec MsVar pas facile

- Approches frequentiste vs. Bayesienne
- Très longs temps de calcul pour les MCMC de MsVar

Influence de l'intensité du changement démographique



Performances attendues pour des contractions de faible à très forte amplitude :

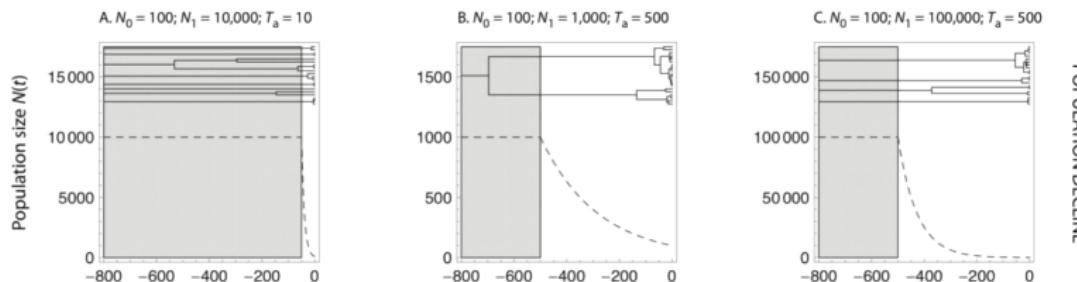
- $\frac{\theta_{anc}}{\theta} = \frac{N_{anc}}{N}$ varie de 5 à 1000,
- $N = 200 (\theta = 0.4), N_{anc} = 400 \rightarrow 200\ 000 (\theta_{anc} = 2 \rightarrow 400)$
- $T=500$ générations ($D = 1.25$, bon "timing")

Réultats

- Très bons taux de détection (BDR) pour $N_{ratio} \geq 10$
- Inférences précises quand contractions détectées
- Meilleures performances pour des fortes contractions

Interprétation des différences de précision d'estimation observées entre paramètres selon les différents scenarios à l'aide la théorie de la coalescence

- Comment les généalogies de gènes sont-elles affectées par les paramètres démographiques ?

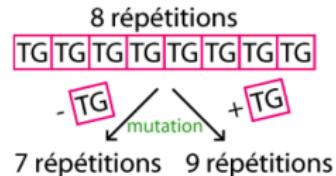


→ “Prédire” la quantité d’information présente dans les données
 L’information dans les données génétiques dépend fortement du nombre de mutations et d’événements de coalescence ayant eu lieu pendant les différentes phases démographiques

Robustesse : mauvaise spécification des processus mutationnels

Les microsatellites montrent des processus mutationnels complexes

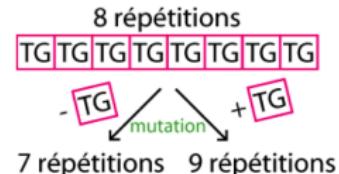
- Mutations ne suivent pas le SMM,
- Indels de plus d'une répétition courants



Robustesse : mauvaise spécification des processus mutationnels

Les microsatellites montrent des processus mutationnels complexes

- Mutations ne suivent pas le SMM,
- Indels de plus d'une répétition courants

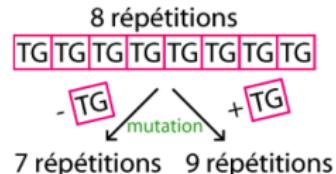


- Meilleur modèle = GSM (Generalized Stepwise Model)
Indels de X répétitions (loi géométrique)
valeurs "réalistes" : $pGSM \approx 0.22 - 0.74$

Robustesse : mauvaise spécification des processus mutationnels

Les microsatellites montrent des processus mutationnels complexes

- Mutations ne suivent pas le SMM,
- Indels de plus d'une répétition courants



- Meilleur modèle = GSM (Generalized Stepwise Model)
Indels de X répétitions (loi géométrique)
valeurs "réalistes" : $pGSM \approx 0.22 - 0.74$
- Problème : Analyser avec le SMM des données simulées en GSM et en population stable montre des signes de contraction passées
- 57% de fausses détections avec $pGSM = 0.22$
100% avec $pGSM = 0.74$!

