

Comparaison de l'utilisation d'un référentiel standard et d'un référentiel interne pour la recommandation d'objets d'apprentissage

Molka Tounsi Dhouib¹[0000-0002-6670-7821], Catherine Faron¹[0000-0001-5959-5561], and Oscar Rodriguez Rocha²[0000-0003-2764-1134]

¹ Université Côte d'Azur, Inria, CNRS, I3S, Sophia Antipolis, France

² Teach On Mars

{dhouib,faron}@i3s.unice.fr, oscar.rodriquez@teachonmars.com

Résumé Avec la transformation numérique, l'adaptation et le développement des compétences sont devenus des facteurs majeurs pour améliorer les performances des collaborateurs et des entreprises. Comprendre les besoins des collaborateurs et les aider à atteindre leurs objectifs de développement de carrière est un véritable défi aujourd'hui. Dans ce travail, nous partageons notre expérience pour mettre en place un système de recommandation automatique permettant aux apprenants de trouver des objets d'apprentissage pertinents en fonction de leurs objectifs d'apprentissage. Cette tâche de mise en correspondance se fonde principalement sur la détermination de la similarité sémantique entre les objectifs d'apprentissage organisés sous forme de thésaurus et le texte des objets d'apprentissage. Nous avons étudié l'impact de l'adaptation et l'utilisation d'un référentiel existant par rapport à la construction d'un référentiel interne à l'entreprise pour définir les objectifs d'apprentissage. Les résultats des expérimentations montrent que la création et l'utilisation d'un référentiel interne à l'entreprise est plus bénéfique que l'utilisation d'un référentiel existant dans notre cas d'usage.

Keywords: Apprentissage intelligent · systèmes de recommandation de formation · référentiels.

1 Introduction

Aujourd'hui, le monde de travail subit des changements dynamiques et continus. Pour stimuler la performance, les entreprises ont la responsabilité de répondre aux attentes et aux besoins des collaborateurs en matière de formation et de développement des compétences, et d'aider les collaborateurs à choisir la formation qui convient à leur parcours, à leurs compétences actuelles, aux besoins du projet sur lequel ils travaillent mais aussi à leurs objectifs d'apprentissage. *Teach on Mars* (TOM)³ est une société spécialisée dans l'Education et l'apprentissage mobile qui développe une plate-forme d'apprentissage spécialisée

3. <https://www.teachonmars.com/fr/>

dans la formation continue au sein des entreprises. De nombreuses solutions de recommandation sont développées chez *Teach on Mars* telles que le filtrage collaboratif et les recommandations basées sur le contenu (similarité entre les objets d'apprentissage). L'objectif de notre projet est de mettre en place un système de recommandation d'objets d'apprentissage qui correspondent aux besoins et aux objectifs des collaborateurs d'une entreprise. Notre système de recommandation repose sur deux composants. (i) D'un côté, le profil de l'apprenant est construit à partir de l'ensemble des compétences déjà acquises et de l'ensemble des compétences qu'il souhaite apprendre. Pour représenter les objectifs d'apprentissage (LG) des apprenants, nous avons considéré deux types de référentiels, le premier est un référentiel interne défini par un expert pédagogique de l'entreprise et le deuxième est ESCO⁴ qui est une classification multilingue des aptitudes, compétences, certifications et professions européennes. Comme exemple des objectifs d'apprentissage, nous pouvons citer "Gestion du temps", "prise de parole en public" ou "Multiculturalisme". (ii) De l'autre côté, une base de données contient 760 objets d'apprentissage (LO) manuellement identifiés par l'expert de *Teach on Mars*, et principalement écrits en français et en anglais. Nous proposons une approche basée sur le calcul de la similarité sémantique entre les objectifs d'apprentissage fournis par l'apprenant et l'ensemble des contenus textuels des objets d'apprentissage de la base.

