

Réseau antagoniste génératif pour la fouille des contradictions TRIZ dans les brevets

Guillaume Guarino*, Ahmed Samet*
Denis Cavallucci*

*ICUBE (UMR CNRS 7357)
INSA Strasbourg, 24 Boulevard de la Victoire, 67000 Strasbourg
prénom.nom@insa-strasbourg.fr

Résumé. L'apprentissage semi-supervisé avec des réseaux antagonistes génératifs (GANs) a attiré beaucoup d'attention ces dernières années dans les domaines souffrant d'un manque de données labélisées. Dans cet article, nous proposons une nouvelle approche appelée PaGAN¹ qui est une combinaison d'un classifieur de documents et d'un classifieur de phrases dans un GAN pour la compréhension des brevets. PaGAN est appliqué et évalué sur un jeu de données réelles. Les expériences montrent que les résultats de PaGAN sont supérieurs à ceux des approches de référence.

1 Introduction

L'innovation est un sujet de développement majeur pour les entreprises d'aujourd'hui. Elle nécessite des recherches théoriques longues et fastidieuses et s'appuie principalement sur l'expérience et le talent des ingénieurs. Guenrich Altshüller, un ingénieur de l'ex-URSS, a développé une théorie à contre-courant. Après avoir fait analyser des centaines de milliers de brevets par des centaines d'ingénieurs, il s'est rendu compte que le chemin qui mène à l'innovation, la "manière" d'innover, était similaire dans tous les domaines explorés. Ainsi, le processus d'innovation serait un mécanisme générique, simplement décliné dans chaque domaine existant. Altshüller est arrivé à la conclusion que la simple observation des problèmes et des solutions d'autres domaines serait la clé d'une innovation quasi-constante et systématique. Selon la théorie qu'il a développée, appelée TRIZ, la clé pour résoudre un problème pourrait simplement consister à "analyser ce qui existe" dans différents domaines techniques, dans le but de trouver des paires problème-solution similaires. La question se pose alors de savoir comment comparer les problèmes et les solutions. La formulation de ces problèmes dépend en effet fortement de leur domaine respectif.

Zanni-Merk et al. (2011) a développé une ontologie basée sur la théorie TRIZ qui est indépendante du domaine technique. Un système technique est défini par deux types de paramètres : des *paramètres d'action* et des *paramètres d'évaluation*. Les paramètres d'action représentent toutes les entités sur lesquelles le concepteur a un pouvoir de modification. Par

1. G. Guarino, A. Samet, A. Nafi, D. Cavallucci, PaGAN : Generative Adversarial Network for Patent understanding, 21st IEEE International Conference on Data Mining (ICDM), Auckland, New Zealand, 2021

exemple, la forme d'une partie du fuselage peut être modifiée. Ce sera un paramètre d'action. Les paramètres d'évaluation permettent d'évaluer les aspects positifs et négatifs résultant d'un choix du concepteur. Par exemple, dans le cas de la partie du fuselage, l'aérodynamisme pourrait être un paramètre d'évaluation. Les paramètres d'évaluation doivent être mesurables pour quantifier l'influence des paramètres d'action. Dans le cas de l'aérodynamique, un ensemble de coefficients peut être calculé, et les variations de ces coefficients sont donc mesurables. Ainsi, un problème sera formulé sous la forme d'une contradiction entre deux paramètres d'évaluation, c'est-à-dire que la modification d'un paramètre d'action conduira à une amélioration d'un paramètre d'évaluation mais aussi à la dégradation d'un autre paramètre d'évaluation. Dans le cas de la partie du fuselage, la modification de la forme (paramètre d'action) pourrait conduire à la diminution des coefficients aérodynamiques (paramètre d'évaluation amélioré) mais aussi à l'augmentation du temps de fabrication (paramètre d'évaluation dégradé). La phrase contenant le paramètre amélioré est appelée "première partie de contradiction", la phrase contenant le paramètre dégradé sera la "deuxième partie de contradiction".

Aucunes des approches existantes (Berdyugina et Cavallucci (2020); Souili et Cavallucci (2017)) n'a réussi à extraire avec précision les problèmes résolus par les brevets, ni à extraire les contradictions. Utiliser l'apprentissage profond semble être une voie majeure d'amélioration. Les réseaux de neurones profonds sont déjà très performants sur des tâches de résumé extractif, très proches de l'extraction de contradictions (Zhou et al. (2018); Devlin et al. (2019); Liu et Lapata (2019)).

