

**Master Recherche Orsay 2006-2007**

# Fouille de Données et Apprentissage

**Michèle Sebag**

TAO : Thème Apprentissage et Optimisation, Université  
Paris-Sud

<http://tao.lri.fr/>

# Apprentissage relationnel

- Introduction
- Rappels de logique
  - <http://www.cl.cam.ac.uk/Teaching/1998/LogProof>
- Programmation Logique Inductive (ILP)
- Une limite : la transition de phase
- Etude de cas : Apprentissage de lois et programmation génétique

# Motivations

Représentations propositionnelles

90% des applications

Limites :

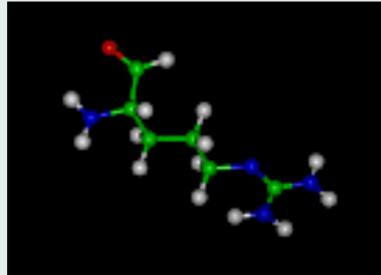
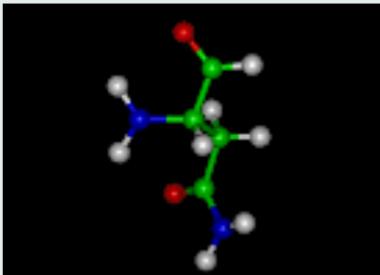
Quand un exemple est formé d'entités semblables en relation

Exemples de domaines :

- Chimie (molécule : atomes en relation)
- Langage naturel (phrase : mots en relation)
- Urbanisme (paysage : bâtiments, routes, ...)

# La frontière propositionnelle / relationnelle

Ne peut-on pas se ramener au problème précédent ?



Représenter la première molécule : facile

atom1 .. atomN	lien 1 – 2 .. lien $i - j$
carbone .. hydrogène	double .. -

Représenter la seconde molécule : ...??

→ Considérer tous les appariements :

atome i (première molécule)  $\leftrightarrow$  atome j (seconde molécule)

Un facteur exponentiel

# Michalski's Trains

1. TRAINS GOING EAST

1.       
2.    
3.    
4.     
5.    

2. TRAINS GOING WEST

1.    
2.    
3.    
4.     
5.    

pb

# Données structurées

Séquences

Bio-info, Fouille de textes, Gestion d'alarmes,..

Arbres

Données XML, fouille du Web,..

Graphes

Chimie

Predictive Toxicology Evaluation

$muta(m) \leftarrow atm(m, m_1, Carb), \dots atm(m, m_K, Hydr),$   
 $bond(m_i, m_j, simple), \dots, bond(m_p, m_q, double)$

Fouille de données multi-relationnelles

CRM

$bonClient(m) \leftarrow transaction(m, m_1), .. transaction(m, m_K)$   
 $client(m), client(m_1), \dots, client(m_K)$

# Apprentissage relationnel

- Introduction
- Rappels de logique  
<http://www.cl.cam.ac.uk/Teaching/1998/LogProof>
- Programmation Logique Inductive
- Apprentissage relationnel et transition de phase
- Etude de cas : Apprentissage de lois et programmation génétique

# Logique

- Enoncés *Black is the color of my true love's hair*
- Interprétation vrai ou faux ?
- Logique relations entre énoncés (consistance, implication)
- Preuve modélisation du raisonnement humain déductif
- Apprentissage raisonnement inductif

# Logique du Premier Ordre

Décrire

Connaissances du domaine

$grandpere(X, Y) \leftarrow pere(X, Z), parent(Z, Y)$

$mutagen(m) \leftarrow atm(m, m_1, carbon, atm(m, m_2, hydr), ..$   
 $bond(m_1, m_2, simple), ...$

Déduire

- Raisonner sur les fonctions et les relations entre entités

$(pere(Jean, Sophie), pere(Sophie, Marc)) \Rightarrow grandpere(Jean, Marc)$

- Raisonner sur les rapports entre tous et quelques uns

$(homme(X) \Rightarrow mortel(X)), homme(Socrate) \Rightarrow mortel(Socrate)$

# Logiques

## Niveaux

- Logique propositionnelle : logique booléenne classique
- Logique relationnelle du premier ordre :  
variables, quantification universelle ou existentielle
- Logiques d'ordres supérieurs :  
raisonnement sur les ensembles et les fonctions  
(applications à la vérification de hardware)
- Logique modale :                  raisonner sur ce qui doit, ou peut, arriver

# Logique du premier ordre, 2

- Fonction  $f$  arité  $n$
- Constante (arité 0)  $m_1, carbon$
- Variable  $X, Y, Z$
- Prédicat, fonction à valeurs dans  $\{V, F\}$   $grandpere, atm, bond$
- Terme  $t$  Variable, constante ou  $f(t_1, \dots, t_n)$
- Atome  $pere(X, Z), atm(m, m_1, carbon)$
- Littéral Atome ou négation d'un atome
- Clause  $L_1 \vee \dots \vee L_n$
- Clause définie : un seul littéral négatif

# représenter $\equiv$ calculer

## Connaissance du domaine

$parent(X, Y) \leftarrow mere(X, Y)$

$parent(X, Y) \leftarrow pere(X, Y)$

$grandparent(X, Y) \leftarrow parent(X, Z), parent(Z, Y)$

### Faits

$pere(Jean, Sophie), pere(Sophie, Marc), \neg mere(Marc, Jean) \dots$

### Interprétation

## Propriétés d'un énoncé

fonction des Interprétations qui le satisfont

- Valide toutes
- Contingent certaines
- Insatisfiable aucune

# représenter $\equiv$ calculer, 2

## Implication logique $\models$

Toute interprétation qui satisfait les prémisses satisfait la conclusion

$$\begin{aligned}\{p\} &\models (p \vee q) \\ \{p\} &\not\models (p \wedge q) \\ \{p, q\} &\models (p \wedge q)\end{aligned}$$

## Règles d'inférence

### Modus Ponens

$$\frac{\phi \Rightarrow \psi}{\phi} \quad \frac{\phi}{\psi}$$

### Double négation

$$\frac{\neg\neg\phi}{\phi}$$

### Modus Tollens

$$\frac{\phi \Rightarrow \psi}{\neg\psi} \quad \frac{\neg\psi}{\neg\phi}$$

### Elimination d'équivalence

$$\frac{\phi \Leftrightarrow \psi}{\begin{array}{c} \phi \Rightarrow \psi \\ \psi \Rightarrow \phi \end{array}}$$

# Règles d'inférence, suite

Règle de résolution

Principe :  $(A \vee B) \wedge (\neg A \vee C) \models (B \vee C)$

Ma montre est arrêtée ou cet homme est mort  
Cet homme est vivant ou je suis Groucho Marx  
-----  
Ma montre est arrêtée ou je suis Groucho Marx

$$\frac{\{A, B_1, \dots, B_n\} \quad \{\neg A, C_1, \dots, C_m\}}{\{B_1, \dots, B_n, C_1, \dots, C_m\}}$$

Cas particuliers

Réduction

$$\frac{\{A\} \quad \{\neg A, B_1, \dots, B_n\}}{\{B_1, \dots, B_n\}}$$

Incohérence

$$\frac{\{A\} \quad \{\neg A\}}{\square}$$

# Logique du premier ordre

## Variables liées et libres

$$\forall X \exists Y p(X, Y), q(Y, Z)$$

## Substitution

Un ensemble fini de remplacement variable/terme

$$\begin{array}{ll} \forall X \textit{homme}(X) \Rightarrow \textit{mortel}(X) \\ (X/\textit{Socrate}) \quad \textit{homme}(\textit{Socrate}) \Rightarrow \textit{mortel}(\textit{Socrate}) \\ (X/\textit{table}) \quad \quad \quad \textit{homme}(\textit{table}) \Rightarrow \textit{mortel}(\textit{table}) \end{array}$$