Nos principales questions de recherche sont :

- Quel est l'impact de l'utilisation d'un référentiel standard par rapport à l'utilisation d'un référentiel interne à l'entreprise pour définir les objectifs d'apprentissage ?
- Quel est le modèle que nous pouvons utiliser dans notre cas, pour construire des représentations vectorielles des objets et objectifs d'apprentissage afin d'améliorer la qualité des recommandations ?

Le reste de cet article est organisé comme suit. La section 2 donne un aperçu de l'état de l'art sur les systèmes de recommandation dans le domaine de l'éducation. La section 3 détaille notre approche de recommandation pour répondre au cas d'usage de *Teach on Mars*. La section 4 rapporte et discute les résultats de nos expériences menées sur les données de *Teach on Mars*. La section 5 conclut et donne quelques orientations pour des travaux futurs.

2 État de l'art

Les systèmes de recommandation (RS) sont des systèmes de filtrage d'information ayant comme objectif d'aider les utilisateurs à trouver des contenus, des produits ou des services en se basant sur les préférences des autres utilisateurs [10,2]. Dans le domaine de l'Éducation, nous pouvons distinguer trois techniques de recommandation [4,15] :

- Recommandation fondée sur la connaissance : utilise des ontologies pour suggérer des articles à l'utilisateur en fonction du contexte de l'utilisateur,

4. <https://ec.europa.eu/esco/portal/home>

du contexte de l'article et de leurs relations modélisées par l'ontologie [1,14,19].

- Recommandation fondée sur l'analyse des réseaux sociaux : ces travaux sont fondés sur la construction des graphes des apprenants et des objets d'apprentissage issus des réseaux sociaux en utilisant des tweets avec des URLs éducatives. Ces graphes sont construits en utilisant les co-occurrences de hashtags et les retweets. Par la suite, des mesures de densité et de centralité sont appliquées à ces graphes pour fournir des recommandations [8].
- Recommandation fondée sur l'apprentissage automatique : certains travaux utilisent les techniques de clustering pour trouver les objets d'apprentissage similaires afin de générer les recommandations [6]. D'autres travaux utilisent les techniques de classification pour générer les recommandations. [13] utilisent les algorithmes des arbres de décision et de Naive Bayes afin de classifier les caractéristiques démographiques des utilisateurs pour recommander des objets d'apprentissage. [15] entraînent un modèle *Random Forest* pour classifier la correspondance entre une compétence et un objet d'apprentissage. Ce modèle de décision binaire utilise plusieurs caractéristiques comme la longueur des objets d'apprentissage, leurs niveaux, le nombre de vues, et plus spécifiquement la mesure de similarité textuelle entre eux. Cette mesure de similarité est calculée en utilisant les techniques de plongement de mots avec la mesure du cosinus.

Pour répondre à notre cas d'utilisation, nous adoptons une approche de recommandation basée sur le contenu en utilisant les techniques d'apprentissage automatique et plus précisément la mesure de similarité textuelle sémantique (STS) entre le profil de l'utilisateur qui est représenté par un ensemble d'objectifs d'apprentissage et le contenu textuel des objets d'apprentissage. Une mesure STS qui se fonde sur une correspondance stricte des mots ou des modèles term frequency-inverse document frequency (TF-IDF) entre les descriptions textuelles pour la tâche de recommandation donnerait de mauvais résultats, car elle ne prendrait pas en compte les relations syntaxiques et sémantiques des mots. Pour remédier à cela, les techniques de plongement de mots (word embedding) ont été utilisées avec beaucoup de succès dans les tâches de calcul de similarité entre textes. Ces techniques permettent de générer une représentation distribuée des mots qui exploite la sémantique des mots. L'inconvénient de cette méthode est l'incapacité de ces modèles à prendre en compte le contexte des mots et à approfondir les relations entre les mots de la phrase [11,9]. Progressivement, les modèles de plongement de mots contextuel ont gagné de la place et ont montré les meilleures performances sur les benchmarks de la tâche STS. Parmi ces modèles nous citons par exemple USE (Universal Sentence Encoder) [3], BERT (Bidirectional Encoder Representations from Transformers) [5] et RoBERTa (Robustly optimized BERT approach) [7], SBERT (Sentence-BERT) [12].