Cependant, dans le domaine de l'extraction de brevets et de la conception inventive, les jeux de données contenant des brevets labélisés sont rares voire inexistant à cause de la complexité et du caractère très chronophage de cette tâche. Par conséquent, de nouvelles stratégies d'apprentissage pour les modèles profonds sont nécessaires. L'apprentissage semi-supervisé avec un réseau antagoniste génératif (GAN, Goodfellow et al. (2014)), que cet article étudie, est l'une de ces stratégies. Nos contributions sont les suivantes : (i) un nouveau jeu de données contenant des contradictions issues des brevets ; (ii) une approche reposant sur une classification de document pour vérifier l'existence d'une contradiction dans le document analysé ; (iii) une nouvelle approche se fondant sur un GAN pour l'extraction de contradictions qui intègre l'approche de classification de documents.

2 Modèle de référence

L'extraction de phrases contradictoires est proche d'une tâche de résumé automatique. C'est la raison pour laquelle notre modèle est basé sur un modèle de résumé extractif Guarino et al. (2020), appelé SummaTRIZ. L'encodeur BERT est utilisé dans ce modèle. BERT prend en entrée une série de tokens. Chaque phrase est séparée par un token spécial [SEP]. Un autre token spécial [CLS] est utilisé pour représenter chaque phrase.

Une couche de Transformer au-dessus de BERT et qui ne prend en entrée que les représentations des tokens [CLS], qui sont donc les représentations des phrases, permet d'avoir une attention globale sur la séquence entière même si celle-ci est plus longue que la limite traditionnelle de 512 tokens pour BERT. La sortie de cette dernière couche est donc une représentation contextuelle de chaque phrase. La limite est fixée à 1500 tokens pour correspondre à la longueur de la majorité des parties "état de l'art" des brevets.

Le modèle de base est pré-entraîné sur une tâche de résumé extractif d’articles de presse avec le jeu de données CNN/DailyMail Hermann et al. (2015). L’objectif est d’entraîner la couche d’attention au-dessus de BERT afin qu’elle soit capable de construire une représentation contenant les informations essentielles dans les séquences d’entrée.

Deux classifieurs (perceptron multicouche) binaires sont utilisés, au-dessus de la couche de Transformer, pour prédire si chaque phrase appartient à la première partie de la contradiction, à la deuxième partie de la contradiction ou à aucune d’entre elles. Deux classifieurs différents sont utilisés dû à l’existence d’une probabilité non nulle qu’une phrase contienne la totalité de la contradiction et doive donc être classée à la fois comme première et deuxième partie de la contradiction.

3 Analyse de document pour la fouille de contradiction

La limite du modèle de référence est qu’il ne permet pas de prédire si un document contient une contradiction ou non. Grâce à l’expérience acquise lors du processus d’annotation, nous estimons que seuls 20% des 7 millions de brevets disponibles contiennent une contradiction utilisable. Par conséquent, l’ajout d’une analyse au niveau du document permettrait d’éliminer automatiquement les brevets qui ne contiennent pas de contradiction.

Nous proposons pour cette partie quatre modèles différents qui couvrent les principales tendances en matière de classification de documents : un modèle probabiliste, un modèle basé sur un réseau récurrent, un modèle basé sur un Transformer et un modèle basé sur un perceptron multicouche (MLP). Le modèle probabiliste suppose que le choix des parties de contradictions sont indépendants et donc que la probabilité que deux phrases forment une contradiction est simplement le produit de la probabilité de chacune d’elles d’être une partie de la contradiction. Une autre voie explorée a été les réseaux récurrents et les transformers qui permettent d’analyser l’intégralité du document, à partir des représentations de toutes les phrases. Enfin, le dernier modèle utilisé est un perceptron multicouche pour la classification du document à partir des représentations des deux phrases ayant les probabilités maximales d’appartenir à la contradiction (une phrase pour le *première partie* et une phrase pour le *seconde partie de la contradiction*). Ainsi, la probabilité $P_c(S_1...S_n)$ qu’une contradiction soit présente dans le document devient :

$$P_c(S_1...S_n) = MLP(\arg \max_{1 \leq i \leq n}(P_{c1}(S_i)), \arg \max_{1 \leq i \leq n}(P_{c2}(S_i))) \quad (1)$$

avec $c1$, $c2$ les parties de la contradiction et S_i la i ème phrase du document.