Mauvaise robustesse aux processus mutationnels

Solution : implémenter un modèle GSM dans MIGRAINE

- Un paramètre de plus : $pGSM$ (4 param. à estimer)
→ temps de calcul plus longs

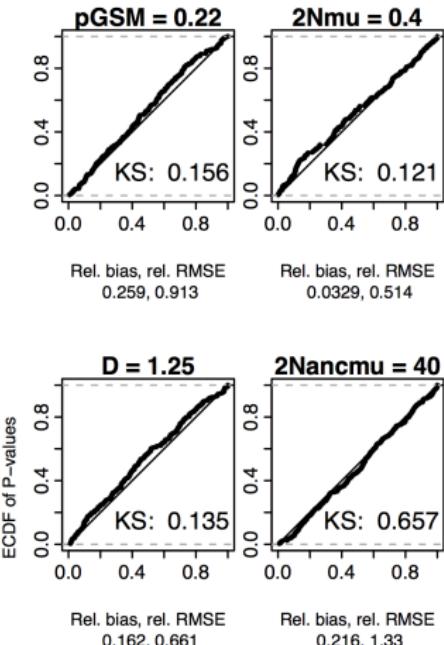
Mauvaise robustesse aux processus mutationnels

Solution : implémenter un modèle GSM dans MIGRAINE

- Un paramètre de plus : $pGSM$
- temps de calcul plus longs

Résultats : inférences avec le GSM

- $pGSM$ estimé avec précision limitée
- Autres paramètres bien estimé
- Perte de précision faible avec GSM vs. SMM



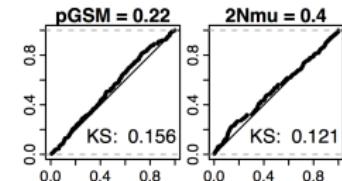
Mauvaise robustesse aux processus mutationnels

Solution : implémenter un modèle GSM dans MIGRAINE

- Un paramètre de plus : $pGSM$
- temps de calcul plus longs

Résultats : inférences avec le GSM

- $pGSM$ estimé avec précision limitée
- Autres paramètres bien estimé
- Perte de précision faible avec GSM vs. SMM



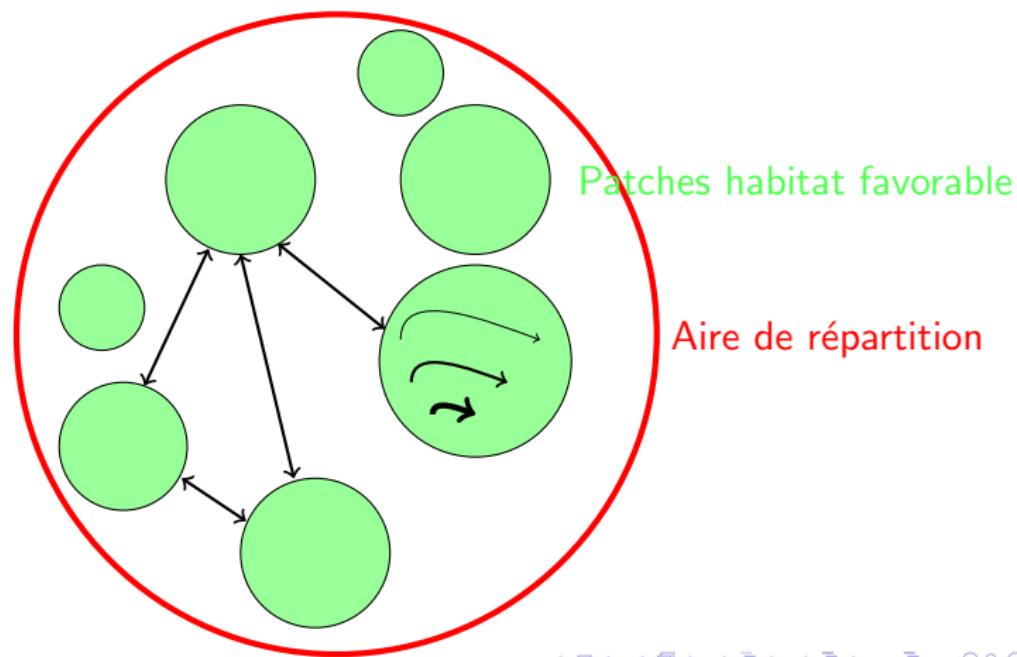
Rel. bias, rel. RMSE
0.259, 0.913 0.0329, 0.514

