

Graph Markov Neural Networks

et classification dans des graphes de documents

Séminaire TALia du 5 novembre 2021

[Source principale](#)

arXiv.org > cs > arXiv:1905.06214

Computer Science > Machine Learning

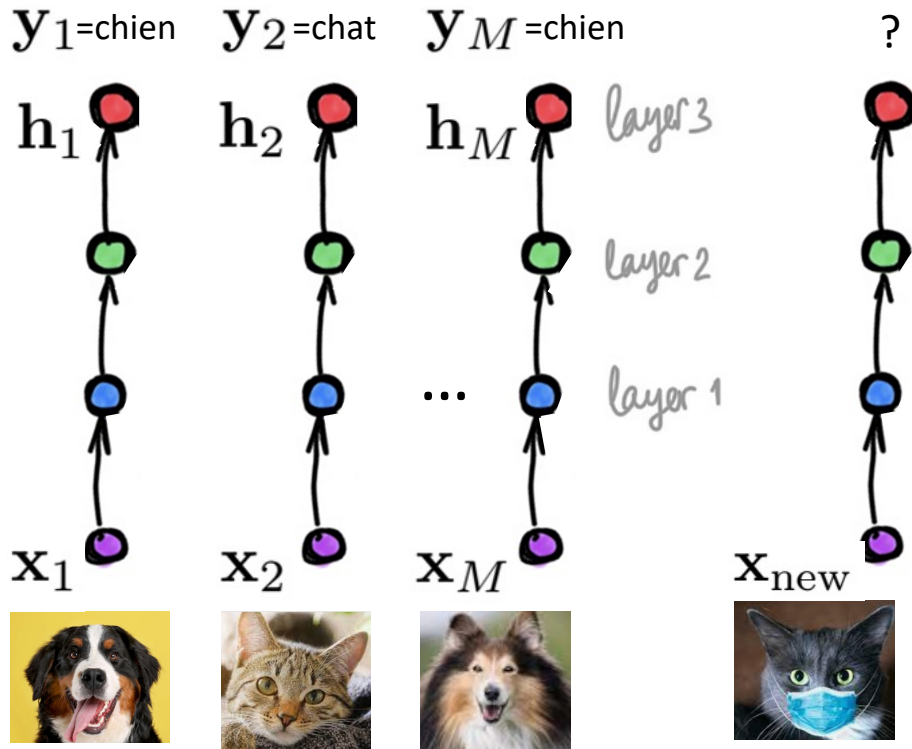
[Submitted on 15 May 2019 (v1), last revised 23 Jul 2020 (this version, v3)]

GMNN: Graph Markov Neural Networks

[Meng Qu](#), [Yoshua Bengio](#), [Jian Tang](#)

Intuitions sur les réseaux de neurones de graphe

Modèle inductif

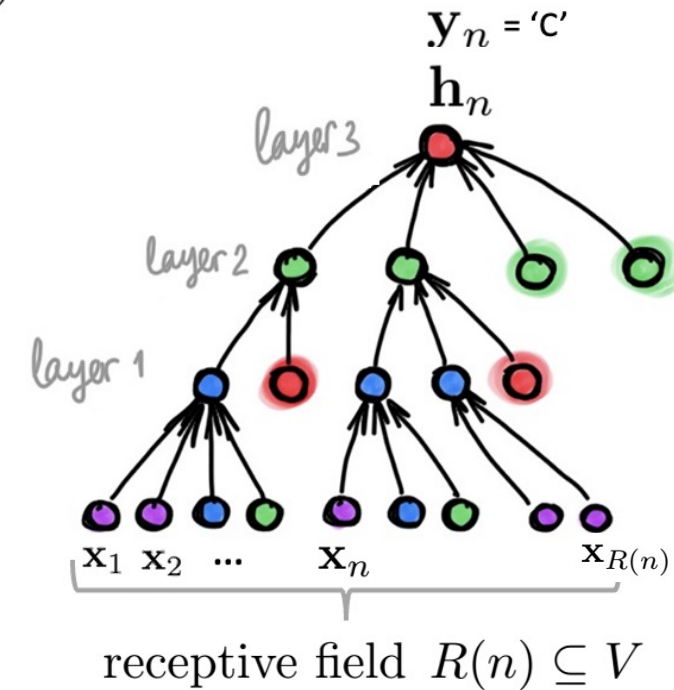



$$p(\mathbf{y}_i | \mathbf{x}_i) = \text{Cat}(\mathbf{y}_i | \text{softmax}(W\mathbf{h}_i)), \quad \mathbf{h}_i = \mathbf{h}(\mathbf{x}_i)$$