## Unification

$\theta$  unifie  $t$  et  $t'$  si  $t\theta = t'\theta$

$\theta$  est plus général que  $\theta'$  si  $\theta' = \theta o \sigma$

$mgu(t, t')$  : substitution max. général unifiant  $t$  et  $t'$

$$mgu(t = f(a, X), t' = f(Y, g(Z))) : \theta = \{Y/a, X/g(Z)\}$$

# Substitutions

## Clause

$C \quad \text{mutagen}(X) \leftarrow \text{atm}(X, Y, \text{carbon}), \text{atm}(X, Z, \text{carbon}), \text{atm}(X, T, \text{hydr})$   
 $\quad \quad \quad \text{bond}(Z, T, \text{simple})$

$E \quad \text{mutagen}(m) \leftarrow \text{atm}(m, m_1, \text{carbon}), \text{atm}(m, m_2, \text{carbon}), \text{atm}(m, m_3, \text{carbon})$   
 $\quad \quad \quad \text{atm}(m, m_4, \text{hydr}), \text{bond}(m_1, m_2, \text{simple}), \text{bond}(m_3, m_4, \text{simple})$

## Substitution

$$\theta = \{X/m, Z/m_3, T/m_4\} \quad C\theta \subset E$$

## $\theta$ -subsumption

Plotkin

$$C\theta \subset E : C \models E$$

Rq: plus faible que l'implication logique

# Démonstration – Preuve

Etant donné { expressions }, prouver (expression but)

## Comment faire

Séquence  $S_1, \dots, S_K$  d'application de règles d'inférence telle que

Etape  $i$  :

Prémises : expressions initiales ou

résultats obtenus aux étapes  $1 \dots i - 1$

Etape  $K$  :

Résultat : (expression but)

# Apprentissage relationnel

- Introduction
- Rappels de logique
  - <http://www.cl.cam.ac.uk/Teaching/1998/LogProof>
- Programmation Logique Inductive
- Apprentissage relationnel et transition de phase
- Etude de cas : Apprentissage de lois et programmation génétique

# ILP : Problème posé

## Input

- Exemples  $\mathcal{E}^+, \mathcal{E}^-$
- Théorie du domaine  $\mathcal{B}$
- Espace d'hypothèses  $\mathcal{H}$
- Relation de couverture, implication logique  $\models$

## Propriétés cherchées

- Complétude
- Correction

$$\begin{aligned}\mathcal{B}, h \models e, e \in \mathcal{E}^+ \\ \mathcal{B}, h \not\models e, e \in \mathcal{E}^-\end{aligned}$$

## Formulation faible

- Implication logique indécidable
- Theta-subsumption

Plotkin, 70

# Programmation Logique Inductive

## Les fondamentaux

- Tout est dans la représentation : pas d'appauvrissement !  
molécule  $\notin \mathbb{R}^d$ , (masse, charge, hydrophobicité,..)
- Utilisation rigoureuse de la connaissance du domaine  
déclaratif vs procédural
- Que l'induction soit un mode de programmation  
Le Graal : la synthèse de programme

## Même esprit que Prolog

non pas que le programmeur peine à décrire le **COMMENT** pour que la machine l'exécute aisément  
mais que le programmeur décrive aisément le **QUOI** et que la machine se débrouille pour passer du **QUOI** au **COMMENT**

# Programmation Logique Inductive, 2

## Première époque

1990-1997

- Synthèse automatique de programmes à partir de traces

$$sort(L) \leftarrow list(L, [X, L']), list(L', [Y, L'']), sort([X, Y]), sort(L'')$$

## Cœur algorithmique :

- Espace de recherche : programmes Prolog
- Approches de type Generate & Test
- Critères d'optimisation, Heuristiques d'élagage

## Priorités

- Apprendre avec peu d'exemples
  - Trouver “la” solution
  - Récursivité
- les bons

# PLI, Seconde époque (1995-...)

## Predictive Toxicology Evaluation

- Muggleton-King-Srinivasan, 96-06
- De Raedt-Kramer, 01-05

## Scientific Discovery

- Identification of developmental laws, Dzeroski et al. 97-..
- Identification of behavioral laws, Sebag et al. 96-02

## Priorités

- Résister au bruit des données
- Traiter les informations numériques
- Efficacité algorithmique

# Programmation Logique Inductive deux formulations

## Learning from Interpretation

- $\text{pere}(\text{Jean}, \text{Sophie})$ ,  $\text{mere}(\text{Sophie}, \text{Marc})$ , ...
- $\text{grandpere}(\text{Jean}, \text{Marc})$

## Tables relationnelles

## Learning from Entailment

- $\text{grandpere}(\text{Jean}, \text{Marc}) \leftarrow \text{pere}(\text{Jean}, \text{Sophie}), \text{pere}(\text{Sophie}, \text{Marc})$

# ILP, Algorithmes

## Alg. descendants

top-down



## Alg. descendants

bottom-up

# FOIL

Quinlan 90

- Init :
  - $H = \{\}$
  - $\mathcal{E} = \{\text{ensemble des exemples positifs}\}$
- Tant que  $\mathcal{E}$  n'est pas vide
  - $C : tc(X) \leftarrow Body, Body = true$
  - Jusqu'à ce que  $C$  soit correct
    - \* Spécialiser  $C$
  - $H = H \cup \{C\}$
  - Oter de  $\mathcal{E}$  les exemples couverts par  $C$

# FOIL, suite

Spécialiser  $C : tc(X) \leftarrow Body$



**Critère**  $c(Body \wedge L)$

- pureté  $Pr(+|Body \wedge L)$
  - quantité d'information - pureté log (pureté)
  - gain pureté ( $Body \wedge L$ ) - pureté ( $Body$ )

# Relationnel, ce qui change

Clauses connectées partagent des variables

- $L \in \rho(\text{Body})$  si  $\text{Body} \wedge L$  est connecté

Look ahead la myopie est plus grave

Ex :

$$fume(X) \leftarrow ami(X, Y), fume(Y)$$

Il faut considérer  $L = ami(X, Y)$ , alors qu'il n'apporte aucune information, si on veut pouvoir accéder à  $fume(Y)$

Evaluation plus complexe

$n^-(\text{Body})$  : nombre de substitutions  $\theta$  tq  $\text{Body}\theta$  couvre un négatif prendre en compte

$$\frac{n^-(\text{Body} \wedge L)}{n^-(\text{Body})}$$

# PROGOL

## Principe

Muggleton 95

Inversion de la résolution

- $B$  : connaissance du domaine
  - $E$  : exemples
  - Trouver  $H$  tq  $B, H \models E$
- $$B \not\models E$$
- $$\Rightarrow B, \neg E \models \neg H$$

## Algorithme

- Construire la bottom clause  $\mathcal{B} = B \wedge \neg E$
- se ramener au problème précédent : ne considérer que les spécialisations de *Body* qui généralisent  $\mathcal{B}$

# ILP Applications

## Ecology

- Biological classification of river water quality
- Modelling algal growth in the Lagoon of Venice
- Modelling growth of maximal biomass quantity in the metalimnion of the east basin of the lake of Bled
- Predicting biodegradability of chemical compounds

## Discussion

- Handling numerical knowledge
- + Exploit background knowledge

# ILP Applications, biologie moléculaire

## La mutagenèse

- 230 molecules; circa 40 atoms, 60 bonds.
- Effets de la connaissance du domaine
  - atomes et liens
  - idem + “connaissances” numériques
  - idem + connaissances chimiques (e.g. groupes méthyl)

# ILP Applications, biologie moléculaire, 2

Résonance magnétique nucléaire, spectre de fréquences

## Les diterpènes

- 1503 examples (diterpene molecules)
- 23 target relations (labdan(Molecule), clerodan(Molecule), ...)
- background knowledge

## Comparaisons (10cv)

	FOIL	RIBL	C4.5
red	46.5	86.5	—
prop	70.1	79	78.5
red + prop	78.3	91.2	—

# Fouille de données relationnelles

## Diagnosis-Therapy Index

- Data gathered from a survey of German hospitals.
- multirelational database with 6 relations:
  - hospitals and units [300 tuples]
  - patients [6.000 tuples]
  - diagnoses [25.000 tuples]
  - therapies [43.000 tuples]
  - patient-therapies-days [260.000 tuples]
  - patient-diagnosis-days [250.000 tuples]
- Goal: find groups of patients (therapies, hospitals) with unusual cost or success structure

# Diagnosis-Therapy Index

## Representation

- patient(PatientID,Name,Age,Sex,Outcome,...)
- patient\_diagnosis(PatientID,DiagnosisID,Date,HospitalID)
- patient\_therapy(PatientID,TherapyID,Dosage,Date,HospitalID)
- diagnosis(DiagnosisID,Name,Latin)
- therapy(TherapyID,Name,Duartion,StandardMedification)
- hospital(HospitalID,Name,Location,Size,Owner,Class)

"Patients older than 65 who were diagnosed at a small hospital have an unusually high mortality rate."