Pour répondre au cas d'usage de *Teach on Mars*, nous avons choisi d'utiliser des modèles de plongement contextuel de l'état d'art. Dans [16], nous avons montré que ces modèles ont des performances qui dépassent de loin celles du

modèle BM25 d'Elasticsearch généralement utilisé dans l'industrie. Nous nous intéressons ici à l'étude de l'impact du choix du référentiel utilisé dans la tâche de recommandation et comparons les résultats obtenus avec trois modèles de plongement contextuel de l'état d'art et deux référentiels différents : un référentiel interne à *Teach on Mars* et le référentiel ESCO.

3 Approche proposée

Dans notre scénario de recommandation, lorsqu'un nouvel objectif d'apprentissage est exprimé par l'apprenant, un ensemble d'objets d'apprentissage les plus pertinents pour cet objectif devrait être automatiquement suggéré. Dans notre approche, nous supposons qu'un objet d'apprentissage est pertinent pour un objectif d'apprentissage si ces deux derniers sont sémantiquement similaires.

La Figure 1 présente l'approche que nous proposons. Elle comprend deux étapes principales : (i) la représentation vectorielle des objets et objectifs d'apprentissage, et (ii) le calcul de la similarité sémantique entre objets et objectifs d'apprentissage.




FIGURE 1 – Processus de recommandation des objets d'apprentissage.

3.1 Représentation vectorielle des objectifs et objets d'apprentissage

Cette première étape permet de représenter chaque objet ou objectif d'apprentissage par un vecteur qui capture la sémantique de ses phrases de telle manière que l'objectif d'apprentissage et tous les objets d'apprentissage pertinents soient proches dans l'espace vectoriel.

Modèles de plongement de phrases Nous avons considéré différents modèles contextuels et multilingues pour générer ces représentations vectorielles :

Multilingual Universal Sentence Encoder (MUSE). MUSM⁵[20] convertit un texte de longueur variable en un vecteur de 512 dimensions. Il est destiné à être utilisé pour des tâches de classification de textes, clustering, de recherche de similarités textuelles sémantiques, etc.

Sentence-BERT. Le modèle SBERT représente une modification de l'architecture du modèle BERT et a été conçu pour accélérer le temps de recherche de la paire la plus similaire, très coûteuse avec BERT[12]. SBERT est disponible dans la bibliothèque *SentenceTransformers* qui fournit une méthode pour calculer la représentation vectorielle des textes. Il fournit deux modes principaux pour la recherche sémantique : (i) La recherche sémantique symétrique où la requête et les textes du corpus ont la même longueur. Parmi les modèles de cette catégorie, on peut citer *Paraphrase*⁶, *Distiluse*⁷. (ii) La recherche sémantique asymétrique pour des requêtes courtes (c'est-à-dire une question ou un mot-clé) mais où les entrées dans le corpus sont plus longues. Parmi les modèles de cette catégorie, nous pouvons citer *MsMarco*. Dans notre approche de recommandation, nous sommes dans le cas de la recherche asymétrique (nous utilisons le titre et le texte des objets d'apprentissage). Le problème est qu'il n'existe pas de modèle multilingue dans la recherche asymétrique pour générer les représentations vectorielles, ce qui ne répond pas à nos besoins puisque les objets d'apprentissage sont en français et en anglais. Pour cette raison, nous avons décidé d'utiliser les modèles de recherche symétriques : (i) Paraphrase fait correspondre les phrases et les paragraphes à un espace vectoriel dense de 768 dimensions, et peut être utilisé pour des tâches telles que le clustering ou la recherche sémantique. (ii) Distiluse fait correspondre les phrases et les paragraphes à un espace vectoriel dense de 512 dimensions et peut être utilisé pour des tâches telles que le clustering ou la recherche sémantique.