$(\mathbf{x}_i, \mathbf{y}_i)$ sont i.i.d

Modèle transductif

$$G = (V, E, \mathbf{x}_V) \quad V = L \cup U$$



$$p(\mathbf{y}_n | \mathbf{x}_V) = \text{Cat}(\mathbf{y}_n | \text{softmax}(W\mathbf{h}_n)), \quad \mathbf{h}_n = \mathbf{h}(\mathbf{x}_{R(n)})$$

$(\mathbf{x}_i, \mathbf{y}_i)$ ne sont pas i.i.d

Construction itérative des représentations dans un GCN

motivation théorique

Un schéma de propagation simple pour les GCN

$$H^{(l+1)} = \sigma \left(\underbrace{\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}}}_{\substack{\text{matrice d'adjacence} \\ \text{normalisée avec} \\ \text{self-connexion} \\ \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}}} \underbrace{H^{(l)} W^{(l)}}_{\substack{\text{matrice de poids} \\ \text{partagés entre tous} \\ \text{les nœuds} \\ \in \mathbb{R}^{d_l \times d_{l+1}}} \right) \quad \text{où} \quad H^{(l)} := \begin{bmatrix} (\mathbf{h}_1^{(l)})^\top \\ (\mathbf{h}_2^{(l)})^\top \\ \vdots \\ (\mathbf{h}_{|\mathcal{V}|}^{(l)})^\top \end{bmatrix} \in \mathbb{R}^{|\mathcal{V}| \times d_l}$$

Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering

Michaël Defferrard Xavier Bresson Pierre Vandergheynst
 EPFL, Lausanne, Switzerland
 {michael.defferrard,xavier.bresson,pierre.vandergheynst}@epfl.ch

[article](#)

Indépendance conditionnelle des étiquettes \mathbf{y}_V étant donnés les attributs \mathbf{x}_V

$$p(\mathbf{y}_V | \mathbf{x}_V) = \prod_{n \in V} p(\mathbf{y}_n | \mathbf{x}_n)$$



Un GNN calcule des représentations des nœuds mais ignore complètement les dépendances entre labels !

Comment tenir compte des corrélations entre labels ?

L'expérience montre que la prise en compte des corrélations entre les étiquettes est **bénéfique** pour améliorer la précision de la classification !

Classifying Wikipedia in a fine-grained hierarchy : what graphs can contribute

Tiphaine Viard^{1,2*}, Thomas McLachlan², Hamidreza Ghader^{2,3} and Satoshi Sekine²

¹Laboratoire d'Informatique de Paris Nord (LIPN), Villetaneuse, France

²Language Information Access Team, Riken AIP, Tokyo, Japan

³ILPS, Amsterdam University

{thomas.mclachlan, hamidreza.ghader, satoshi.sekine}@riken.jp, viard@lipn.univ-paris13.fr

Modélisation « classique » par des **Conditional Random Fields** (CRF) :

$$p(\mathbf{y}_V | \mathbf{x}_V) = \frac{1}{Z(\mathbf{x}_V)} \prod_{(n,m) \in E} \psi(\mathbf{y}_m, \mathbf{y}_n; \mathbf{x}_V) \quad \longrightarrow \quad p(\mathbf{y}_n | \mathbf{y}_{V \setminus n}; \mathbf{x}_V) \stackrel{\text{Markov car indépendant des nœuds qui ne sont pas des voisins}}{=} p(\mathbf{y}_n | \mathbf{y}_{\text{NB}(n)}; \mathbf{x}_V)$$

construit avec des features élaborées par des experts

On aimerait calculer $p(\mathbf{y}_U | \mathbf{y}_L; \mathbf{x}_V)$... hélas **problème d'inférence difficile** à cause de $\frac{1}{Z(\mathbf{x}_V)}$

Approche variationnelle par optimisation de ELBO (1)

Objectif des GMNN : Faire la synthèse entre les GNN's et les CRF's pour modéliser des graphes d'objets dont les labels sont corrélés.