4 PaGAN : Réseau antagoniste génératif pour la compréhension de brevets

L’architecture de PaGAN est basée sur celle de Guarino et al. (2020) décrite dans la sous-section 2. L’encodeur BERT permet de construire des représentations contextuelles des phrases qui sont ensuite classées comme *première partie de la contradiction*, *seconde partie de la contradiction* ou comme phrase neutre.

Réseau antagoniste génératif pour la fouille des contradictions TRIZ dans les brevets

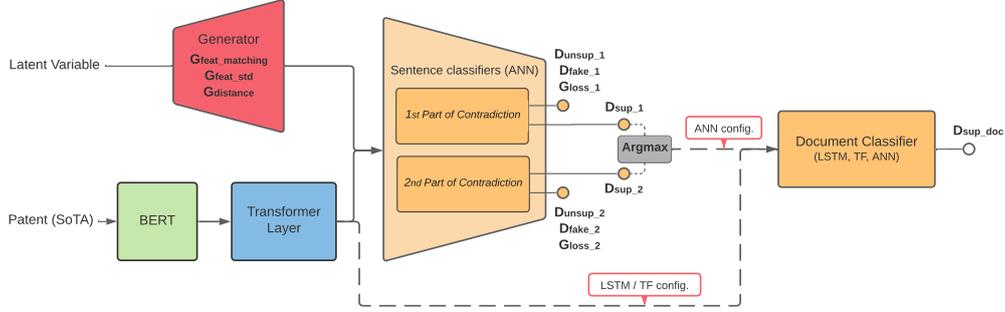


FIG. 1 : Architecture de PaGAN

Nous améliorons le modèle de Guarino et al. (2020) via deux contributions. La première contribution est l'ajout d'un classifieur de document, décrit dans la section 3, qui permet de prédire si un document contient une contradiction. L'utilisation possible de données non labélisées nous a conduit à explorer le potentiel de l'entraînement semi-supervisé pour améliorer les résultats du modèle de référence. Notre deuxième contribution majeure est l'implémentation d'un Réseau Antagoniste Génératif (GAN) pour optimiser l'apprentissage et résoudre le problème de la taille du jeu de données pour l'entraînement.

4.1 Entraînement du modèle

Un apprentissage adverse au niveau des classifieurs de phrases est mis oeuvre comme décrit par Salimans et al. (2016). Une classe supplémentaire est créée pour introduire les probabilités d'appartenance des données d'entrée à la distribution cible p_{data} . Les classifieurs de phrases ont donc trois neurones en sortie : les neurones de classification de la contradiction initiale et un autre neurone associé à la probabilité que le document ne soit pas réel (voir Fig. 1). Les neurones de "contradiction" sont donc impliqués dans la perte supervisée (D_{sup_1} ou D_{sup_2}) pour les deux classes de classification de contradiction C et \bar{C} (la phrase appartient à la partie i de la contradiction ou non, Equation 2) tandis que le neurone "adverse" est impliqué dans les pertes non supervisées pour les classes $fake$ F et $non\ fake$ \bar{F} (Equations 3 et 4).

$$D_{sup_i} = E_{x,y \sim p_{data}} [-\log(P(\hat{y}_{s_i} = y_{s_i} | x, y_{s_i} \in (C, \bar{C})))] \quad (2)$$

$$D_{unsup_i} = E_{x \sim p_{data}} [-\log(P(\hat{y}_{s_i} = y_{s_i} | x, y_{s_i} = \bar{F}))] \quad (3)$$

$$D_{fake_i} = E_{z \sim p_z} [-\log(P(\hat{y}_{s_i} = y_{s_i} | x, y_{s_i} = F))] \quad (4)$$

D_{unsup} indique la capacité du modèle à classer les données réelles comme des données réelles. D_{fake} mesure la capacité du modèle à classer les données "fausses" comme des données "fausses". Les phrases utilisées pour les pertes non supervisées proviennent de brevets non labélisés. Comme les pertes sont calculées au niveau de la phrase, peu de documents sont nécessaires (nous utilisons seulement 1/10 du nombre de documents annotés dans le jeu de données initial). D_{unsup} est donc rétro-propagé à travers la couche de transformer et l'encodeur BERT. Cela implique que l'encodeur va apprendre à intégrer de nouvelles informations

dans les représentations des phrases pour permettre une meilleure reconnaissance des données "réelles". Cette représentation plus riche des phrases des brevets induira une classification plus facile pour la contradiction qui est notre objectif principal. Ce mécanisme permet également de minimiser le sur-apprentissage. Ceci est encore amplifié par le fait que deux pertes non-supervisées sont calculées et rétro-propagées en même temps (une pour chaque classifieur).