5. <https://tfhub.dev/google/universal-sentence-encoder-multilingual/3>

6. <https://huggingface.co/sentence-transformers/paraphrase-multilingual-mpnet-base-v2>

7. <https://huggingface.co/sentence-transformers/distiluse-base-multilingual-cased-v1>

Méthode de calcul des représentations vectorielles des objets et objectifs d'apprentissage

Représentation vectorielle simple. La représentation vectorielle d'un objet d'apprentissage (ou d'un objectif d'apprentissage) x est un vecteur $V(x)$ qui représente le résultat direct obtenu à partir du modèle utilisé.

Représentation vectorielle moyenne des objectifs d'apprentissage en se basant sur les niveaux d'un thésaurus. Nous considérons un thésaurus qui permet d'organiser l'ensemble des objectifs d'apprentissage selon différents niveaux hiérarchiques et dont les feuilles correspondent aux mots clés que nous utilisons pour annoter les contenus textuels. En utilisant un tel thésaurus, nous pouvons enrichir la représentation vectorielle simple d'un texte basée sur les seuls mots clés, avec les concepts des niveaux supérieurs dans le thésaurus. La représentation vectorielle $V(lg)$ d'un objectif d'apprentissage lg est la moyenne des représentations vectorielles en considérant N niveaux du thésaurus :

$$V(lg) = \frac{1}{N} \sum_{i=1}^N V(c_i), \quad (1)$$

où $V(c_i)$ est la représentation vectorielle simple du concept c_i apparaissant dans lg et N est le nombre de niveaux considérés pour enrichir les représentations.

3.2 Similarité sémantique

Afin de pouvoir mesurer la similarité sémantique entre les représentations vectorielles V d'un objectif d'apprentissage LG et l'objet d'apprentissage LO , nous avons utilisé la métrique basée sur le cosinus.

$$sim(LO, LG) = \frac{V(LO) \cdot V(LG)}{\|V(LO)\| \cdot \|V(LG)\|}, \quad (2)$$

Un objet d'apprentissage lo est recommandé pour un objectif d'apprentissage lg si la valeur de $sim(lo, lg)$ est supérieure à un seuil donné.

4 Expérimentations

4.1 Description des données

Le jeu de données est composé de deux éléments principaux : les objectifs d'apprentissage et les objets d'apprentissage.

Objectifs d'apprentissage Dans le scénario de l'utilisation de notre système de recommandation, l'apprenant doit construire son profil à partir de l'ensemble des compétences qu'il souhaite apprendre. Pour représenter les objectifs d'apprentissage des apprenants, nous considérons deux sources de données alternatives :

Référentiel interne à Teach on Mars. Nous avons utilisé un référentiel interne à *Teach on Mars* qui a été défini par les experts de contenus de l'entreprise. Ce référentiel contient 166 concepts répartis en trois niveaux : (i) 5 catégories, (ii) 25 thématiques et (iii) 133 mots clés.

Classification européenne des aptitudes/compétences, certification et professions. ESCO fournit la description de 121 compétences non techniques traduites en 27 langues. La structure hiérarchique d'ESCO est organisée en six niveaux. La première difficulté rencontrée dans l'utilisation d'ESCO est l'absence d'un jeu de données bien défini pour établir une correspondance entre les concepts d'ESCO et les LOs de *Teach on Mars*. La création d'un tel jeu de données nécessiterait beaucoup de travail d'expertise en terme de temps et d'effort afin que l'expert se familiarise avec la signification et le contexte de chaque concept ESCO avant de pouvoir l'associer avec les LOs qui répondent à ce concept.

