# Optimisation de variétés de tournesol sous incertitude climatique 

Ronan Trépos (master 2 de Bastien Poublan)

31 octobre 2014

Collaborations: B. Poublan, V.Picheny et R.Trépos


## Sommaire

(1) Présentation du stage
(2) Méthodes développées

- Sélection d'un sous-ensemble de climat
- Reconstruction des distributions de rendements
(3) Résultats obtenus

4 Conclusion

## Optimisation de variétés de tournesol sous incertitude climatique

- Modèle de simulation dynamique :

Contexte :

- Type de sol,
- Conduite de culture,

Traits phénotypiques:

- Taille des feuilles,
- Inclinaison de la plante,


Récolte : - Rendement

```
Données climat :
- T }\mp@subsup{}{}{\circ}\textrm{min
    - T`max,
- Pluie,
```

- Objectif : trouver le phénotype permettant d'obtenir les meilleurs rendements


## Tournesol

- Différentes caractéristiques:
- 8 traits phénotypiques
- Minimum et maximum pour chaque trait
- Variations continues

Gestion de l'incertitude

- Séries temporelles pour la description du climat:
- Données journalières
- Données de 1975 à 2012 sur 5 emplacements en France $\Rightarrow 190$ climats différents

Température maximale



Ensoleillement


Précipitations


## Enjeux

- Prise en compte de l'incertitude climatique $\Rightarrow$ Temps de calcul important
- Comment réduire le nombre de simulations?
- Quels critères statistiques de performance?
$\diamond$ Climat variable aléatoire $\rightarrow$ Rendement variable aléatoire

Objectifs du stage
$\Rightarrow$ Formalisation du problème d'optimisation
$\Rightarrow$ Solution algorithmique

## Optimisation : quelle formulation?

## Critères statistiques

- Moyenne, variance, quantile ...
- Utilité espérée, "CVaR" ...


## Données

- 1 phénotype : 190 rendements




## Formulation retenue

Maximiser: $\left\{\begin{array}{l}E[R] \\ C V a R_{30 \%}(R)\end{array}, \mathrm{R} \in \mathbb{R}^{190}\right.$


## Différentes approches

- Approche par échantillonnage exhaustif :

- Approche à l'aide d'un apprentissage à priori :



## Discussion sur l'approche choisie

- Séparation apprentissage a priori et optimisation
- Adaptable à un autre simulateur
- Approche sur la classification
- Séries climatiques différentes
- Rendements différents
- Limites:
- Résolution d'un problème approché
- Pas de correction en ligne sur l'apprentissage


## Sélection d'un sous-ensemble de climat

Recherche de 10 climats différents donnant 10 rendements différents

## Étapes de la classification

- Calcul de distance entre les séries temporelles
- Agrégation des distances (Normalisation + somme pondérée)
- Algorithme de classification non supervisée (K-means, PAM, classification hiérarchique)
$\Rightarrow$ Sous ensemble de climats

Température minimale



Température maximale



Évapotranspiration Ensoleillement


Précipitations


Rendements
28.99
25.5
...
22
24
26.5

## Distance entre deux séries (même variable)

- Distance DTW (Dynamic Time Warping)
- Prise en compte de "décalage" entre deux séries
- Température minimale, maximale, ensoleillement, évapotranspiration : $\pm 7$ jours
- Précipitation : $\pm 3$ jours

Évapotranspiration


Précipitations


## Agrégation des distances (toutes les variables)

## Distances

- Distance DTW inter-climats
- Distance euclidienne inter-rendements
- Normalisation des distances

Utilisation dans la classification de la distance suivante :

$$
\begin{aligned}
\text { Distance }_{\text {Totale }} & =\frac{1}{2}\left(\alpha_{1} \bar{D}_{\text {Tmin }}+\alpha_{2} \bar{D}_{\text {Tmax }}+\alpha_{3} \bar{D}_{\text {Evapo }}\right. \\
& \left.+\alpha_{4} \bar{D}_{\text {Ensol }}+\alpha_{5} \bar{D}_{\text {Pluie }}\right) \\
& +\frac{1}{2}\left(\mu_{1} \bar{D}_{\text {Pheno1 }}+\mu_{2} \bar{D}_{\text {Pheno2 }}+\ldots+\mu_{10} \bar{D}_{\text {Pheno10 }}\right)
\end{aligned}
$$