Le classifieur de documents n'a qu'un seul neurone en sortie qui fait la décision entre les documents qui contiennent une contradiction (classe Dc) et ceux qui n'en contiennent pas (classe \overline{Dc}). Il est donc impliqué dans une seule perte supervisée :

$$D_{sup_doc} = E_{x,y \sim p_{data}} [-\log(P(\hat{y}_d = y_d | x, y_d \in (Dc, \overline{Dc})))] \quad (5)$$

Comme le nombre de documents labélisés est inférieur au nombre de phrases labélisées, le classifieur de documents a tendance à apprendre plus rapidement que les classifieurs de phrases. Un coefficient expérimental de 0,1 est donc appliqué à D_{sup_doc} afin que les courbes d'apprentissage de tous les classifieurs puissent correspondre.

4.2 Architecture et entraînement du générateur

Plusieurs architectures différentes sont mises en oeuvre pour le générateur : un réseau entièrement connecté, un LSTM et un transformer. La comparaison de ces différentes architectures est présentée dans la section 5.

Le générateur, dans notre cas, génère des séquences de représentations de phrases qui doivent être plausibles afin de tromper les classifieurs de phrases. La perte associée au générateur combine les deux pertes des classifieurs de phrases (G_loss_1 et G_loss_2 dans la Fig. 1) :

$$G_{loss} = \sum_{i=1}^2 E_{z \sim p_z} [-\log(1 - P(\hat{y}_{s_i} = y_{s_i} | x, y_{s_i} = F))] \quad (6)$$

Pour s'assurer que le générateur converge vers les bonnes distributions, nous ajoutons deux pertes de correspondance entre les caractéristiques statistiques. G_{feat_mean} (équation 7) garantit que les représentations générées sont proches des données d'apprentissage et G_{feat_std} (équation 8) garantit également que les documents générés ne sont pas une représentation unique d'une phrase répétée n fois. Nous ajoutons ainsi une contrainte sur la variété des représentations dans un même document.

$$G_{feat_mean} = \|E_{x \sim p_{data}(x)} f(x) - E_{z \sim p_z(z)} f(G(z))\| \quad (7)$$

$$G_{feat_std} = \|\sigma_{x \sim p_{data}(x)} f(x) - \sigma_{z \sim p_z(z)} f(G(z))\| \quad (8)$$

Enfin, pour apporter de la variété dans les documents générés, nous introduisons une minimisation de la similarité entre les documents générés via une mesure de similarité cosinus :

$$Cos_{similarity}(A, B) = \frac{A \cdot B}{\|A\| \|B\|} \forall A, B \in \mathbb{R}^n \quad (9)$$

5 Expérimentations

5.1 Métriques

Les métriques classiques de classification (Précision, Rappel, score F1) sont utilisées pour l'évaluation. De nouvelles métriques sont également introduites. Les métriques S et S_m évaluent l'analyse des phrases. S se rapporte au nombres de phrases correctement labélisées dans les n_1/n_2 phrases les mieux classées avec n_1/n_2 le nombre de phrases comprenant le 1^{er}/2^{eme} paramètre de la contradiction. S_m évalue le nombre de phrases correctement extraites dans les $n_1 + margin$ ou $n_2 + margin$ meilleures phrases selon la partie de la contradiction étudiée (nous prenons $margin = 2$ pour les expériences).

Nous appelons $E_1 = \{S_{10}...S_{1n_1}\}$ l'ensemble des n_1 phrases labélisées comme *première partie de la contradiction* et $E_2 = \{S_{20}...S_{2n_1}\}$ l'ensemble des n_2 phrases labélisées comme *seconde partie de la contradiction*. Chaque paire $S_{1i}S_{2j}$ forme une contradiction. On considère qu'une contradiction est extraite si $\arg \max_{1 \leq i \leq n} (P_{c1}(S_i)) \in E_1$, $\arg \max_{1 \leq i \leq n} (P_{c2}(S_i)) \in E_2$ et $P_c(S_1...S_n) > P_{seuil}$ avec $P_k(S_i)$ la probabilité que la phrase i soit la k^{eme} partie de la contradiction et $P_c(S_1...S_n)$ la probabilité qu'il y ait une contradiction à extraire. La métrique CO_{Found} évalue les deux premières conditions de sorte qu'elle ne prend en compte que l'analyse des phrases. La métrique CO_{Valid} est utilisée pour évaluer le nombre d'extractions qui vérifient toutes ces conditions. Un P_{seuil} de 0.5 est utilisé pour les expériences.