$patient(I, N, A, S, O), (A > 65), p_d(I, D, Dt, H), hospital(H, *, *, sr)$

# Fouille de données relationnelles, 2

quand les données ne tiennent pas en mémoire

## Exploration

- Langage : e.g., clauses connectées; suivre les clés
- Target attribute: treatment success (binary, yes or no)
- Reference population: distribution [61%, 31%]
- "Patients older than 65 who were first diagnosed in a small hospital"  
distribution [43%, 57%]

# Apprentissage relationnel

- Introduction
- Rappels de logique
  - <http://www.cl.cam.ac.uk/Teaching/1998/LogProof>
- Programmation Logique Inductive
- Apprentissage relationnel et transition de phase
- Etude de cas : Apprentissage de lois et programmation génétique

# Apprentissage relationnel

Les questions qui fâchent :

- Passage à l'échelle ?
- *Where are the really hard problems ?*

# Problème posé

## Input

- Exemples  $\mathcal{E}^+, \mathcal{E}^-$
- Théorie du domaine  $\mathcal{B}$
- Espace d'hypothèses  $\mathcal{H}$
- Relation de couverture, implication logique  $\models$

## Propriétés cherchées

- Complétude
- Correction

$$\begin{aligned}\mathcal{B}, h \models e, e \in \mathcal{E}^+ \\ \mathcal{B}, h \not\models e, e \in \mathcal{E}^-\end{aligned}$$

## Formulation faible

- Implication logique indécidable
- Theta-subsumption

Plotkin, 70

# Theta-subsumption $\equiv$ Constraint Satisfaction Problem

**$\Theta$ -subsumption** :  $C \prec D$  iff  $\exists \theta / C\theta \subseteq D$

$$C : q_0(X_1, X_2), \quad q_1(X_1, X_3), \quad q_2(X_2, X_3)$$

$$D : q_0(a_2, a_7), \quad q_1(a_3, a_2), \quad q_2(a_1, a_4), \\ q_0(a_3, a_1), \quad q_1(a_7, a_2), \quad q_2(a_7, a_2),$$

..

..

..

**Constraint Satisfaction** : trouver  $\theta$

Contraintes

$$\boxed{q_0(X_1, X_2) \wedge q_1(X_1, X_3) \wedge q_2(X_2, X_3)}$$

Relation  $q_0$  :

$$\{q_0(a_1, a_2), q_0(a_2, a_7), \dots\}$$

Substitution  $\theta$  :

$$\{X_1, \dots, X_n\} \rightarrow \{a_1, \dots, a_L\}$$

Solution  $\theta$ :

$$q_0(\theta(X_1), \theta(X_2)) \in \text{Relation } q_0$$

$$q_1(\theta(X_1), \theta(X_3)) \in \text{Relation } q_1$$

$$q_2(\theta(X_2), \theta(X_3)) \in \text{Relation } q_2$$

## $\Theta$ -subsumption

$$C : \quad p_1(X_1, X_4), p_2(X_1, X_2), p_3(X_2, X_3), \dots \dots p_m(X_2, X_4)$$

$$\theta = (X_1/a_{17}, X_2/a_5, X_3/a_9, X_4/a_{11})$$

$D$	$p_1$	$p_2$	$p_3$	$\dots$	$\dots$	$p_m$
	$a_8, a_{15}$ $\textcolor{red}{a_{17}}, \textcolor{red}{a_{11}}$ $a_{20}, a_{12}$ $\dots$	$a_{21}, a_{10}$ $a_3, a_{16}$ $\textcolor{red}{a_{17}}, \textcolor{red}{a_5}$ $\dots$	$a_5, a_9$ $a_{18}, a_{19}$ $a_{14}, a_{11}$ $\dots$			$a_{14}, a_4$ $a_7, a_{15}$ $\textcolor{red}{a_5}, \textcolor{red}{a_{11}}$ $\dots$

# Transition de phase et CSP

Complexité pire cas : exponentielle

$|\text{search space}| = L^n$   
souvent  $>>$  complexité effective

Paramètres d'ordre CSP

$$p_1 = \frac{2m}{n(n-1)} \quad \text{densité de contraintes}$$

$$p_2 = 1 - \frac{N}{L^2} \quad \text{dureté des contraintes}$$

Transition de phase en CSP

Modèle statistique

Soit  $csp(p_1, p_2)$  une instance de CSP de paramètres  $p_1, p_2$

Satisfiabilité moyenne

$$P_{sol}(p_1, p_2) = Pr(csp(p_1, p_2) \text{ satisfiable})$$

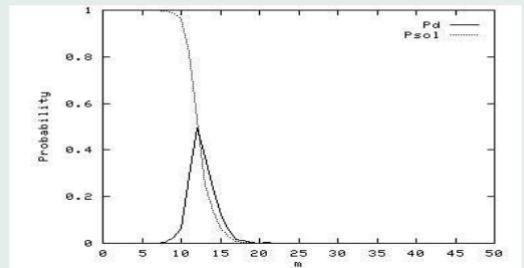
Coût moyen

$$Compl(p_1, p_2) = \mathbb{E}[Complexite(csp(p_1, p_2))]$$

# Transition de phase en CSP

Expérimentalement: Fixer  $p_1$ , varier  $p_2$  de 0 à 1.

$p_2$	$P_{sol}$	$Cot$	Region
petit	$\approx 1$	-	YES
-	$1 \searrow 0$	elevé	PT
grand	$\approx 0$	-	NO



Transition de phase :

Lieu des problèmes difficiles en moyenne.

# $\Theta$ -subsumption : Existence de TP

Giordana Saitta, MLJ 00

Paramètres d'ordre

$n$	nb variables	$N$	nb littéraux
$m$	nb prédictats	$L$	nb constantes

## Protocole

Pour  $n \in [4, 14]$ ,  $m \in [5, 50]$ ,  $N \in [50, 100]$ ,  $L \in [15, 50]$

- Tirer 100 paires  $(C, e)$

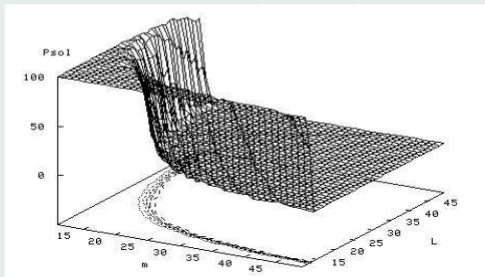
$$C = p_1(x_{1,1}, x_{1,2}), \dots, p_m(x_{m,1}, x_{m,2})$$

$$e = \bigwedge_{k=1}^m p_k(a_{1,1}, a_{1,2}), \dots, p_k(a_{N,1}, a_{N,2})$$

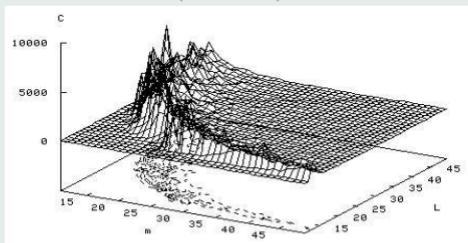
- Mesurer  $P_{sol}(n, m, N, L) = Pr(C \prec e)$

