

Estimation des paramètres d'un modèle de dynamique de population structuré en longueur: maximum de vraisemblance et algorithme génétique

DROUINEAU Hilaire
MAHEVAS Stéphanie
BERTIGNAC Michel



Ifremer

Introduction

- En halieutique, les modèles de dynamique des pop ont trois principaux objectifs:
 - Améliorer la connaissance sur les espèces et leurs exploitations
 - Réaliser des diagnostics de l'état des stocks et de leur exploitation
 - Prédire leur évolution sous différentes hypothèses

Introduction

- Modèles traditionnels sont:
 - Structurés en âge: population divisée en classes d'âge considérées homogènes + besoin de données structurées en âge
 - Non spatialisés: la population et l'activité de pêche sont considérés homogènement répartis dans l'espace
 - Souvent un pas de temps annuel
- Or:
 - De nombreux processus sont plus liés à la taille du poisson qu'à son âge + données disponibles en taille
 - Des concentrations saisonnières de la population (reproduction, nourricerie...) et de la pêche
 - Les processus (croissance, mortalité, pêche...) sont continus dans le temps

Introduction

- Donc:
 - Structurer la population en taille en longueur plutôt qu'en âge
 - Spatialiser le modèle
- Mais:
 - Nécessité d'évaluer l'impact de la discrétisation des longueurs et du temps
 - Trouver des hypothèses rendant le modèle plus robuste

Introduction


- Modèle matriciel décrit les sous-processus guidant la dynamique de la population et de son exploitation
- Mais de nombreux paramètres inconnus
 - Doivent être estimés
 - Ajustement du modèle par maximum de vraisemblance sur des données observées (captures professionnelles, données de campagnes...)
 - Optimisation d'une fonction multi-dimensionnelle => vers des algorithmes génétiques

Impact de la discrétisation du temps et de la longueur



Un modèle matriciel de croissance


- $N(t+1)=G(t)N(t)$
 - $G(t)$: matrice des probabilités de transition
 - La croissance moyenne suit une loi de Von Bertalanffy:
Incrément $\Delta l=(L_{inf}-L(t))(1-\exp(-K \cdot \Delta t))$
 - Les incréments de croissance suivent une loi de distribution autour de cette moyenne
- Quelles hypothèses?
 - Quel pas de temps? 1 an, 1 trimestre, 1 mois
 - Quelle taille de classe? 5cm, 1 cm
 - Position des individus dans les classes?



$$P_{1 \rightarrow 3} = \int_{c - \frac{a+b}{2}}^{d - \frac{a+b}{2}} f(x) dx \quad \text{avec } E(X) = \left(L_{\infty} - \frac{a+b}{2} \right) [1 - \exp(-K \cdot \Delta t)]$$

Un modèle matriciel de croissance

- $N(t+1)=G(t)N(t)$
 - $G(t)$: matrice des probabilités de transition
 - La croissance moyenne suit une loi de Von Bertalanffy:
Incrément $\Delta l=(L_{\infty}-L(t))(1-\exp(-K \cdot \Delta t))$
 - Les incréments de croissance suivent une loi de distribution autour de cette moyenne
- Quelles hypothèses?
 - Quel pas de temps? 1 an, 1 trimestre, 1 mois
 - Quelle taille de classe? 5cm, 1 cm
 - Position des individus dans les classes?



$$P_{1 \rightarrow 3} = \int_a^b \int_{c-y}^{d-y} f(x) dx dy \quad \text{avec } E(X) = (L_{\infty} - y) [1 - \exp(-K \cdot \Delta t)]$$

Un modèle matriciel de croissance

- $N(t+1)=G(t)N(t)$
 - $G(t)$: matrice des probabilités de transition
 - La croissance moyenne suit une loi de Von Bertalanffy:
Incrément $\Delta l=(L_{inf}-L(t))(1-\exp(-K \cdot \Delta t))$
 - Les incréments de croissance suivent une loi de distribution autour de cette moyenne
- Quelles hypothèses?
 - Quel pas de temps? 1 an, 1 trimestre, 1 mois
 - Quelle taille de classe? 5cm, 1 cm
 - Position des individus dans les classes?
 - Quelle loi de distribution des incréments? Normale, gamma, lognormale