Rel. bias, rel. RMSE
0.162, 0.661 0.216, 1.33

- GSM aussi trop simpliste / réalité : processus mutationnels toujours mal spécifiés
- Simulations → robuste à d'autres facteurs mutationnels

Robustesse à la structuration des populations

Les populations naturelles sont rarement panmitiques et isolées,
→ différents niveaux de structuration, dispersion / migration



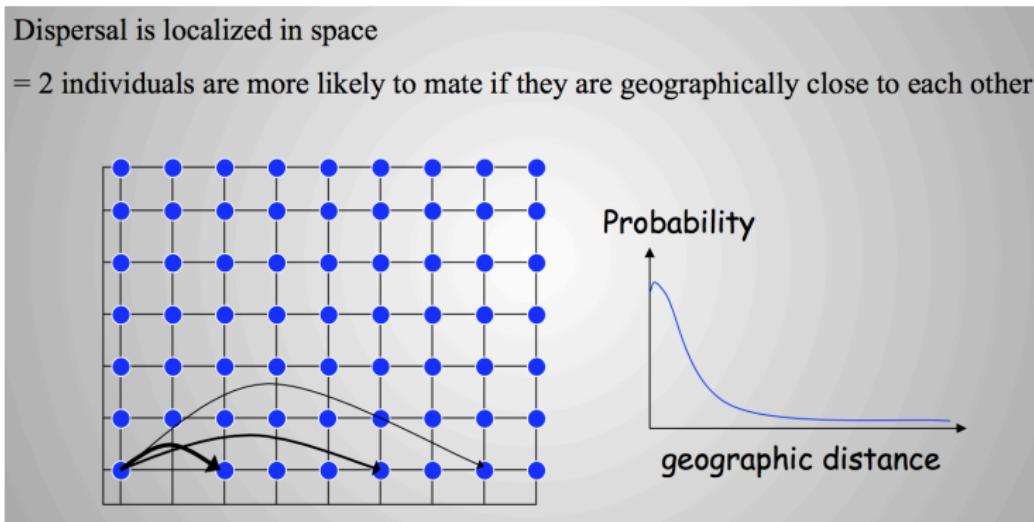
Robustesse à la structuration des populations

Les populations naturelles sont rarement panmitiques et isolées,
→ différents niveaux de structuration, dispersion / migration

- Structuration fine (dispersion limitée dans l'espace) :
- ex : Isolement par la distance dans patches d'habitat favorable

Dispersal is localized in space

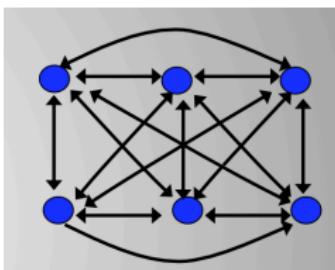
= 2 individuals are more likely to mate if they are geographically close to each other



Robustesse à la structuration des populations

Les populations naturelles sont rarement panmitiques et isolées,
→ différents niveaux de structuration, dispersion / migration