Pour  $n = 10, N = 100$

## Probabilité de couverture( $m, L$ )



## Complexité effective( $m, L$ )



# Observations

Comme attendu :

- Existence d'une région OUI

$C$  trop générale wrt  $e$ ,  $Pr(C \prec e) \approx 1$

- Existence d'une région NON

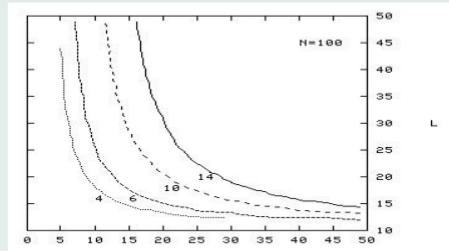
$C$  trop spécifique wrt  $e$ ,  $Pr(C \prec e) \approx 0$

- Existence d'une étroite transition de phase,

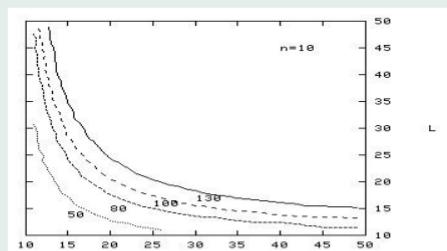
où le coût de la  $\theta$ -subsumption est maximum.

Lieu de la transition de phase,  $P_{sol} = .5$

$n = 4, 6, 10, 14$



$N = 50, 80, 100$



## Conséquences sur l'apprentissage relationnel

Botta et al, 03

## Protocole

1. Problèmes artificiels  $(C, \mathcal{E})$  Régions : OUI, NON, TP
  2. Apprendre  $\hat{C}$  Algs. FOIL, Smart+, GNet
  3. Etude : impact de la position du problème
    - sur la prédiction  $Err(\hat{C})$
    - sur la découverte  $C \neq \hat{C}$
    - sur le coût

# Protocole expérimental

$n = 4$	nb variables	$N = 100$	nb littéraux
$m$	nb prédicts	$L$	nb constantes

Pour  $m \in [5, 50]$ ,  $L \in [15, 50]$

- Construire  $\mathcal{C}$

$$x_{i,j} \in \{x_1, \dots, x_4\}$$

$$p_1(x_{1,1}, x_{1,2}), \dots, p_m(x_{m,1}, x_{m,2})$$

- Construire base d'apprentissage  $\mathcal{E}_L$  et base de test  $\mathcal{E}_T$ :  
200 exemples chaque, 100 positifs, 100 négatifs      (Réparer  $e$  si nécessaire)

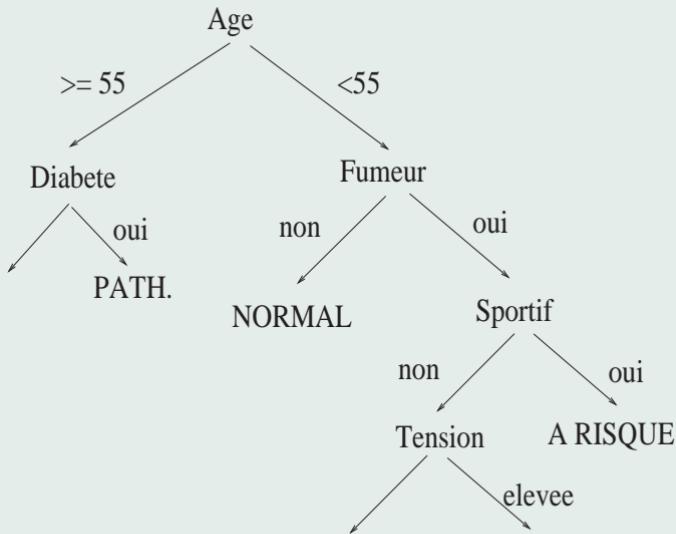
$$e = \bigwedge_{k=1}^m p_k(a_{1,1}, a_{1,2}), \dots, p_k(a_{N,1}, a_{N,2})$$

- $\hat{C} = \text{FOIL } (\mathcal{E}_L)$  : succèsssi

$$|\{e \in \mathcal{E}_T / (C \prec e) \neq (\hat{C} \prec e)\}| < 20\% |\mathcal{E}_T|$$

# FOIL : First Order Inductive Learner

## 1. Arbre de décision



# Decision tree

Breiman et al. 83, Quinlan 79

## Decision Tree

$$X = \mathbb{R}^d$$

- Init:  $T = \perp$ ,  $node = \perp$ ,  $E = \mathcal{E}$ ,  $A = \{1..d\}$
- Recursively, find  $att_i$

$$att_i = Argmax\{\text{Information Gain}(att_j), j \in A\}$$

$$IG(att_i) = \sum_{v_j} Pr(att_i = v_j)IG(att_i = v_j),$$

$$\begin{aligned} \text{with } IG(att_i = v_j) &= -p_{i,j}\log(p_{i,j}) - (1 - p_{i,j})\log(1 - p_{i,j}), \\ p_{i,j} &= Pr(y = +1 | x_i = v_j) \end{aligned}$$

- call Decision Tree

$$\begin{aligned} T &\leftarrow (T \cup (\text{edge}(node, [att_i = v_j])), \\ node &\leftarrow [att_i = v_j], \\ E &\leftarrow E_{att_i=v_j}, \\ A &\leftarrow A - \{i\} \end{aligned}$$

# FOIL : First Order Inductive Learner, 2

Quinlan 86

First step : propositional

- Find  $f(X_1, X_2)$ ,  $f = \text{Argmax}\{IG(q_j), j = 1..m\}$

Following steps

Given  $f(X_1, ..X_k)$ , find  $q_p(X_i, X_j)$  st

- $f(X_1, ..X_k) \wedge q_p(X_i, X_j)$  connected
- $q_p(X_i, X_j) = \text{ArgMax}\{IG(f(X_1, ..X_k) \wedge q(X_t, X_u))\}$

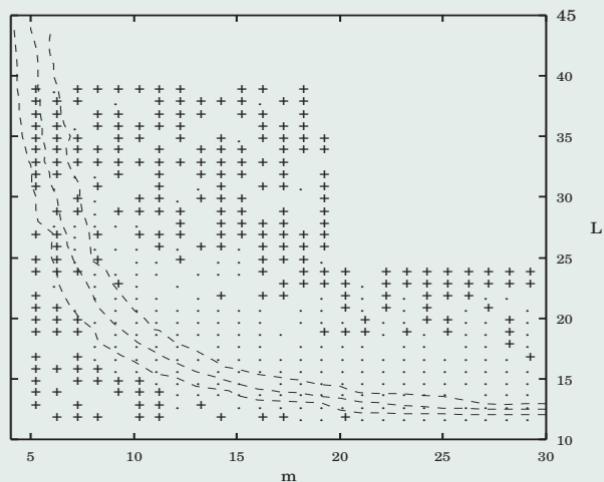
where

$$IG(f \wedge q(X_t, X_u)) = \mathcal{F}(\Theta^+(f), \Theta^+(f \wedge q), \Theta^-(f), \Theta^-(f \wedge q))$$

$$\Theta^+(g) = \{\theta, g\theta \subseteq e, e \in \mathcal{E}^+\}$$

$$\Theta^-(g) = \{\theta, g\theta \subseteq e, e \in \mathcal{E}^-\}$$

# FOIL Competence Map



+ Success ( $> 80\%$  on test set) . Failure

$$n = 4, N = 100$$

# Analyse de la carte de compétence

$\mathcal{C}$	$\hat{\mathcal{C}}$	Performances			Qualité		
$m$	$L$	$K$	$\hat{m}$	<i>train.</i>	<i>test</i>	Exact	%
8	16	1	8	100	100	106.2	O O
10	13	1	14	100	99	144.2	O O
10	16	8	11.75	88	48.5	783.5	N N
11	13	1	11	100	100	92.2	O O
11	15	6	13.5	85	53.5	986.2	N N
12	13	3	14	98.5	83	516.4	N O