Un modèle matriciel de croissance


- $N(t+1)=G(t)N(t)$
 - $G(t)$: matrice des probabilités de transition
 - La croissance moyenne suit une loi de Von Bertalanffy:
Incrément $\Delta l=(L_{inf}-L(t))(1-\exp(-K \cdot \Delta t))$
 - Les incréments de croissance suivent une loi de distribution autour de cette moyenne
- Quelles hypothèses?
 - Quel pas de temps? 1 an, 1 trimestre, 1 mois
 - Quelle taille de classe? 5cm, 1 cm
 - Position des individus dans les classes?
 - Quelle loi de distribution des incréments? Normale, gamma, lognormale
 - Relation entre moyenne et variance des incréments? $V=CE$, $V=CE^2$

Ajusté sur des données quasi-continues

- Pour quantifier l'impact des différentes hypothèses:
 - On simule la croissance de 10000 individus avec un pas de temps mensuel => données quasi-continues
 - Hypothèses sur la loi des incréments, la variance, et le taux de croissance
- On ajuste le modèle matriciel à ces données
 - On estime K et la variance des incréments
 - Maximum de vraisemblance des fréquences « observées » et fréquences estimées
- Analyse statistique (modèles linéaires et arbre de régressions multiples) pour expliquer par les différentes hypothèses:
 - L'écart entre fréquences observées et estimées: BIC
 - L'écart entre taux de croissance estimé et observé: | Kobs-Kest |

Résultats

- Pas de améliori
- L'estim
 - un p class
 - Des des (unifo




leur
jeurs

mplexe
er de
ance
tribution

Ajustement du modèle aux données observées





Présentation du modèle matriciel

- $N(t+1) = S_r(t) [Mig(t) G(t) (R(t) + N(t))]$

effectifs

survie

migration

croissance

recrutement

- Quatre processus biologiques:

- Recrutement: un recrutement moyen et des effets aléatoires

$$N_1(t) = N(t) + \bar{R} \exp\left(\varepsilon_{recru} + \frac{\sigma_{recru}^2}{2}\right) \quad \text{with} \quad \varepsilon_{recru} \sim N(0, \sigma)$$

Présentation du modèle matriciel

- $N(t+1) = Sr(t)[Mig(t)G(t)(R(t) + N(t))]$

effectifs

survie

migration

croissance

recrutement

- Quatre processus biologiques:

- Recrutement: un recrutement moyen et des effets aléatoires
- Croissance: (cf avant) on doit estimer un taux de croissance et une variance

$$N_2(\text{classe}, \text{zone}) = \sum_c p_{c \rightarrow \text{classe}} N_1(c, \text{zone})$$

Présentation du modèle matriciel

- $N(t+1) = Sr(t)[Mig(t)G(t)(R(t) + N(t))]$

effectifs

survie

migration

croissance

recrutement

- Quatre processus biologiques:
 - Recrutement: un recrutement moyen et des effets aléatoires
 - Croissance: (cf avant) on doit estimer un taux de croissance et une variance
 - Migration: proportion d'individus matures et immatures changeant de zones par saison

$$N(t+\varepsilon, classe, zone) = \sum_z [mat_{classe} N_2(classe, z) mig_{mature}(z, zone) + (1 - mat_{classe}) N_2(class, z) mig_{immature}(z, zone)]$$

Présentation du modèle matriciel

- $N(t+1) = Sr(t)[Mig(t)G(t)(R(t) + N(t))]$

effectifs

survie

migration

croissance

recrutement

- Quatre processus biologiques:
 - Recrutement: un recrutement moyen et des effets aléatoires
 - Croissance: (cf avant) on doit estimer un taux de croissance et une variance
 - Migration: proportion d'individus matures et immatures changeant de zones par saison
 - Mortalité naturelle des matures et immatures à estimer
 - +effectifs initiaux par classes et par zones à estimer