## Reconstruction de la distribution (10 rendements $\Rightarrow 190$ rendements)



- Approches non paramétriques


Pour un nouveau phénotype $p$ et à partir des rendements obtenus sur les 10 climats représentatifs des classes $I_{1}, \ldots, l_{10}$ : $R\left(p, I_{1}\right), \ldots, R\left(p, I_{10}\right)$, reconstruire une estimation des rendements sur les 190 climats: $\hat{R}\left(p, c_{1}\right), \ldots, \hat{R}\left(p, c_{190}\right)$.

## Reconstruction des 190 rendements (méthode 3)

- Soit $\tilde{R}=\{\overbrace{R\left(p, I_{1}\right), \ldots, R\left(p, I_{1}\right)}^{N_{1}}, \overbrace{R\left(p, I_{2}\right), \ldots, R\left(p, I_{2}\right)}^{N_{2}}, \ldots, R\left(p, l_{10}\right)\}$
- Soit une base $B$ de phenotypes evalués sur les 190 climats :
$\mathcal{B} \in \mathbb{R}^{\|B\|, N}$
- on pose : $\tilde{\mathcal{B}}_{i} \in\{\overbrace{\mathcal{B}\left(i, I_{1}\right), \ldots, \mathcal{B}\left(i, l_{1}\right)}^{N_{1}}, \overbrace{\mathcal{B}\left(i, l_{2}\right), \ldots, \mathcal{B}\left(i, l_{2}\right)}^{N_{2}}, \ldots, \mathcal{B}\left(i, l_{10}\right)\}$
- calcul de résidus : $\epsilon_{i, j}=\mathcal{B}_{i, j}-\tilde{\mathcal{B}}_{i, j}$
- alors $\hat{R}_{j}=\tilde{R}_{j}+\zeta_{j}$
- où $\zeta_{j}$ est une perturbation du rendement pour le climat $j$ dont le signe est donné par les $\epsilon_{i, j}$ et l'ampleur est fonction de la variance intra classe du climat $j$, la variance de $\tilde{R}$ et la variance de $\tilde{\mathcal{B}}$.
remarque : comme base $B$, on peut prendre les 10 pheno utilisés pour la classification pour lesquels on a simulé le rendement sur les 190 climats.


## Reconstruction des 190 rendements

Rendements obtenus pour deux phénotypes:



Noir: distribution exacte

## Méthode d'optimisation :

- Utilisation de deux critères de performance
- Optimisation multicritère NSGA2
- 80 individus
- 80 générations
- 10 climats
- Deux lancements de la méthode d'optimisation
- Analyse post traitement avec 190 climats
- Comparaison avec 1000 phénotypes aléatoires

Pareto sets using 10 random pheno for reconstruction


- Globalement bonne reconstruction de l'espérance et la CVar30 sur les 1000 phénos du LHS
- Mauvaise reconstruction des phéno du front de pareto


## Pareto sets using 10 pheno from previous pareto front



Difference : on utilise le front de Pareto issu du 1er lancement de NSGA-II comme base B pour la reconstruction au lieu de celle des 10 phenos utilisés pour la classification. $\rightarrow$ requiert la simulation exhaustive (sur les 190 climats) des phéno du front de pareto.

## Résultats obtenus

Représentation des caractéristiques des phénotypes présents dans le front de Pareto


## Représentation d'un groupe de phénotypes optimaux

Stratégie prudente


- Période de floraison courte
- Faible capacité d'interception de la lumière (Inclinaison de la plante)
- Eviter les risques hydriques et solaires
$\rightarrow$ CVaR grande
- Sélection d'un sous-ensemble de climats par classification
- Distance "DTW" pour la classification, mise en place d'un algorithme ( $k$-means)
- Différents critères de comparaison retenus :
- Rendement moyen
- "Conditional Value at Risk" à $\alpha \%$ du rendement pour différentes valeurs de $\alpha$
- Résultats satisfaisants dans l'optimisation
- Perspectives :
- Poids pour l'agrégation des distances
- Apprentissage dans l'optimisation (modifications de l'algorithme d'optimisation MO-PSO)

Merci de votre attention