**Facile**

F

**Dur**

F

D

**faisable**

$\mathcal{C}$  appartient à la région p.s. satisfiable

15	29	1	6	100	100	185.3	N O	f
15	35	2	6	97.5	84.5	894.6	N O	f
18	35	1	6	100	100	201.0	N O	f
21	18	8	4.13	81.5	58	1394.9	N N	D
25	24	1	6	100	99	135.9	N O	f
29	17	1	12	100	99.5	144.9	N O	f

$\mathcal{C}$  appartient à la région p.s. insatisfiable

6	28	12	8.08	91.5	50.5	815.4	N N	D
7	28	11	7.63	91.5	60.5	1034.2	N N	D
8	27	1	7	100	100	58.8	O O	F
13	26	1	9	100	99	476.8	N O	f
17	14	8	15	93	46	294.6	N N	D
18	16	8	8.87	91	58.5	404.0	N N	D
26	12	3	24.33	80	58	361.4	N N	D

$\mathcal{C}$  appartient à la transition de phase

# 1. Problèmes faciles

$\mathcal{C}$		$\hat{\mathcal{C}}$		Performances		Qualité	
$m$	$L$	$K$	$\hat{m}$	<i>train.</i>	<i>test</i>	Exact	%
8	16	1	8	100	100	O	O
10	13	1	14	100	99	O	O
11	13	1	11	100	100	O	O

$\mathcal{C}$  appartient à la région p.s. satisfiable

8	27	1	7	100	100	58.8	O	O
---	----	---	---	-----	-----	------	---	---

$\mathcal{C}$  appartient à la transition de phase

## Problèmes faciles

- Région satisfiable
- Concept cible petit

## 2. Problèmes faisables

$\mathcal{C}$		$\hat{\mathcal{C}}$		Performances		Qualité	
$m$	$L$	$K$	$\hat{m}$	<i>train.</i>	<i>test</i>	CPU	Exact %
12	13	3	14	98.5	83	516.4	N O

$\mathcal{C}$  appartient à la région p.s. satisfiable

15	29	1	6	100	100	185.3	N	O
15	35	2	6	97.5	84.5	894.6	N	O
18	35	1	6	100	100	201.0	N	O
25	24	1	6	100	99	135.9	N	O
29	17	1	12	100	99.5	144.9	N	O

$\mathcal{C}$  appartient à la région p.s. insatisfiable

13	26	1	9	100	99	476.8	N	O
----	----	---	---	-----	----	-------	---	---

$\mathcal{C}$  appartient à la transition de phase

### Problèmes faisables

- Du bon côté de la TP
- Dans la région insatisfiable, très loin de la TP.

### 3. Problèmes difficiles

$\mathcal{C}$		$\bar{\mathcal{C}}$		Performances			Qualité	
$m$	$L$	$K$	$\hat{m}$	<i>train.</i>	<i>test</i>	CPU	Exact	%
10	16	8	11.75	88	48.5	783.5	N	N
11	15	6	13.5	85	53.5	986.2	N	N

$\mathcal{C}$  appartient à la région p.s. satisfiable

21	18	8	4.13	81.5	58	1394.9	N	N
----	----	---	------	------	----	--------	---	---

$\mathcal{C}$  appartient à la région p.s. insatisfiable

6	28	12	8.08	91.5	50.5	815.4	N	N
7	28	11	7.63	91.5	60.5	1034.2	N	N
17	14	8	15	93	46	294.6	N	N
18	16	8	8.87	91	58.5	404.0	N	N
26	12	3	24.33	80	58	361.4	N	N

$\mathcal{C}$  appartient à la transition de phase

#### Problèmes durs

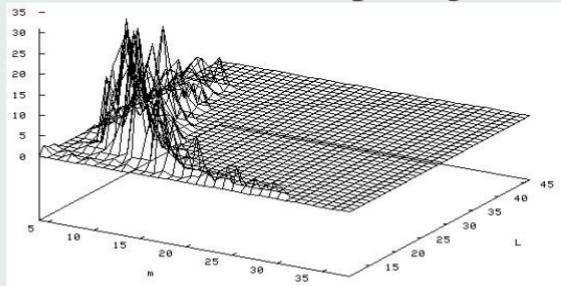
- Grands concepts cibles
- Proches de la TP.

# 1. La TP est un attracteur de la PLI

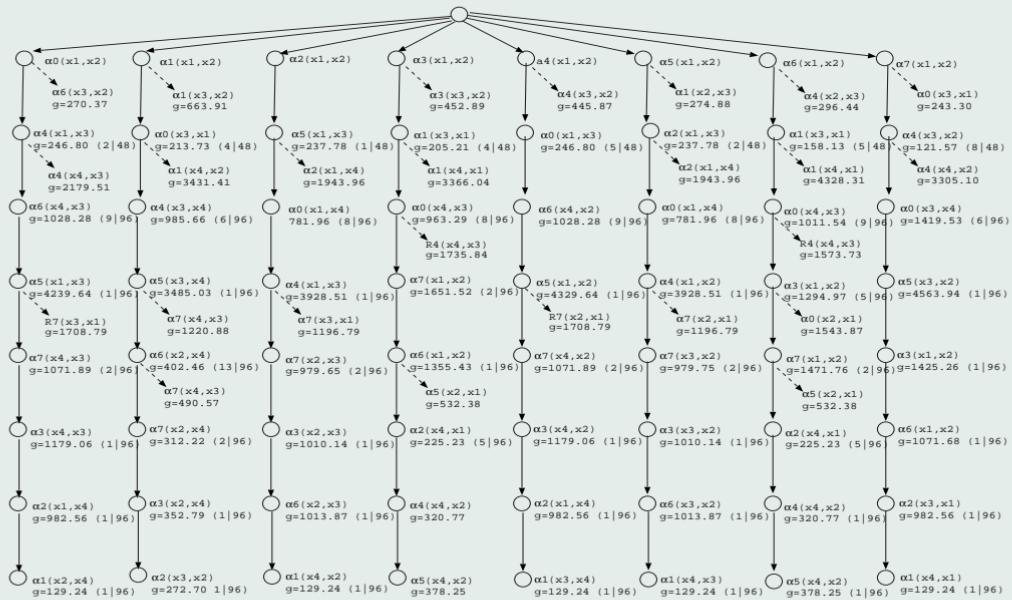
Les hypothèses retenues sont dans la TP  
que le concept cible y soit ou non.

A posteriori, pas étonnant.

...Jette un doute sur le passage à l'échelle de la PLI...



## 2. La zone aveugle de la PLI



# Pourquoi plus complexe $\not\Rightarrow$ plus difficile ?

## I. Bonnes approximations

Soit  $C$  ds la région non satisfiable,

Soit  $G \prec C$

$G$  complet par construction

$G$  appartient à la TP (versant insatisfiable),  $G$  p.s. correct

$\Rightarrow G$  bonne approximation

## II. Probabilité de les trouver

$\# \{G / G \prec C, G \in TP\}$  exponentiel en la taille de  $C$ .

# Apprentissage relationnel

- Introduction
- Rappels de logique
  - <http://www.cl.cam.ac.uk/Teaching/1998/LogProof>
- Programmation Logique Inductive
- Apprentissage relationnel et transition de phase
- Etude de cas : Apprentissage de lois et programmation génétique

# Exemple

	<i>Battery</i>	<i>Wire</i>	<i>I</i>	<i>C</i>	<i>I/C</i>
$e_1$	$A$	$X$	3.4763	3.4763	1.0000
$e_2$	$A$	$Y$	4.8763	4.8763	1.0000
$e_3$	$A$	$Z$	3.0590	3.0590	1.0000
$e_4$	$B$	$X$	3.9781	3.4763	1.1444
$e_5$	$B$	$Y$	5.5803	4.8763	1.1444
$e_6$	$B$	$Z$	3.5007	3.0590	1.1444
$e_7$	$C$	$X$	5.5629	3.4763	1.6003
$e_8$	$C$	$Y$	7.8034	4.8763	1.6003
$e_9$	$C$	$Z$	4.8952	3.0590	1.6003

**But : Inférer des lois physiques (chimiques,..)**

$$U = RI$$

# **Identification of macro-mechanical models**

coll. M. Schoenauer (CMAP), and H. Maitournan (LMS)

## **Behavioral law of materials**

- needed for accurate CAD;
- ill-known for new materials (e.g. polymers).