Afin de contourner ce problème, nous avons commencé par un travail d'alignement entre ESCO et le référentiel interne de *Teach on Mars*. Nous avons utilisé une approche d'alignement d'ontologie basée sur un ensemble de règles exploitant l'espace de plongement de mots et mesurant les clusters d'étiquettes pour identifier les relations entre les entités [17,18]. Par la suite, nous avons utilisé cet alignement pour générer une correspondance entre les concepts d'ESCO alignés et les LOs de *Teach on Mars* en exploitant l'information commune qui est le référentiel interne de l'entreprise. Le résultat de l'alignement entre ESCO et le référentiel interne de *Teach on Mars* contient 74 concepts ESCO structurés en 3 niveaux que nous avons nommés pour la suite catégorie, thématique et mots clés.

Objets d'apprentissage Un expert de *Teach on Mars* a choisi manuellement sur le Web (crawling) 1350 LOs. Il s'agit d'articles, de vidéos, ou de broadcasts. Chaque LO est associé manuellement par l'expert à une thématique unique du référentiel de *Teach on Mars*. Cela nous a permis de construire notre base d'annotation manuelle pour pouvoir comparer les performances de chaque modèle. Nous ne considérons dans cette étude que les LOs de type article car le texte est généralement plus long qu'une description de vidéo ou de broadcast. Nous avons obtenu 760 LOs dont 400 en langue française et 360 en anglais. La première étape du traitement consiste à récupérer le titre et le contenu textuel de chaque article. Voici un exemple d'objet d'apprentissage :

```
Title: Learn to make decisions that last take this quick test
Learning object text: [...] Everyday we are faced with a multitude
of decisions that alter our lives in small or significant ways.
How you weigh up the pros and cons of each decision and decide
which direction to take isn/'t always easy or foolproof [...]
```

4.2 Protocole d'évaluation

Afin d'évaluer la performance de notre approche de recommandation et de vérifier l'apport de chaque référentiel dans l'amélioration des résultats de recom-

mandation et de déterminer le meilleur modèle et la meilleure représentation vectorielle des LOs et LGs, nous avons défini 15 expérimentations dont les paramètres sont décrits dans la Table 1.

Afin de mesurer la correspondance entre les recommandations produites automatiquement et les recommandations produites manuellement par les experts, nous avons utilisé les métriques de précision, rappel, F1 et “précision à N” en considérant les N LOs les mieux classés :

$$P@N = \frac{\text{EP parmi le top } N \text{ des ER}}{N}. \quad (3)$$

où EP et ER représentent respectivement les éléments pertinents et les éléments recommandés.

Les expériences ont été menées en utilisant la méthodologie de validation croisée 5 fois.

TABLE 1 – Cadre expérimental

Expérimentations	Modèles	Paramètres
MUSE_c	MUSE	catégorie
MUSE_t	MUSE	thématique
MUSE_k	MUSE	mot clé
MUSE_k_t	MUSE	mot clé/thématique
MUSE_k_t_c	MUSE	mot clé/thématique/catégorie
paraphrase_c	Paraphrase	catégorie
paraphrase_t	Paraphrase	thématique
paraphrase_k	Paraphrase	mot clé
paraphrase_k_t	Paraphrase	mot clé/thématique
paraphrase_k_t_c	Paraphrase	mot clé/thématique/catégorie
distiluse_c	Distiluse	catégorie
distiluse_t	Distiluse	thématique
distiluse_k	Distiluse	mot clé
distiluse_k_t	Distiluse	mot clé/thématique
distiluse_k_t_c	Distiluse	mot clé/thématique/catégorie