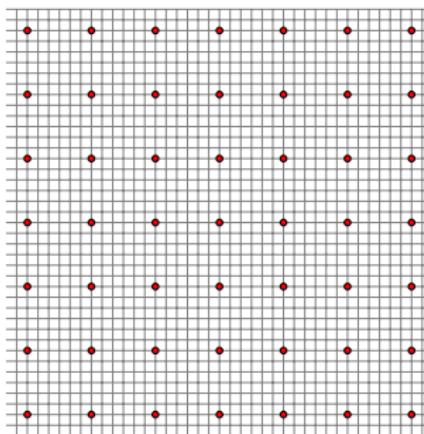
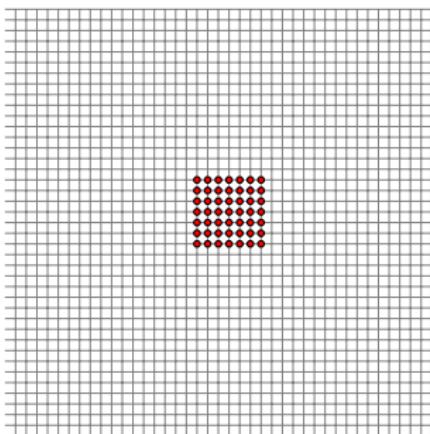
- Structuration fine (dispersion limitée dans l'espace) :
→ ex : Isolement par la distance dans patches d'habitat favorable
- Structuration à plus grande échelle
→ ex : modèle en îles entre patches d'habitat favorable



Robustesse à la structuration fine des populations

Structuration fine : effet de l'IBD sur la détection & inférence

- Simulation IBD en populations continues
- Force de l'IBD ($1 \leq D\sigma^2 \leq 100$)
- Echelle d'échantillonnage (local & global)



Robustesse à la structuration fine des populations

Effet IBD en population de taille constante sur détection de fausses contraction (FCDR) et fausses expansions (FEDR)

IBD strength	sampling scale	
	small (10 × 5)	large (28 × 28)
	FCDR / FEDR	FCDR / FEDR
$\sigma^2 = 1$	0.67 / 0.0	0.16 / 0.005
$\sigma^2 = 4$	0.54 / 0.0	0.095 / 0.010
$\sigma^2 = 10$	0.49 / 0.0	0.080 / 0.010
$\sigma^2 = 20$	0.41 / 0.005	0.090 / 0.020
$\sigma^2 = 100$	0.145 / 0.005	0.11 / 0.040

Robustesse à la structuration fine des populations

Effet **IBD en population de taille constante** sur détection de fausses contraction (FCDR) et fausses expansions (FEDR)

- Fausses detections de contraction quand échantillon à petite échelle (local)
- Peu d'effet quand échantillon sur toute la surface de la pop (global)

Robustesse à la structuration fine des populations

Effet **IBD en population de taille constante** sur détection de fausses contraction (FCDR) et fausses expansions (FEDR)

- Fausses detections de contraction quand échantillon à petite échelle (local)
- Peu d'effet quand échantillon sur toute la surface de la pop (global)

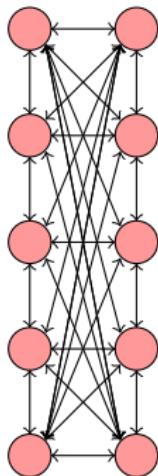
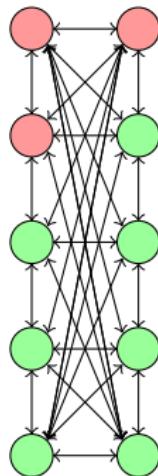
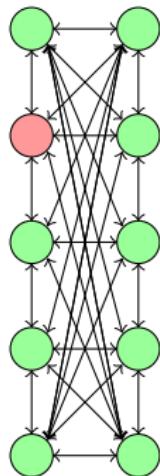
Effet **IBD en population de taille variable** sur détection de contraction (CDR) et inférence des paramètres

- Faible influence de l'IBD sur le taux de détection de contraction (au pire 90 vs. 99%)
- Mais meilleure précision des estimations et meilleurs IC avec échantillonnage global sur toute la surface de la population

Robustesse à la structuration des populations à plus grande échelle

Structuration à grande échelle (modèle en îles) : effet de la migration sur la détection & inférence

- Simulation modèle à 10 îles
- Intensité structuration ($0.01 \leq 2Nm \leq 100$, $0.000025 \leq m \leq 0.25$)
- "Echelle" d'échantillonnage : une pop & 3 pops & toutes