## **Art of macro-mechanical modeling:**

- Adapting the model of another material;
- Designing a brand new model;
- Starting with a micro-mechanical analysis.

## **Fails when the current material:**

- does not resemble other materials;
- does not fit expert's guesses;
- is not provided a tractable model by  $\mu$ -M analysis.

# Machine Discovery

- **First Era (1983)**

Langley, Falkenhainer, Nordhausen,...

Heavy assumptions

Heuristic construction of new terms

$PV$ ,  $PV/T$ ,  $PV/nT$ ,..

- **Second Era (1995)**

Dzeroski, Valdes-Perez,...

Exhaustive exploration

Challenge : restricting the search space

- **On the ILP side**

Srinivasan, Camacho, Simon, Frisch,...

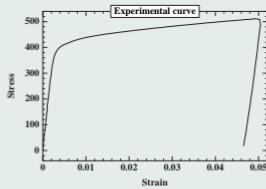
Fixed equations

Parametric optimization

# Dilemma

- **Strong background knowledge**  
→ exhaustive exploration is feasible
- **Reasonable background knowledge**  
+ smart optimization criterion  
= greedy search
- **“Light” background knowledge**  
+ stochastic search  
= global optimization

# Identification of Behavioral Laws



## Input: Experimental curves

- observed strain  $\epsilon(t)$  for applied stress  $\sigma(t)$ ;
- observed stress  $\sigma(t)$  for applied strain  $\epsilon(t)$ ;

## Identification of Behavioral Laws, 2

### Output: Behavioral law

Differential equations linking  $\epsilon(t)$ ,  $\sigma(t)$  and their derivatives, e.g.

$$\begin{array}{ll} \text{if} & \sigma(t) < \sigma_1 \quad \text{then } \sigma(t) = a.\epsilon(t) + b.\dot{\epsilon}(t) \\ \text{else if} & \sigma(t) < \sigma_2 \quad \text{then } \sigma(t) = c.\epsilon(t) + d.\dot{\epsilon}(t) \end{array}$$

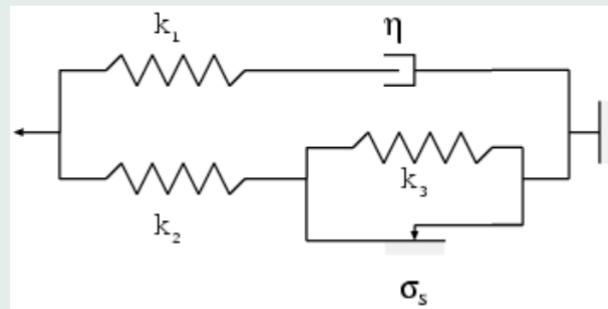
**Criteria:** the law must fit the experiments **and** be comprehensible.

# Search space: Rheological models

## Dynamic 1-D laws.

Assembly in series or parallel of

- springs (elastic behavior)
- sliders (plastic behavior)
- dashpots (viscous behavior)



## Identification Goals:

- For a given model, adjust the parameters  
     $\implies$  **Parametric optimization**
- Optimize both the model and the parameters  
     $\implies$  **Non-parametric optimization**

# Programmation génétique

J. Koza – 1992

$$\mathcal{F} : \Omega \mapsto \mathbb{R} \quad \text{Trouver } \operatorname{argmax} (\mathcal{F})$$

**Le rêve : Le programme qui écrit le programme**

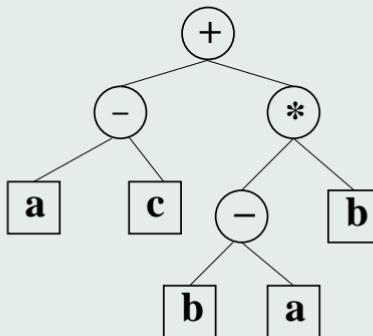
$\Omega$  = espace de programmes

$\mathcal{F}$  = qualité d'un programme

S-expressions :

$\mathcal{T} = \{ \text{Vars, Cstes} \}$

$\mathcal{N} = \{ \text{opérateurs} \}$



# Quelques applications

- Classification
- Régression symbolique
- Prédiction séries chaotiques
- Stratégies multi-agents (e.g. jeux, ...)
- Robotique
- Génération de plans
- Conception de circuits analogiques
- Apprentissage de réseaux neuronaux
- Modélisation mécanique

# Concepts

GP = rejeton de GAs

**Traits distinctifs :** matériel génétique

structuré (souvent sous forme d'arbre)  
de taille variable (bornée)  
souvent exécutable

**Historique :**

**Représentation:** Langage LISP

**Publications:** Cramer 85, Koza 89, Koza 92, Koza 94

**Remarque :**

pas d'alternative en optimisation classique

# Espaces d'arbres

Etant donné :

Un ensemble  $\mathcal{N}$  de noeuds (ou opérateurs)

Un ensemble  $\mathcal{T}$  de feuilles (ou opérandes)

$$\Omega = \text{Arbres}(\mathcal{N}, \mathcal{T})$$

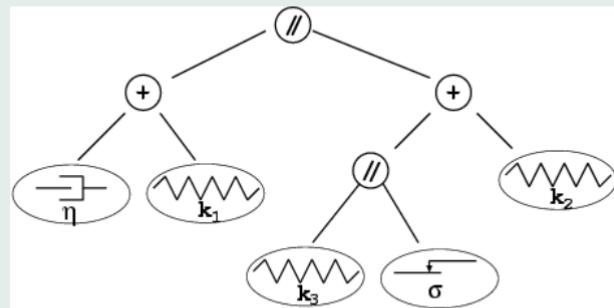
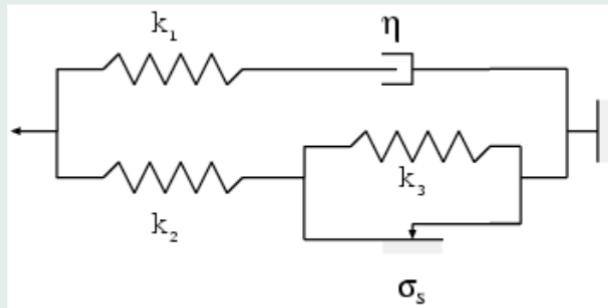
Exemples :

- $$\begin{cases} \mathcal{N} = \{+, \times\} \\ \mathcal{T} = \{X, \mathcal{R}\} \\ \Omega = \text{Polynomes de } X. \end{cases}$$
- $$\begin{cases} \mathcal{N} = \{ \text{ if-then-else, while-do, repeat-until,.. } \} \\ \mathcal{T} = \{ \text{expressions, instructions} \} \\ \Omega = \text{Programmes} \end{cases}$$

# Rheological GP

Rheological models  $\equiv$  Trees built from

- $\mathcal{N} = \{ \text{series } +, \text{parallel } // \}$
- $\mathcal{T} = \{ \text{Spring}(k), \text{Slider}(\sigma_S), \text{Dashpot}(\eta) \}$



# Initialisation

Creer Arbre:

    Choisir Noeud dans { +, //, ressort, patin, amort }

    Si Noeud dans { ressort, patin, amortisseur }

        Tirer Constante  $k, \sigma_S, \eta$  dans  $\mathbb{R}^+$

        Retour (Noeud, constante)

