

Introduction au Meta-Learning

Séminaire TALia

Jean Vassoyan

ONEPOINT & TELECOM PARIS

September 16, 2022

Table of Contents


- 1 Introduction
- 2 Non-Parametric Meta-Learning
- 3 Black-Box Meta-Learning
- 4 Optimization-Based Meta-Learning

Table of Contents

- 1 Introduction
- 2 Non-Parametric Meta-Learning
- 3 Black-Box Meta-Learning
- 4 Optimization-Based Meta-Learning

Pourquoi le Meta-Learning ?

- On veut construire un modèle **généraliste**
- Approche classique : Transfer Learning



- Défauts :
 - Nécessite dataset de grande taille pour chaque *downstream task*
 - Faible capacité de généralisation "out-of-distribution"
 - Les humains apprennent avec peu d'exemples

Objectif du Meta-Learning

Objectif : créer un modèle capable de s'adapter **rapidement** à de nouvelles tâches (pas vues à l'entraînement)

rapidement = peu d'exemples par classe

(*few-shot learning, one-shot learning, zero-shot learning*)

Objectif du Meta-Learning

Objectif : créer un modèle capable de s'adapter **rapidement** à de nouvelles tâches (pas vues à l'entraînement)

rapidement = peu d'exemples par classe
(*few-shot learning, one-shot learning, zero-shot learning*)

→ Comment prépare-t-on un modèle à effectuer des tâches auxquelles il n'a jamais été confronté ?

Le problème de Meta-Learning

Tache T_1
races de chats



Tache T_2
races de chiens



⋮

⋮


Tache T_{N+1}
races de lapins



⋮

⋮

Le problème de Meta-Learning



Le problème de Meta-Learning

Objectif :


Etant donné un ensemble de tâches $\mathcal{T}_1, \dots, \mathcal{T}_n$, résoudre rapidement la nouvelle tâche $\mathcal{T}_{\text{test}}$.

Les tâches $\mathcal{T}_i = \{\mathcal{D}_i^{\text{tr}}, \mathcal{D}_i^{\text{test}}, \mathcal{L}_i\}$ sont i.i.d. et tirées suivant une même distribution $p(\mathcal{T})$

→ Ne fonctionne que si toutes ces tâches partagent une structure géométrique commune !


Le problème de Meta-Learning

Supervised Learning:



Data: $\{(\mathbf{x}, \mathbf{y})_i\}$

Meta Supervised Learning:



Data: $\{\mathcal{D}_i\}$

$\mathcal{D}_i : \{(\mathbf{x}, \mathbf{y})_j\}$

Finn. *Learning to Learn with Gradients*. PhD Thesis. 2018

Fonction objectif :


$$\min_{\theta} \sum_{\mathcal{T}_i \sim p(\mathcal{T})} \sum_{(x, y) \sim \mathcal{D}_i^{\text{ts}}} \mathcal{L}_i(f_{\theta}(\mathcal{D}_i^{\text{tr}}, x), y)$$

Table of Contents



- 1 Introduction
- 2 Non-Parametric Meta-Learning**
- 3 Black-Box Meta-Learning
- 4 Optimization-Based Meta-Learning

Non-Parametric Meta-Learning


Idée : Apprendre à comparer les éléments de $\mathcal{D}_i^{\text{ts}}$ à ceux de $\mathcal{D}_i^{\text{tr}}$



Non-Parametric Meta-Learning




(a) Koch et al., ICML 2015



(b) Vinyals et al., NeurIPS 2016

Non-Parametric Meta-Learning : Matching Networks



1. Sample task \mathcal{T}_i
2. Sample disjoint datasets \mathcal{D}_i^{tr} , \mathcal{D}_i^{ts} from \mathcal{D}_i
3. Compute $\hat{y}^{ts} = \sum_{x_k, y_k \in \mathcal{D}_i^{tr}} f_\theta(x^{ts}, x_k) y_k$
4. Update θ using $\nabla_\theta \mathcal{L}(\hat{y}^{ts}, y^{ts})$

Non-Parametric Meta-Learning : Avantages / Inconvénients

Points forts :

- Généralement très expressive
- Rapide et facile à optimiser

Points faibles :

- Difficile à généraliser sur des tailles de $\mathcal{D}_i^{\text{tr}}$ variables
- Peu scalable sur les $\mathcal{D}_i^{\text{tr}}$ de grandes tailles
- Approche limitée à la classification

Table of Contents

- 1 Introduction
- 2 Non-Parametric Meta-Learning
- 3 Black-Box Meta-Learning**
- 4 Optimization-Based Meta-Learning

Black-Box Meta-Learning (BBML)

Objectif

Entraîner un réseau de neurones f_θ à prédire les paramètres ϕ_i d'un autre réseau de neurones g_{ϕ_i} selon la tâche \mathcal{T}_i .