Robustesse à la structuration des populations à plus grande échelle

Effet migration **en populations de tailles constantes** sur détection de fausses contraction (FCDR) et fausses expansions (FEDR)

Island model settings		sampling scale		
		small 1 island	large 3 islands	very large all 10 islands
$\theta = 4$	$M = 0.01$	0.11 / 0.025	1.0 / 0.0	1.0 / 0.0
	$M = 0.1$	0.32 / 0.02	1.0 / 0.0	1.0 / 0.0
	$M = 1.0$	0.21 / 0.0	0.84 / 0.0	0.76 / 0.0
	$M = 10.0$	0.52 / 0.0	0.32 / 0.0	0.10 / 0.010
	$M = 30.0$	0.38 / 0.0	0.18 / 0.01	0.10 / 0.015
	$M = 100.0$	0.19 / 0	0.085 / 0.015	0.11 / 0.026
$\theta = 20$	$M = 1.0$	0.78 / 0.0	0.91 / 0.0	0.64 / 0.0

Robustesse à la structuration des populations à plus grande échelle

Effet migration **en populations de tailles constantes** sur détection de fausses contraction (FCDR) et fausses expansions

- Effet plus complexe qu'en IBD : beaucoup de FCD quelque soit l'échelle d'échantillon.
- moins d'effet échantillon global quand migration forte, et vice-versa
- Echantillonner un gène par dème réduit les FCDR à 2%

Robustesse à la structuration des populations à plus grande échelle

Effet migration **en populations de tailles constantes** sur détection de fausses contraction (FCDR) et fausses expansions

- Effet plus complexe qu'en IBD : beaucoup de FCD quelque soit l'échelle d'échantillon.
- moins d'effet échantillon global quand migration forte, et vice-versa
- Echantillonner un gène par dème réduit les FCDR à 2%

Effet **migration en population de taille variable** sur détection de contraction (CDR) et inférence des paramètres

- Forte influence de la migration sur la détection de contraction (CDR : 0.5% ; 7% ; 88% vs. 99%, pour $M = 0.01; 1.0; 100.0$)
- Estimation toujours mauvaise des paramètres sauf pour $2Nm \geq 100$

Publication et Analyses de jeux de données réels

Publications :

Microsatellites Molecular Biology and Evolution, Oct 2014

Séquences ADN, multi-marqueurs cet hiver/printemps

Interface graphique cet hiver/printemps.

Analyses concrètes : Oran-Outangs + jeux de données projets ANR
MNHN

Analyses de jeux de données réels

Oran-Outang : contraction récente (concorde avec démo & MsVar)

Analyses projet ANR MOHMIE (MNHN, petite faune maroc)

- Mulots : forte expansion
- Gerbillles : contraction forte et ancienne
- Crapauds : forte contraction très récente,
...étrange : très répandu mais tailles efficaces actuelles très faibles...
- Souris : à faire

et IM-MODEL@coral.fish (MNHN, poissons coralliens et requins)

- Requins baleines : expansion récente
- Requins pointes noires : beaucoup d'expansions anciennes,
une contraction récente (Homme)
- Poissons coralliens : à faire

Les analyses 'OnePopVarSize' dans MIGRAINE : conclusions and perspectives

- Très efficace pour détecter de contractions ou des expansions
- Précision dépend fortement des scenarios et des paramètres
- Robuste à une structuration fine intra-pop (IBD local)
- Plus rapide et plus précis que l'alternative "MCMC" MsVar

Mais :

- Pas robuste aux processus mutationnels (mais GSM implémenté)
- Pas robuste à la structuration à grande échelle (modèle en îles)
- Biais pour contractions fortes et récentes (très fort déséq., IS non efficace)

ce qu'il faudrait faire maintenant :

- Distinguer la migration des variations de tailles de population
- Améliorer l'IS pour des modèles en déséquilibre (pas évident...)