5.2 Résultats

Les résultats² de la classification de phrases sont présentés dans le tableau 1. Les résultats de la classification des documents sont présentés dans le tableau 2. Une validation croisée 4-Fold a été réalisée. 1600 brevets avec contradictions et 1600 brevets sans contradictions ont été labélisés. Plus de détails sur le jeu de données sont mis à disposition ici.

SummaTRIZ (Guarino et al. (2020)) est la seule approche existante qui s'est attaquée à l'extraction de contradictions. Ce modèle ne permet que la classification des phrases. Afin de le comparer aux autres approches, nous introduisons la classification des documents dans le modèle SummaTRIZ avec un modèle probabiliste (voir Partie 3). Le modèle SummaTRIZ_D est entraîné sur notre jeu de données uniquement. L'indice TL fait référence à l'apprentissage par transfert, ce qui indique que le modèle est d'abord entraîné sur le jeu de données CNN/DailyMail (tâche de résumé extractif) puis entraîné avec notre jeu de données. Pour une comparaison plus équitable des modèles et pour mettre en évidence la contribution du GAN, un modèle SummaTRIZ avec un MLP comme classifieur de documents est également introduit comme *Référence*. Notons que pour les classifieurs de phrases, nous utilisons un MLP avec une seule couche intermédiaire.

Nous remarquons que le jeu de données seul ne permet pas d'atteindre un niveau de performance correct. PaGAN montre des résultats de classification de phrases légèrement meilleurs au niveau des métriques traditionnelles mais aussi des nouvelles métriques S et S_m avec une amélioration respectivement de 8% et 6% pour S et 3% pour S_m par rapport à la référence utilisant le transfer learning. Au niveau de la classification de documents et du nombre de contradictions extraites, la différence est beaucoup plus visible. La loss est environ 7% inférieure

2. Le code de PaGAN est disponible ici.

Première partie de contradiction							Deuxième partie de contradiction						
Modèle	Perte	Prec.	Rapp.	F1	S	S_m	Modèle	Perte	Prec.	Rapp.	F1	S	S_m
SummaTRIZ _D	0.140	0	0	0	548	1158	SummaTRIZ _D	0.171	0	0	0	1750	2692
SummaTRIZ _{TL}	0.115	0.53	0.25	0.34	1119	1711	SummaTRIZ _{TL}	0.129	0.69	0.49	0.57	2493	3127
Référence _{MLP_D}	0.140	0	0	0	535	1149	Référence _{MLP_D}	0.170	0	0	0	1766	2692
Référence _{MLP_{TL}}	0.115	0.54	0.25	0.35	1098	1710	Référence _{MLP_{TL}}	0.129	0.68	0.50	0.57	2500	3131
PaGAN _{PROB}	0.112	0.56	0.25	0.35	1168	1736	PaGAN _{PROB}	0.120	0.69	0.56	0.62	2619	3226
PaGAN _{MLP}	0.112	0.56	0.23	0.33	1187	1760	PaGAN _{MLP}	0.120	0.67	0.62	0.64	2626	3206
PaGAN _{LSTM}	0.112	0.58	0.22	0.32	1186	1752	PaGAN _{LSTM}	0.118	0.67	0.63	0.65	2645	3213
PaGAN _{TF}	0.113	0.52	0.29	0.37	1143	1759	PaGAN _{TF}	0.121	0.65	0.63	0.64	2631	3220

TAB. 1 : Résultats de la classification de phrases (avec un LSTM pour générateur)

Modèle	Perte	VP	FP	VN	FN	Acc.	Pre.	Rappel	Score F1	CO _{Found}	CO _{valid}
SummaTRIZ _D	-	0	0	1600	1600	0.50	0	0	0	153	0
SummaTRIZ _{TL}	-	386	135	1465	1214	0.58	0.74	0.24	0.36	582	213
Référence _{MLP_D}	0.529	1274	490	1110	326	0.74	0.72	0.80	0.76	146	96
Référence _{MLP_{TL}}	0.502	1275	438	1162	325	0.76	0.74	0.80	0.77	580	467
PaGAN _{PROB}	-	335	126	1474	1265	0.57	0.73	0.21	0.33	668	192
PaGAN _{MLP}	0.466	1335	431	1169	265	0.78	0.76	0.83	0.79	666	576
PaGAN _{LSTM}	0.481	1370	507	1093	230	0.77	0.73	0.86	0.79	654	567
PaGAN _{TF}	0.467	1345	427	1173	255	0.79	0.76	0.84	0.80	648	552