    Si Noeud dans { +, // }

        Fils<sub>1</sub> = Creer Arbre

        Fils<sub>2</sub> = Creer Arbre

        Retour (Noeud, Fils<sub>1</sub>, Fils<sub>2</sub>)

# Evaluation

## Compilation

$$H \rightarrow \text{Système d'équations } \mathcal{S}_H$$

- Ressort( $k$ )  $\sigma(t) = k \cdot \varepsilon(t)$
- Amortisseur( $\eta$ )  $\sigma(t) = \eta \cdot \dot{\varepsilon}(t)$
- Patin( $\sigma_S$ )  $(\dot{\varepsilon}(t) = 0) \text{ OR } (|\sigma(t)| = \sigma_S)$
- Série  $\varepsilon_{parent}(t) = \varepsilon_{fils_1}(t) + \varepsilon_{fils_2}(t)$   
 $\sigma_{parent}(t) = \sigma_{fils_1}(t) = \sigma_{fils_2}(t)$
- Parallèle  $\varepsilon_{parent}(t) = \varepsilon_{fils_1}(t) = \varepsilon_{fils_2}(t)$   
 $\sigma_{parent}(t) = \sigma_{fils_1}(t) + \sigma_{fils_2}(t)$

## Simulation

$$\mathcal{S}_H \cup (\varepsilon_H(t) = \varepsilon_{exp}(t)) \rightarrow \sigma_H(t)$$

## Evaluation

$$f(H) = Distance(\sigma_H, \sigma_{exp})$$

# Critère d'arrêt

## Sources d'erreur

- ED → Différences finies
- Erreurs expérimentales
- Bruit de résolution

## Estimation de l'erreur

$$Err = ||\sigma_H(t_{exp} = t_1, t_2, t_3, \dots) - \sigma_H(t_{exp} = t_1, t_3, t_5, \dots)||$$

## Critère de succès

$$f(H) \approx Err$$

# Conclusion partielle

- **Identification de modèle rhéologique par GP**

Premiers résultats positifs.

Passage à l'échelle difficile.

- **C'est un cas favorable :**

Tout élément de l'espace de recherche est acceptable...

# GP and Background Knowledge

- **EC: same evolution as AI**

- I. A universal tool

- 1965

- II. Knowledge makes the difference

- 1991

- **GP: the closure assumption**

- any subtree is a valid operand

- for any operator.

Pros simple crossover

simple mutation

Cons Search space size

# GP and Background Knowledge, 2

- Syntactic constraints

Gruau 96, Keijzer Babovic 99

- Strongly typed GP

Montana 97

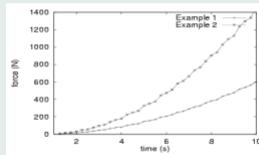
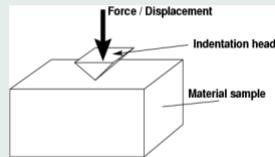
- BNF Grammars

Horner 96, Ryan et al. 98

# Dimension aware GP

## The mechanical problem

Indentation experiments on unknown material



**Goal:** Find expression  $\mathcal{F}$  s.t.

$$\text{Force} = \mathcal{F}(\text{displacement, time, material parameters})$$

# GP and Machine Discovery

## Trivial BK: Dimension-consistency

meters + seconds ? Oups !

### Assumption:

finite set of units       $\{m, s, kg\}$   
compound units       $U_{ijk} : m^i s^j kg^k$   
limited combinations       $i, j, k \in [-2, 2]$

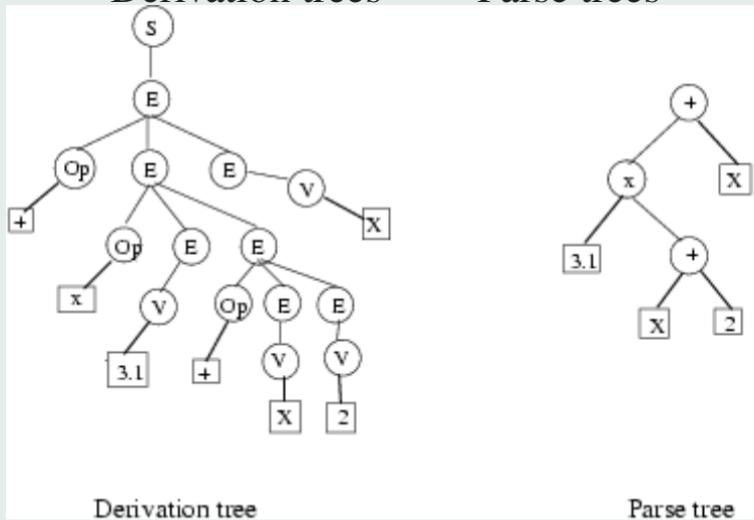
## Representation: BNF grammars

$S$	start symbol	$U_{1,-2,1}$
$N$	non-terminals	$\{U_{ijk}\}$
$T$	terminals	$\{Vars, \mathcal{R}, +, -, *, /, exp\}$
$P$	production rules	

$$U_{ijk} := U_{ijk} + U_{ijk} \mid U_{ijk} - U_{ijk} \mid U_{ijk} \exp^{U_{000}} \\ \mid abc+def=ijk \quad U_{abc} * U_{def} \\ \mid abc-def=ijk \quad U_{abc} / U_{def} \\ \mid unit(var)=ijk \quad Var$$

# Enforcing constraints through grammars

Derivation trees → Parse trees



Beware !

Terminals

Non-Terminals

CFG

variables, constants, operators  
typed expressions

GP

variables and constants  
operators

# GP on derivation trees – Gruau 96

- **Initialization:** uniform selection among derivations in a production rule

filter out trees with depth  $> D_{max}$

- **Crossover:** swap nodes with same non-terminal symbol
  - ≡ Strongly Type Genetic Programming
  - Montana 1995, Haynes et al. 1996

- **Mutation:** select another derivation

# Dimension grammar

Physical units			
Quantity	mass	length	time
<i>Variables</i>			
$K$ (Elastic element)	+1	0	-1
$n$ (Viscous element)	+1	0	-1
$t$ (time)	0	0	+1
$u$ (displacement)	0	1	0
<i>Solution</i>			
$F$ (Force)	1	1	-2

# Automatic generation of the grammar

$N$	non-terminals	$\{U_{ijk}\}$
$T$	terminals	$\{Vars, \mathcal{R}, +, -, *, /, exp\}$
$P$	production rules	

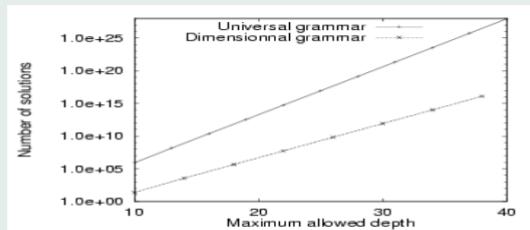
$$U_{ijk} := \begin{array}{l} U_{ijk} + U_{ijk} \mid U_{ijk} - U_{ijk} \mid U_{ijk} \exp^{U_{000}} \\ \mid abc+def=ijk U_{abc} * U_{def} \\ \mid abc-def=ijk U_{abc} / U_{def} \\ \mid unit(var)=ijk Var \end{array}$$

$$\mathcal{F} := \text{mass} \times \text{length} \times \text{time}^{-2}$$

## Automatically generated

# First Results

## Reduction of the search space



## Poor performances

Uniform initialization:  $\mathcal{P}(\text{non-terminal}) \gg \mathcal{P}(\text{terminal})$

...blamed on Initialization

deep trees, most are filtered out

**Note** : Similar to constrained optimization with sparse feasible region

Ryan et al, 1998

Poor initial population → poor performances

# Initialization in Grammar Guided GP

## Biased initialization fails

- Set  $\mathcal{P}(\text{terminals}) \gg \mathcal{P}(\text{non-terminals})$
- Population poorly diversified, premature convergence