1. On définit un modèle prédictif paramétrique $p_\phi(\mathbf{y}_L, \mathbf{y}_U | \mathbf{x}_V)$ (à choisir) et on essaie de maximiser la vraisemblance pour la distribution marginale $p_\phi(\mathbf{y}_L | \mathbf{x}_V)$ sur les labels observés.

2. On utilise la borne inférieure variationnelle ELBO (Evidence Lower Bound)

distribution marginale sur les observations

L'écart = $KL[q||p] > 0$

$$\log p_\phi(\mathbf{y}_L | \mathbf{x}_V) \geq$$

distribution conjointe

distribution variationnelle

$$\text{ELBO}[q, \theta] \rightarrow \mathbb{E}_{q_\theta(\mathbf{y}_U | \mathbf{x}_V)} [\log p_\phi(\underbrace{\mathbf{y}_L, \mathbf{y}_U}_{:= \mathbf{y}_V} | \mathbf{x}_V) - \log q_\theta(\mathbf{y}_U | \mathbf{x}_V)], \quad \forall q_\theta(\mathbf{y}_U | \mathbf{x}_V)$$

On a l'égalité si et seulement si $q_\theta(\mathbf{y}_U | \mathbf{x}_V) = p_\phi(\mathbf{y}_U | \mathbf{y}_L, \mathbf{x}_V)$ qu'on cherche justement à calculer !

3. On choisi un modèle judicieux pour la distribution variationnelle $q_\theta(\mathbf{y}_U | \mathbf{x}_V)$.

Approche variationnelle par optimisation de ELBO (2)

4. On alterne une étape d'inférence (E = Expectation) et une étape d'apprentissage (M = Maximization)

(E) Expectation

On fixe p_ϕ et on optimise les paramètres θ pour rapprocher $q_\theta(\mathbf{y}_U | \mathbf{x}_V)$ de $p_\phi(\mathbf{y}_U | \mathbf{y}_L, \mathbf{x}_V)$ c.à.d. minimiser $\text{KL}(p_\phi || q_\theta)$

Distribution cible

(M) Maximization

On fixe q_θ et on optimise les paramètres ϕ pour maximiser ELBO donc la log vraisemblance $\ell(\phi) := \mathbb{E}_{q_\theta(\mathbf{y}_U | \mathbf{x}_V)} [\log p_\phi(\mathbf{y}_L, \mathbf{y}_U | \mathbf{x}_V)]$

Choix pour la distribution variationnelle qui prédira les **labels à partir des arguments** :

$$q_\theta(\mathbf{y}_U | \mathbf{x}_V) := \prod_{n \in U} q_\theta(\mathbf{y}_n | \mathbf{x}_V)$$

Approximation du champ moyen

$$q_\theta(\mathbf{y}_n | \mathbf{x}_V) := \text{Cat}(\mathbf{y}_n | \text{softmax}(W_\theta \mathbf{h}_{\theta,n}(\mathbf{x}_V)))$$

Calculé avec un GNN choisi avec soin !

Choix pour la distribution CRF qui prédira les **corrélations entre les labels**:

$$p_\phi(\mathbf{y}_n | \mathbf{y}_{\text{NB}(n)}; \mathbf{x}_V) = \text{Cat}(\mathbf{y}_n | \text{softmax}(W_\phi \mathbf{h}_{\phi,n}))$$

On montre que ça suffit !

Calculé avec un GCN basique

Les GMNN en une figure !

1 $q_\theta(\mathbf{y}_U | \mathbf{x}_V) := \prod_{n \in U} q_\theta(\mathbf{y}_n | \mathbf{x}_V)$ est initialisée avec un « bon » GNN comme p.ex. GCN avec réduction de variance