Black-Box Meta-Learning (BBML)

Objectif

Entraîner un réseau de neurones f_θ à prédire les paramètres ϕ_i d'un autre réseau de neurones g_{ϕ_i} selon la tâche \mathcal{T}_i .

$$f_\theta: \mathcal{D}_i^{\text{tr}} \mapsto \phi_i$$

$$g_{\phi_i}: \mathbf{x}^{\text{ts}} \mapsto \mathbf{y}^{\text{ts}}$$


Black-Box Meta-Learning (BBML)

Objectif


Entraîner un réseau de neurones f_θ à prédire les paramètres ϕ_i d'un autre réseau de neurones g_{ϕ_i} selon la tâche \mathcal{T}_i .

$$f_\theta: \mathcal{D}_i^{\text{tr}} \mapsto \phi_i$$

$$g_{\phi_i}: \mathbf{x}^{\text{ts}} \mapsto \mathbf{y}^{\text{ts}}$$




BBML : Algorithme Général




1. Sample task \mathcal{T}_i (or mini batch of tasks)
2. Sample disjoint datasets $\mathcal{D}_i^{tr}, \mathcal{D}_i^{test}$ from \mathcal{D}_i
3. Compute $\phi_i \leftarrow f_{\theta}(\mathcal{D}_i^{tr})$
4. Update θ using $\nabla_{\theta} \mathcal{L}(g_{\phi_i}, \mathcal{D}_i^{test})$

En pratique

- Prédire tous les paramètres d'un réseau de neurones ne serait pas très scalable !
- En pratique : prédire seulement une représentation suffisante de \mathcal{T}_i



Meta-Learning with Memory-Augmented Neural Networks
Santoro, Bartunov, Botvinick, Wierstra, Lillicrap. ICML '16



Conditional Neural Processes. Garnelo, Rosenbaum, Maddison,
Ramalho, Saxton, Shanahan, Teh, Rezende, Eslami. ICML '18

Exemple : GPT-3

Language Models are Few-Shot Learners

Tom B. Brown*	Benjamin Mann*	Nick Ryder*	Melanie Subbiah*	
Jared Kaplan [†]	Prafulla Dhariwal	Arvind Neelakantan	Pranav Shyam	Girish Sastry
Amanda Askell	Sandhini Agarwal	Ariel Herbert-Voss	Gretchen Krueger	Tom Henighan
Rewon Child	Aditya Ramesh	Daniel M. Ziegler	Jeffrey Wu	Clemens Winter
Christopher Hesse	Mark Chen	Eric Sigler	Mateusz Litwin	Scott Gray
Benjamin Chess	Jack Clark	Christopher Berner		
Sam McCandlish	Alec Radford	Ilya Sutskever	Dario Amodei	

OpenAI

Exemple : GPT-3

- Grande diversité de tâches :
 - corrections orthographiques
 - traduction
 - problèmes de maths simples
 - ...
- $\mathcal{D}_i^{\text{tr}}$: séquence de caractères (servant d'exemples)
- $\mathcal{D}_i^{\text{ts}}$: suite de la séquence



Black-Box Meta-Learning : avantages / inconvénients

Points forts :

- Très expressif
- Compatible avec une grande variété de problèmes (régression, classification, RL)

Points faibles :

- Taches complexes \Rightarrow modèles complexes : problème d'optimisation difficile
- Souvent *data-inefficient*

Table of Contents

- 1 Introduction
- 2 Non-Parametric Meta-Learning
- 3 Black-Box Meta-Learning
- 4 Optimization-Based Meta-Learning**

Optimization-Based Meta-Learning

- Idée : intégrer le fine-tuning au processus de meta-learning
→ on optimise les paramètres du modèle de manière à anticiper les futurs fine-tuning !
- Principal représentant : MAML

Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks

Chelsea Finn¹ Pieter Abbeel^{1,2} Sergey Levine¹

Objectif du MAML

Fine-tuning pour la tache \mathcal{T}_i :

$$\theta \leftarrow \theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})$$

Objectif du MAML

Fine-tuning pour la tâche \mathcal{T}_i :

$$\theta \leftarrow \theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})$$

Objectif : trouver le θ tel que :

$$\min_{\theta} \sum_{\mathcal{T}_i \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_i} \left(f_{\theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})} \right)$$

Objectif du MAML

Fine-tuning pour la tâche \mathcal{T}_i :

$$\theta \leftarrow \theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})$$

Objectif : trouver le θ tel que :


$$\min_{\theta} \sum_{\mathcal{T}_i \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_i} \left(f_{\theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})} \right)$$

Meta-optimisation sur toutes les tâches $\mathcal{T}_i \sim p(\mathcal{T})$:

$$\theta \leftarrow \theta - \beta \nabla_{\theta} \sum_{\mathcal{T}_i \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_i} \left(f_{\theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})} \right)$$

→ Implique un gradient à travers un gradient ! (produits vectoriels hessiens)

MAML : intuition



Algorithme MAML

Algorithm 1 Model-Agnostic Meta-Learning

Require: $p(\mathcal{T})$: distribution over tasks

Require: α, β : step size hyperparameters

- 1: randomly initialize θ
 - 2: **while** not done **do**
 - 3: Sample batch of tasks $\mathcal{T}_i \sim p(\mathcal{T})$
 - 4: **for all** \mathcal{T}_i **do**
 - 5: Evaluate $\nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})$ with respect to K examples
 - 6: Compute adapted parameters with gradient descent: $\theta'_i = \theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})$
 - 7: **end for**
 - 8: Update $\theta \leftarrow \theta - \beta \nabla_{\theta} \sum_{\mathcal{T}_i \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_i}(f_{\theta'_i})$
 - 9: **end while**
-

MAML : Avantages / Inconvénients



Points forts :

- Agnostique du point de vue de la tâche et du modèle
→ compatible avec n'importe quel modèle entraîné par descente de gradient
- Pas de paramètres supplémentaires à apprendre


Points faibles :

- Dérivée du deuxième ordre : coûteux en calcul et en mémoire
→ approximer le premier gradient par l'identité (donne de bons résultats sur les problèmes simples !)
- L'optimisation à deux niveaux rend l'entraînement plus instable
→ apprendre le *learning rate* interne, optimiser sous-ensemble des paramètres, introduire des variables de contexte

Résultats: Régression




Résultats: Classification - Omniglot



	5-way Accuracy		20-way Accuracy	
	1-shot	5-shot	1-shot	5-shot
Omniglot (Lake et al., 2011)				
MANN, no conv (Santoro et al., 2016)	82.8%	94.9%	–	–
MAML, no conv (ours)	89.7 ± 1.1%	97.5 ± 0.6%	–	–
Siamese nets (Koch, 2015)	97.3%	98.4%	88.2%	97.0%
matching nets (Vinyals et al., 2016)	98.1%	98.9%	93.8%	98.5%
neural statistician (Edwards & Storkey, 2017)	98.1%	99.5%	93.2%	98.1%
memory mod. (Kaiser et al., 2017)	98.4%	99.6%	95.0%	98.6%
MAML (ours)	98.7 ± 0.4%	99.9 ± 0.1%	95.8 ± 0.3%	98.9 ± 0.2%


Résultats: Classification - Minilimagenet

airplane
automobile
bird
cat
deer
dog
frog
horse
ship
truck



	5-way Accuracy	
	1-shot	5-shot
MiniImagenet (Ravi & Larochelle, 2017)		
fine-tuning baseline	28.86 ± 0.54%	49.79 ± 0.79%
nearest neighbor baseline	41.08 ± 0.70%	51.04 ± 0.65%
matching nets (Vinyals et al., 2016)	43.56 ± 0.84%	55.31 ± 0.73%
meta-learner LSTM (Ravi & Larochelle, 2017)	43.44 ± 0.77%	60.60 ± 0.71%
MAML, first order approx. (ours)	48.07 ± 1.75%	63.15 ± 0.91%
MAML (ours)	48.70 ± 1.84%	63.11 ± 0.92%

Résultats: Reinforcement Learning



(a) Half-Cheetah

(b) Ant