Présentation du modèle matriciel

- Dynamique de l'activité de pêche permet de calculer la mortalité par pêche par classes, zone et pas de temps
- Repose sur des Fishery Units:
 - 1 zone de pêche
 - 1 sélectivité (fonction de la longueur): à estimer
- Composées de différentes flottilles dans chaque FU
 - Effort (intensité de pêche) par pas de temps (connu)
 - Capturabilité (proba qu'un poisson soit capturé par une unité d'effort) à estimer

$$N(t+1, classe, zone) = mat_{classe} \times N(t+\varepsilon, classe, zone) \times \exp\left[-(M_{mature} + F_{tot}(t, classe, zone)) \times \Delta t\right] \\ + (1 - mat_{classe}) \times N(t+\varepsilon, classe, zone) \times \exp\left[-(M_{immature} + F_{tot}(t, classe, zone)) \times \Delta t\right]$$

Présentation du modèle matriciel

- Bilan: environ 1 millier des paramètres inconnus! (dont $7 \times 120 = 840$ pour les effectifs initiaux)
- Quelles données disponibles?
 - Captures par classes flotilles, classe de longueur et pas de temps
 - Données de campagnes scientifiques
- On suppose que les observations suivent une loi de distribution de moyenne la valeur estimée par le

$$L(an, flot) = \prod_{t \in an} \prod_{c \in CLASSE} f(C_{obs, flot}(t, c))$$

avec f une densité de probabilité de moyenne $C_{est, fleet}(t, c)$ et de variance σ_{fleet}^2

Comment optimiser la fonction?


- La fonction à maximiser est multi-dimensionnelle, et ne peut être maximiser analytiquement
- Besoin d'une optimisation numérique
- Au vu du nombre de paramètres inconnus, il faut
 - Éviter les optima locaux
 - Converger en un temps « raisonnable vers la solution »

=>Essai d'utilisation d'algorithme génétique

Principe de l'algorithme génétique

● Définitions:

- Gène: la valeur d'un paramètre
- Chromosome: une solution potentielle: ensemble de gènes
- Fitness: « qualité » de la solution, ici sa vraisemblance
- Population: un ensemble de chromosomes, pool de diversité



Population

Chromosome

Principe de l'algorithme génétique

Génération n

Intermédiaire

Génération n+1

- Faire évoluer la population
- Garder les meilleurs solutions: Sélection
- Entretenir de la diversité pour explorer tout l'espace de recherche: mutation, croisement



Principe de l'algorithme génétique

- Sélection (de $2n$ à n):
 - On tire deux chromosomes de la pop de départ, le meilleur est mis dans la pop intermédiaire
- Cross-over (de n à $2n$):
 - On appaire les n chromosomes 2 à 2
 - Le meilleur est copié une deuxième fois
 - On fait une combinaison linéaire des deux chromosomes
- Mutation 1 et 2 ($2n$):
 - Pour chaque gène, on tire un nombre aléatoire entre 0 et 1
 - Si le nombre est inférieur à une proba de mutation =>mute
 - Mutation 1: On tire une valeur entre les bornes de recherche du paramètre
 - Mutation 2: On tire une valeur dans un intervalle resserré autour de la valeur courante

Intérêts

- Bonne exploration de l'univers de recherche
⇒ évite bien les optima locaux
- Pas de calcul de dérivées
⇒ Facilite le codage + vitesse de calcul
- Semble donner des résultats très satisfaisants!

Conclusion



Conclusion

- Analyse de l'impact de la discrétisation a permis de choisir un modèle robuste
- Modèle complet comporte de nombreux paramètres inconnus:
 - Étudier l'identifiabilité des paramètres
 - Réduire le nombre de paramètres en ajoutant des hypothèses supplémentaires
 - Choisir un bon algorithme d'optimisation vu la complexité de la fonction de vraisemblance