Quelques conclusions générales sur l'inférence en génétique des populations

- La théorie de la coalescence et le maximum de vraisemblance forment un très bon cadre statistique pour l'inférence en génétique des populations
- Ces méthodes permettent d'extraire plus d'information que les méthodes des moments (e.g. F-statistiques)
- Forte limitation sur le nombre de locus pouvant être analysés ($\leq 1,000 - 10,000$)
- La théorie de la coalescence et les tests par simulation permettent :
 - de mieux comprendre les limites de ces méthodes
 - de mieux interpréter les résultats obtenus lors de traitements de données réelles

Quelques conclusions générales sur l'inférence en génétique des populations

- La théorie de la coalescence et le maximum de vraisemblance forment un très bon cadre statistique pour l'inférence en génétique des populations
- Ces méthodes permettent d'extraire plus d'information que les méthodes des moments (e.g. F-statistiques)
- Forte limitation sur le nombre de locus pouvant être analysés ($\leq 1,000 - 10,000$)
- La théorie de la coalescence et les tests par simulation permettent :
 - de mieux comprendre les limites de ces méthodes
 - de mieux interpréter les résultats obtenus lors de traitements de données réelles

Merci pour votre attention

What's in the MIGRAINE software ?

C++ core IS computations

- Stratified random sampling of parameter points (Bounds provided by user)
- Estimation of the likelihood at each point using IS
- write some R code

R (automated interaction between C++ and R codes)

- Likelihood surface interpolation by Kriging
- Inference of MLEs and CIs
- (Nice) Plots of 1D and 2D Likelihood profiles
- Computation of new points inside the 99.9% convex envelope
- Computation of LRT-Pvalue (e.g. to test an hypothesis $Nratio < 1$)

parts of R code written by C++, others in a package called "Rmigraine"

What's in the MIGRAINE software ?

C++ core IS computations

Point sampling, Likelihood estimation, Write R code

R scripts (automated interaction between C++ and R codes)

Likelihood surface interpolation, MLEs and CIs, Plots, next points

Migraine can automatically run iterative analysis by considering a sequence of (C++, R) computations.

This procedure allows to obtain better inferences by maximizing the number points in the good zone of the parameter space.

How does the MIGRAINE software work ?

- One (or many) Genepop data files associated with a nexus files for DNA sequence data sets
- Parametrization of C++ and R analysis using a text file or using the graphical interface (Soon)
- Run MIGRAINE
- Outputs :
 - Results text file (ML, CI, LR tests)
 - Graphics in a ps / eps / pdf file

How does the MIGRAINE software work ?

most complex parameters have good default values and ... we provide a very detailed and comprehensive documentation with :

- Basic theory (IS + kriging)
- How to install MIGRAINE (C++ code and R package)
- Complete description by key words of all parameters
- description and interpretation of all outputs
- Simple examples to run (good to start with)

Moreover, the GUI will include a “What’s this” button linked to all keyword description of the documentation

How does the MIGRAINE software work ?

GUI under construction

Model | Geometry | Likelihood | CI-LRT | Interpolation | Graphics |

Demographic model :

1D IBD 2D IBD Island model
 1 pop 1 pop variable size 2 pop

Mutation model: 1D IBD

KAM SMM pGSM

Total allele number : From data file User defined K = []