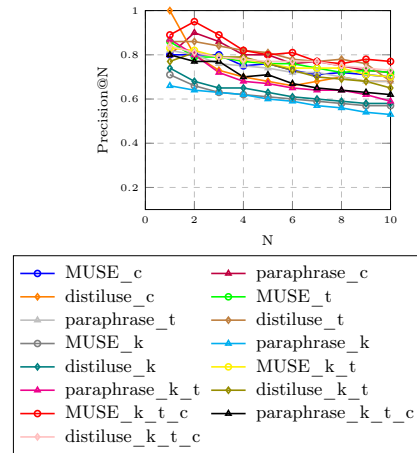
4.3 Résultats et discussion

Résultat des expérimentations en utilisant le référentiel interne de Teach on Mars La Figure 3 présente les performances de notre système pour chaque paramètre testé en terme de précision, rappel, F1 score et precision@N. Nous obtenons les meilleures performances du système en utilisant le niveau “Thématique” du référentiel interne de *Teach on Mars*, avec la meilleure valeur de précision en utilisant le modèle MUSE et la meilleure valeur de rappel en utilisant le modèle “Paraphrase”. La meilleure valeur de F1 est obtenue en utilisant le modèle MUSE avec le niveau le plus précis du référentiel interne c.à.d

“mot clé”. En se basant sur la performance de notre système en terme de $P@N$, nous avons obtenu le meilleur résultat en rajoutant du contexte au troisième niveau du référentiel c.à.d “mot clé”, et ce en utilisant la moyenne des représentations vectorielles des trois niveaux du référentiel, c.à.d “mot clé”, “thématique” et “catégorie” avec le modèle MUSE (MUSE_t en vert avec un rond). Nous remarquons aussi que le modèle Distiluse a une meilleure valeur de cette mesure pour la $P@1$ (distiluse_c en orange) en utilisant le niveau le plus générique du référentiel (catégorie) et $P@5$ et $P@8$ en utilisant les thématiques (distiluse_t en marron).

Expérimentations	Seuil	P	R	F1
MUSE_c	0.130	0.350	0.370	0.360
paraphrase_c	0.240	0.310	0.280	0.290
distiluse_c	0.080	0.340	0.380	0.310
MUSE_t	0.190	0.610	0.450	0.520
paraphrase_t	0.270	0.40	0.610	0.480
distiluse_t	0.190	0.500	0.490	0.500
MUSE_k	0.220	0.520	0.590	0.550
paraphrase_k	0.360	0.390	0.61	0.480
distiluse_k	0.260	0.450	0.580	0.500
MUSE_k_t	0.130	0.370	0.570	0.470
paraphrase_k_t	0.270	0.330	0.590	0.430
distiluse_k_t	0.150	0.380	0.570	0.460
MUSE_k_t_c	0.080	0.360	0.560	0.440
paraphrase_k_t_c	0.300	0.380	0.510	0.440
distiluse_k_t_c	0.150	0.430	0.510	0.470

(a) Précision, Rappel et F1-scores.



(b) Précision@N

FIGURE 2 – Performances du système en fonction des différents paramètres expérimentés en utilisant le référentiel interne.

Résultat des expérimentations en utilisant ESCO La Figure 2 présente les performances de notre système pour chaque paramètre testé en terme de précision, rappel, F1 score et precision@N. Nous obtenons les meilleures performances du système en utilisant le niveau le plus générique d’ESCO et le modèle “MUSE”. La meilleure valeur de F1 est obtenue en utilisant le modèle MUSE avec le niveau intermédiaire d’ESCO (c.à.d “thématique”). En nous basant sur la performance de notre système en terme de $P@N$, nous avons obtenu le meilleur résultat avec le modèle MUSE (MUSE_t en vert avec un rond). Nous remarquons aussi que le modèle Distiluse a une meilleure valeur de cette mesure à partir de $P@6$ en utilisant le niveau intermédiaire de la hiérarchie (distiluse_t en marron).

En comparant les résultats des deux référentiels, nous avons remarqué que l’utilisation d’un référentiel interne améliore les résultats de la recommandation


de plus de 13% pour la valeur de F1. Nous avons aussi remarqué une nette amélioration du P@N avec l'utilisation du référentiel interne (des valeurs entre 0.53 et 1 avec le référentiel interne et inférieures à 0.61 avec ESCO). Cela s'explique par le fait que le référentiel interne est plus concret et plus précis pour les labels des concepts, alors qu'un référentiel standard comme ESCO est généralement plus riche mais aussi plus générique, et peut contenir certains concepts qui peuvent avoir plusieurs interprétations. Par exemple le concept d'ESCO "develop digital content" peut être associé à deux concepts différents de deux catégories différentes du référentiel interne de *Teach on Mars* : (i) le concept "digital marketing" qui appartient à la catégorie "Business Performance", (ii) et le concept "digital transformation" qui appartient à la catégorie "Innovation".