## Constraint resolution for initialization

- Minimal tree depth for each non-terminal or derivation
  - On-line filtering out of derivations
    - incompatible with maximum depth
  - GP initialization = constraint solver
- Diversified initial population within depth  $D_{Max}$

# Constrained Initialization for Grammar-Guided GP

- Compute  $d_{min}(U)$  =  $U$  minimal depth

$$\begin{aligned} U &:= deriv_1 \mid \dots \mid deriv_N \\ d_{min}(U) &= \min_i d_{min}(deriv_i) \\ d_{min}(U_1 \ op \ U_2) &= 1 + \max(d_{min}(U_1), d_{min}(U_2)) \end{aligned}$$

# Constrained Initialization, 2

- **Construct  $Exp$  with maximal depth  $D_{Max}$**

$Exp = S; \quad d_{max}(S) = D_{Max}$

While (exists non terminal symbols in  $Exp$ )

    Select  $U$  in  $Exp \quad U = |_i deriv_i$

    Select  $deriv_i / d_{min}(deriv_i) \leq d_{max}(U)$

$deriv_i = U_1 \ op \ U_2$

    Set  $d_{max}(U_1) = d_{max}(U_2) = d_{max}(U) - 1$

- **Result:**

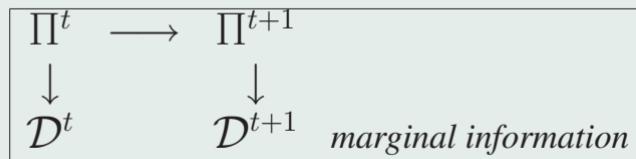
**admissible and diversified** individuals

# Can we learn more ?

**Populations  $\Pi$   $\longleftrightarrow$  Distributions  $\mathcal{D}$**

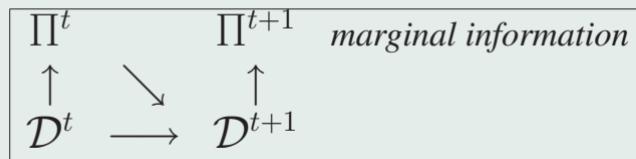
Evolutionary Computation

works in extension



An AI approach: PBIL      Baluja 1995

works in intension



# Probabilistic Grammar-Guided GP

**Principle:** Setting weights on each derivation

Scal:

$$\text{deriv}_i \rightarrow w(\text{deriv}_i)$$

Vect:

$$\text{deriv}_i \times \text{depth } k \rightarrow w(\text{deriv}_i, k)$$

Salustowicz & Schmidhuber, 1998

## Initializing Distribution

$$\forall i, \forall k, w(\text{deriv}_i, k) = 1$$

## Generating Individuals

for  $U$  at depth  $k$ , if  $d_{\min}(\text{deriv}_i) \leq d_{\max}(U)$

$$\text{Prob(Select deriv}_i) \propto w(\text{deriv}_i, k)$$

# Probabilistic Grammar-Guided GP, 2

## Updating Distribution

Loop on the best individuals

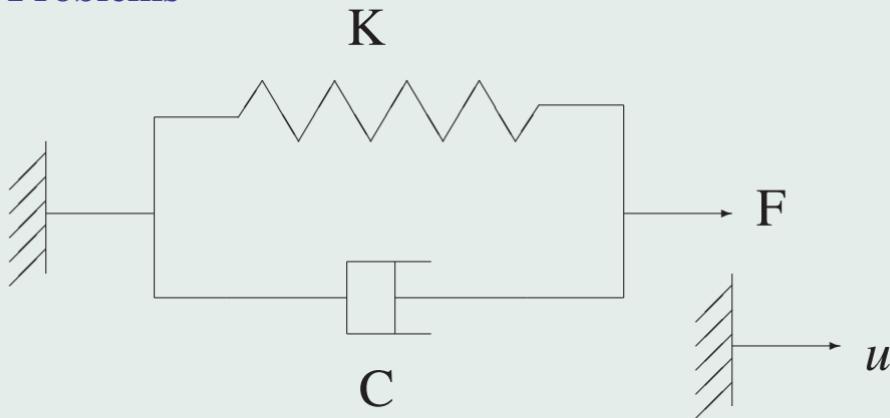
if  $deriv_i$  is chosen at depth  $k$   
 $w(deriv_i, k) * = (1 + \epsilon)$

Loop on the worst individuals

if  $deriv_i$  is chosen at depth  $k$   
 $w(deriv_i, k) * = (1 - \epsilon)$

# Empirical Validation

## Problems



$$x(t) = \frac{F}{K} \left( 1 - e^{\frac{-Kt}{C}} \right) \quad (1)$$

$$x(t) = \frac{F}{K_1} + \frac{Ft}{C_1} + \frac{F}{K_2} \left( 1 - e^{\frac{-Kt}{C_2}} \right) \quad (2)$$

# Empirical Validation, 2

## Grammars

Universal  $S := NT$

$NT := T \mid OP\ NT\ NT$

$OP := + \mid - \mid * \mid \div \mid exp$

$T := F \mid K \mid C \mid t \mid 1 \mid 2 \mid 3 \mid 4$

Universal + exp-neg: same as above, except

$OP := + \mid - \mid * \mid \div \mid exp \mid exp-$

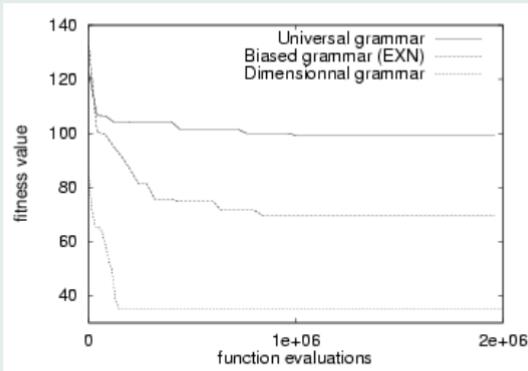
Dimensional: dimension-consistent grammar

Physical units			
Quantity	mass	length	time
<i>Variables</i>			
$E$ (Force)	+1	+1	-2
$K$ (Elastic element)	+1	0	-1
$n$ (Viscous element)	+1	0	-1
$t$ (time)	0	0	+1
<i>Solution</i>			
$x$ (displacement)	0	+1	0

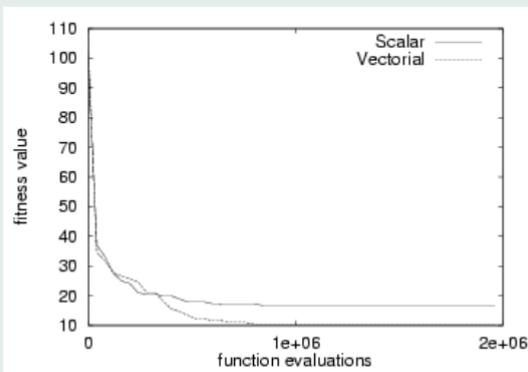
# Empirical Validation, Parameters

Parameter	Value	
Algorithm	GP	GPwPG
Population size	2000	500
Max. number of generations	1000	4000
Probability of Crossover	0.8	—
Probability of tree mutation	0.2	—
Probability of point mutation	0.8	—
Nb of best individuals for learning	—	2
Nb of worst individuals for learning	—	2
Learning rate ( $\epsilon$ )	—	0.001
Probability of perturbation	—	0.001
Amplitude of perturbation	—	0.001
Number of training examples	20	20
Number of independent runs	10	20

# Results



Convergence: Impact of grammars



Convergence: Impact of learning distributions

# Philosophie générale

Pour l'homme qui a un marteau, tout ressemble à un clou...

**Ne pas avoir d'algorithme favori**

Le meilleur algorithme dépend du problème

**Entre science et technologie**

ne pas faire l'autruche

mais

réaliser la difficulté des résultats négatifs

**Regarder au dehors**

Vos voisins de labo ont souvent des problèmes voisins  
et des façons différentes de les regarder...

**Valider**

Théoriquement \*et\* pratiquement