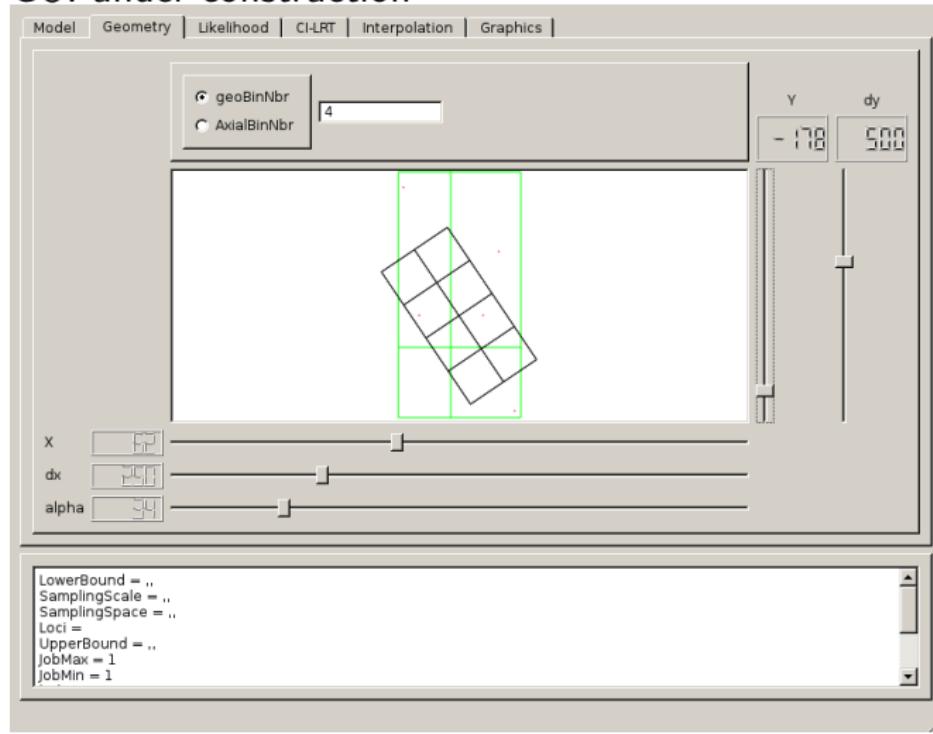
Loci : All Polymorphic only

Choose one data file : Multiple inputs ?

```
LowerBound = ..  
SamplingScale = ..  
SamplingSpace = ..  
Loci = ..  
UpperBound = ..  
JobMax = 1  
JobMin = 1 ..
```

How does the MIGRAINE software work ?

GUI under construction



How does the GUI of MIGRAINE look like ?

GUI under construction

Model | Geometry | Likelihood | CI-LRT | Interpolation | Graphics |

Statistic sequence:

IS PAC Sequence

PAC PAC [] [] [] []

Runs per point : 1000

1000

Points number :

choose points point min point max

Write sequence :

Over, Append Over Append

Add point Remove selected point

Test points :

LowerBound = ..
SamplingScale = ..
SamplingSpace = ..
LocI = ..
UpperBound = ..
JobMax = 1
JobMin = 1

Perspectives for MIGRAINE

Mutational models being currently implemented :

- Short DNA sequences (ISM done, other models?)
- SNPs

Perspectives for MIGRAINE

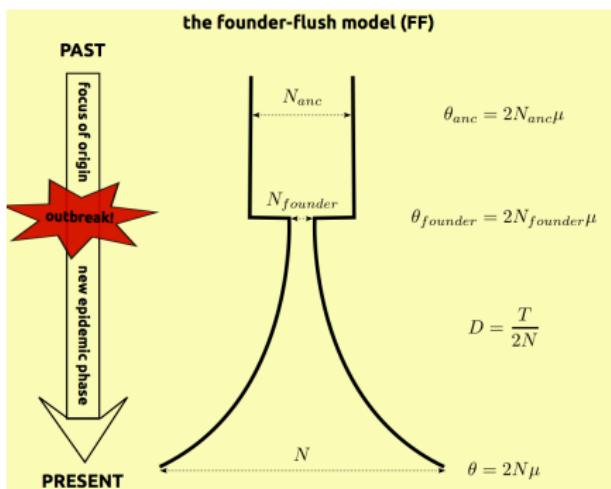
Mutational models being currently implemented :

- Short DNA sequences (ISM done, other models?)
- SNPs

Demographic models which we plan to implement “shortly” :

- Founder-Flush

(first tests are running,
see Poster 15)



Perspectives for MIGRAINE

Mutational models being currently implemented :

- Short DNA sequences (ISM done, other models?)
- SNPs

Demographic models which we plan to implement “shortly” :

- Founder-Flush
- Pure divergence 2-4 populations (with C. Beeravolu)
- Isolation with Migration 2-3 populations (with C. Beeravolu)
- Island population structure with past size variations
- IBD in two habitats (ecological barrier)(with A. Coulon)
- IBD with a geographic barrier (with A. Coulon)