Ces résultats sont cohérents avec les résultats de l'étape d'alignement des deux référentiels puisque nous avons pu aligner 60,65% des concepts ESCO contre 36,84% des concepts du référentiel de TOM. Le pourcentage des concepts en commun entre les deux référentiels est de 48,74%. Après analyse du référentiel ESCO par les experts de contenus chez *Teach on Mars*, ces derniers nous ont recommandé de n'utiliser que les 3 niveaux intermédiaires d'ESCO et donc d'ignorer le premier niveau qui identifie des compétences trop génériques comme par exemple "attitudes et valeurs", et les deux derniers niveaux qui identifient des compétences trop spécifiques comme par exemple "utiliser Yahoo Search". Cette analyse a été confirmée lors de l'étape de l'alignement automatique puisque nous n'avons pu lier que les niveaux intermédiaires d'ESCO. En ne considérant que ces trois niveaux intermédiaires d'ESCO, nous avons pu aligner 74,74% des concepts d'ESCO contre 29,52% des concepts de TOM. Parmi les exemples des concepts de TOM que nous ne pouvons pas lier dans ESCO nous pouvons citer par exemple "productiveness", "Team building" ou "Eco-friendly".

Finalement, à partir de nos expérimentations sur ce cas d'usage, nous pouvons conclure qu'il y a encore un énorme gap entre la communauté de l'ingénierie de connaissance et l'industrie. En cas réel, les entreprises sont toujours en mode exploratoire de ces techniques d'ingénierie de connaissance et ne sont pas forcément conscientes de l'utilité et l'importance de la réutilisation et l'adaptation des référentiels existants, surtout si nous avons l'occasion d'aller jusqu'à intégrer l'aspect de l'interopérabilité. Ce mode exploratoire mène les entreprises à créer directement des référentiels internes selon le besoin souhaité et les données sans prendre le risque de comprendre, analyser et adapter un référentiel standard. Sans surprise, les référentiels internes sont de loin plus performants que l'utilisation et l'adaptation d'un référentiel existant.

5 Conclusion

Dans cet article, nous avons proposé un système de recommandation des objets d'apprentissage en fonction des objectifs de l'apprenant en nous basant sur le calcul de leur distance de similarité et cela en mettant l'accent sur l'apport de l'adaptation d'un référentiel standard par rapport à la création d'un référentiel spécifique. Nos expériences montrent que la recommandation des objets d'ap-



(a) Précision, Rappel et F1-scores.

(b) Précision@N

FIGURE 3 – Performances du système en fonction des différents paramètres expérimentés en utilisant ESCO aligné avec TOM.

prentissage est la plus précise en utilisant le modèle MUSE, et que dans notre cas, l’utilisation d’un référentiel interne améliore le résultat de la recommandation par rapport l’adaptation d’un référentiel standard existant .

Les perspectives de ce travail sont d’étudier comment présenter ces recommandations à l’apprenant et de définir des parcours d’apprentissage personnalisés, en prenant en compte les niveaux de difficultés des objets d’apprentissage et le niveau et l’historique d’apprentissage de l’utilisateur.