TAB. 2 : Classification de documents et fouille de contradictions (avec un LSTM pour générateur)

pour la meilleure configuration de PaGAN. Au niveau des contradictions trouvées CO_{found} , c'est à dire des phrases correctement sélectionnées peu importe la classification du document, nous constatons une augmentation maximale de 15.7% pour passer de 580/1600 à 668/1600. La classification des documents étant meilleure avec le GAN, cet écart grandit encore lorsque nous prenons en compte l'ensemble du modèle avec la classification des phrases et de document. En effet, nous observons une augmentation du nombre des contradictions extraites et validées par le classifieur de document de plus de 23% pour passer de 467/1600 à 576/1600 pour la meilleure configuration de PaGAN.

Quatre différentes configurations de PaGAN ont été testées avec des classifieurs de documents différents (Modèle probabiliste, modèle MLP, modèle LSTM, modèle Transformer). L'approche avec le MLP qui présente en même temps des précisions importantes et un nombre de contradictions extraites légèrement supérieur aux autres paraît être le meilleur choix.

6 Conclusion

Dans ce travail, nous avons proposé de combiner des classifieurs multi-niveaux (phrase et document) pour augmenter la qualité de l'extraction d'information à partir de documents textuels. Nous avons également intégré ces classifieurs dans un réseau antagoniste génératif, ce qui a permis d'améliorer les performances d'extraction de 23% par rapport à l'approche de base. La fouille de contradictions dans les brevets est une tâche nécessaire pour une compréhension fine des problèmes et des solutions dans n'importe quel domaine. Notre approche ouvre donc la voie à une analyse automatique et approfondie du contenu des brevets.

Références

- Berdyugina, D. et D. Cavallucci (2020). Setting up context-sensitive real-time contradiction matrix of a given field using unstructured texts of patent contents and natural language processing. In *Triz Future 2020*.
- Devlin, J., M.-W. Chang, K. Lee, et K. Toutanova (2019). Bert : Pre-training of deep bidirectional transformers for language understanding. In *NAACL-HLT*.
- Goodfellow, I. J., J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, et Y. Bengio (2014). Generative adversarial nets. In *Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2*, NIPS'14, Cambridge, MA, USA, pp. 2672-2680. MIT Press.
- Guarino, G., A. Samet, A. Nafi, et D. Cavallucci (2020). Summatriz : Summarization networks for mining patent contradiction. In *2020 19th IEEE International Conference on Machine Learning and Applications (ICMLA)*, pp. 979–986. IEEE.
- Hermann, K. M., T. Kočiský, E. Grefenstette, L. Espeholt, W. Kay, M. Suleyman, et P. Blunsom (2015). Teaching machines to read and comprehend. In *Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 1*, NIPS'15, Cambridge, MA, USA, pp. 1693-1701. MIT Press.
- Liu, Y. et M. Lapata (2019). Text summarization with pretrained encoders. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, Hong Kong, China, pp. 3730–3740. Association for Computational Linguistics.
- Salimans, T., I. Goodfellow, W. Zaremba, V. Cheung, A. Radford, X. Chen, et X. Chen (2016). Improved techniques for training gans. In D. Lee, M. Sugiyama, U. Luxburg, I. Guyon, et R. Garnett (Eds.), *Advances in Neural Information Processing Systems*, Volume 29. Curran Associates, Inc.
- Souili, A. et D. Cavallucci (2017). *Automated Extraction of Knowledge Useful to Populate Inventive Design Ontology from Patents*, pp. 43–62.
- Zanni-Merk, C., D. Cavallucci, et F. Rousselot (2011). Use of formal ontologies as a foundation for inventive design studies. *Comput. Ind.* 62(3), 323–336.
- Zhou, Q., N. Yang, F. Wei, S. Huang, M. Zhou, et T. Zhao (2018). Neural document summarization by jointly learning to score and select sentences. In *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1 : Long Papers)*, Melbourne, Australia, pp. 654–663. Association for Computational Linguistics.

Summary

In recent years, semi-supervised learning with generative adversarial networks (GANs) has singled out for its performance in domains with little labeled data. In this paper, we propose a new approach called PaGAN which is a combination of a document classifier and a sentence classifier in a GAN for patent understanding. PaGAN is applied and evaluated on a real-world dataset. Experiments show outperforming results of PaGAN comparatively to baseline approaches.