Références

1. Aciad, E., Meziane, F. : An adaptable and personalised e-learning system applied to computer science programmes design. *Education and Information Technologies* **24**(2), 1485–1509 (2019)
2. Bobadilla, J., Ortega, F., Hernando, A., Gutiérrez, A. : Recommender systems survey. *Knowledge-based systems* **46**, 109–132 (2013)
3. Cer, D., Yang, Y., yi Kong, S., Hua, N., Limtiaco, N., John, R.S., Constant, N., Guajardo-Cespedes, M., Yuan, S., Tar, C., Sung, Y.H., Strope, B., Kurzweil, R. : Universal sentence encoder (2018)
4. Chicaiza, J., Piedra, N., Lopez-Vargas, J., Tovar-Caro, E. : Recommendation of open educational resources. an approach based on linked open data. In : 2017 IEEE Global Engineering Education Conference (EDUCON). pp. 1316–1321. IEEE (2017)
5. Devlin, J., Chang, M.W., Lee, K., Toutanova, K. : Bert : Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv :1810.04805* (2018)

6. Duffin, J., Muramatsu, B., Henson Johnson, S. : Oer recommender : A recommendation system for open educational resources and the national science digital library. White paper funded by the Andrew W. Mellon Foundation for the Folksemantic.org project (2007)
7. Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., Stoyanov, V. : Roberta : A robustly optimized bert pretraining approach. arXiv preprint arXiv :1907.11692 (2019)
8. Lopez-Vargas, J., Piedra, N., Chicaiza, J., Tovar, E. : Recommendation of oers shared in social media based-on social networks analysis approach. In : 2014 IEEE Frontiers in Education Conference (FIE) Proceedings. pp. 1–8. IEEE (2014)
9. Majumder, G., Pakray, P., Gelbukh, A., Pinto, D. : Semantic textual similarity methods, tools, and applications : A survey. *Computación y Sistemas* **20**(4), 647–665 (2016)
10. Park, D.H., Kim, H.K., Choi, I.Y., Kim, J.K. : A literature review and classification of recommender systems research. *Expert systems with applications* **39**(11), 10059–10072 (2012)
11. Pontes, E.L., Huet, S., Linhares, A.C., Torres-Moreno, J.M. : Predicting the semantic textual similarity with siamese cnn and lstm. arXiv preprint arXiv :1810.10641 (2018)
12. Reimers, N., Gurevych, I. : Sentence-bert : Sentence embeddings using siamese bert-networks. arXiv preprint arXiv :1908.10084 (2019)
13. Sun, G., Cui, T., Beydoun, G., Chen, S., Dong, F., Xu, D., Shen, J. : Towards massive data and sparse data in adaptive micro open educational resource recommendation : a study on semantic knowledge base construction and cold start problem. *Sustainability* **9**(6), 898 (2017)
14. Tarus, J.K., Niu, Z., Mustafa, G. : Knowledge-based recommendation : a review of ontology-based recommender systems for e-learning. *Artificial intelligence review* **50**(1), 21–48 (2018)
15. Tavakoli, M., Mol, S.T., Kismihók, G. : Labour market information driven, personalized, oer recommendation system for lifelong learners. arXiv preprint arXiv :2005.07465 (2020)
16. Tounsi Dhouib, M., Faron, C., Rodriguez Rocha, O. : Recommendation d’objets d’apprentissage basée sur des objectifs d’apprentissage en utilisant les modèles de plongement de phrases. 7ème conférence sur les Applications Pratiques de l’Intelligence Artificielle APIA 2022 (2022)
17. Tounsi Dhouib, M., Faron, C., Tettamanzi, A.G. : Measuring clusters of labels in an embedding space to refine relations in ontology alignment. *Journal on Data Semantics* **10**(3), 399–408 (2021)
18. Tounsi Dhouib, M., Faron Zucker, C., Tettamanzi, A.G. : An ontology alignment approach combining word embedding and the radius measure. In : International Conference on Semantic Systems. pp. 191–197. Springer, Cham (2019)
19. Wan, S., Niu, Z. : An e-learning recommendation approach based on the self-organization of learning resource. *Knowledge-Based Systems* **160**, 71–87 (2018)
20. Yang, Y., Cer, D., Ahmad, A., Guo, M., Law, J., Constant, N., Abrego, G.H., Yuan, S., Tar, C., Sung, Y.H., et al. : Multilingual universal sentence encoder for semantic retrieval. arXiv preprint arXiv :1907.04307 (2019)