

Title	GCN と Few-Shot Learning を用いた少数サンプル職業推薦モデルのシミュレーションによる性能評価
Author(s)	趙, 泰銘
Citation	
Issue Date	2026-03
Type	Thesis or Dissertation
Text version	author
URL	<a href="https://hdl.handle.net/10119/20444">https://hdl.handle.net/10119/20444</a>
Rights	
Description	Supervisor:長谷川 忍, 先端科学技術研究科, 修士(情報科学)

修士論文

GCN と Few-Shot Learning を用いた  
少数サンプル職業推薦モデルのシミュレーションによる性能評価

Zhao, Taiming

主指導教員 長谷川 忍

北陸先端科学技術大学院大学  
先端科学技術研究科  
(情報科学)

令和 8 年 3 月

## Abstract

The contemporary labor market is undergoing a profound structural transformation driven by rapid digitalization, increasing technological specialization, and the emergence of highly differentiated industries. Along with these changes, large-scale vocational data have become widely available through online recruitment platforms, professional networking services, and corporate human resource systems. Although the volume of such data continues to grow, its distribution is far from uniform. In practice, occupational data commonly exhibit a power-law or long-tail distribution in which a small number of occupations account for the majority of available samples, while a large number of occupations are represented by only a limited amount of data.

In most real-world datasets, so-called “Head” occupations—such as general administrative roles, standard software engineering positions, or retail sales—dominate interaction logs and training samples. In contrast, a substantial number of occupations reside in the “Tail” of the distribution. These include highly specialized technical roles, region-specific professions, and emerging occupations associated with new societal demands, such as those related to the green economy, data governance, or AI ethics. For these occupations, the number of available samples often falls far below the threshold required for stable parameter estimation in conventional machine learning models, making reliable recommendation particularly challenging.

A central issue underlying this challenge is the systemic popularity bias inherent in many existing recommendation algorithms. Classical Collaborative Filtering methods and their neural extensions rely heavily on dense user – item interaction matrices. When an occupation has only a small number of interactions, the corresponding latent representation cannot be sufficiently optimized due to the lack of informative gradients. As a result, embedding quality deteriorates significantly for low-frequency occupations. During inference, models tend to favor popular occupations that have been well optimized during training, as these contribute more strongly to global performance metrics such as overall hit rate or accuracy. This mechanism creates a self-reinforcing feedback loop in which popular occupations are recommended more frequently, generating even more interaction data, while rare but potentially relevant occupations remain underexposed. In the context of job recommendation, this phenomenon is not merely a technical limitation. It may restrict the career exploration space of job seekers, hinder labor mobility toward specialized or emerging sectors,

and exacerbate mismatches between individual skill sets and occupational requirements. Consequently, mitigating popularity bias in long-tail occupations is a critical requirement for building fair and effective job recommendation systems.

To address the limitations of purely data-driven approaches in sparse and imbalanced environments, this research proposes a hybrid framework that shifts the learning paradigm from interaction-frequency dependence to knowledge-infused representation learning. Specifically, the proposed approach integrates Graph Convolutional Networks (GCN) for structural feature extraction with Prototypical Few-Shot Learning (FSL) for robust inference under limited supervision. By combining these two components, the framework aims to leverage both relational knowledge and metric-based generalization.

The foundation of the proposed method is the construction of a Job – Skill Knowledge Graph that explicitly models semantic relationships between occupations through their required skill sets. In this graph, nodes represent occupations and individual skills, while weighted edges encode the strength of association between an occupation and a skill. These weights are derived from large-scale job posting data using a weighted similarity measure that reflects both skill overlap and importance. By embedding domain knowledge into the graph structure, the model introduces a meaningful prior that complements sparse interaction data.

A GCN is then applied to this knowledge graph to perform iterative message passing. Through neighborhood aggregation, each occupation updates its representation by integrating information from semantically related occupations and shared skills. This process allows occupations with limited or even zero interaction data to acquire meaningful representations by leveraging their structural position in the graph. For example, a rare occupation such as a specialized cloud security role in the healthcare domain can inherit foundational semantic information from broader but related occupations, including cybersecurity or cloud infrastructure engineering. As a result, even tail occupations obtain representations grounded in skill semantics rather than historical popularity.

While GCN-based representation learning alleviates sparsity at the feature level, it does not fully address the challenge of decision making under extremely limited supervision. To tackle this issue, the proposed framework incorporates Prototypical Few-Shot Learning as a second stage. Few-shot learning methods are designed to

generalize from a small number of labeled examples by learning a metric space in which similar instances are placed close to one another. In this study, an episodic training strategy is adopted to simulate the target low-data scenario during training.

In each training episode, a small support set is constructed by sampling only a few examples for each occupation, along with a corresponding query set. User profiles and occupation representations are projected into a shared metric space through a learnable projection function. Within this space, a prototype vector is computed for each occupation as the mean representation of its support samples. Recommendation is then formulated as a distance-based ranking problem, where users are matched to occupations based on their proximity to these prototypes. This formulation allows the model to generalize to new or rare occupations, as decision boundaries are determined by relative similarity rather than absolute frequency.

The effectiveness of the proposed GCN – FSL framework was evaluated using a large-scale real-world dataset consisting of over 150,000 vocational profiles, approximately 2,000 occupation categories, and a skill taxonomy containing more than 12,000 unique skills. To analyze performance across different data regimes, occupations were grouped into Head, Mid-frequency, and Tail segments according to their occurrence frequency. This experimental design enables a systematic investigation of model behavior in both data-abundant and data-scarce conditions.

Evaluation was conducted using a combination of accuracy-oriented and diversity-oriented metrics. Standard metrics such as Precision@N, Recall@N, and F1-score were used to assess recommendation correctness. In addition, to directly measure the mitigation of popularity bias, a TailShare@N metric was introduced, defined as the proportion of long-tail occupations appearing in the top-N recommendation lists across all users. Furthermore, Intra-List Diversity was employed to verify that the model provides a broad range of occupational options rather than shifting recommendations toward a narrow subset of niche roles.

Experimental results indicate that the proposed framework maintains competitive performance on Head occupations while demonstrating substantial improvements in the Tail segment. Compared with baseline neural collaborative filtering approaches, the proposed model exhibits significantly more stable performance when interaction data are scarce. The TailShare results further show that rare occupations appear more frequently in top-ranked recommendation lists, suggesting that the model effectively

resists popularity bias. Visualization of the learned embedding space reveals that specialized occupations form tighter and more coherent clusters under the proposed approach, whereas traditional methods tend to collapse these occupations into diffuse regions dominated by popular roles.

In conclusion, this research demonstrates that the long-tail problem in job recommendation systems is not an inherent limitation but a challenge that can be addressed through the integration of structural knowledge and meta-learning techniques. By leveraging a Job – Skill Knowledge Graph and GCN-based representation learning, the proposed framework provides meaningful semantic embeddings even for occupations with little or no interaction data. The incorporation of Prototypical Few-Shot Learning further enables accurate and flexible matching in extreme cold-start scenarios, thereby mitigating popularity bias and promoting more diverse recommendations.

Future work will focus on incorporating temporal dynamics into the knowledge graph to model the evolving relevance of skills over time, allowing the system to adapt to technological change. In addition, large-scale human-in-the-loop evaluations will be conducted in collaboration with professional career counselors to qualitatively assess the usefulness and practical value of long-tail recommendations. Through these extensions, the proposed approach aims to contribute to the development of more equitable, adaptive, and human-centered career recommendation systems.

## 概要

近年の労働市場は、急速なデジタル化や技術の高度化、ならびに産業構造の細分化を背景として、大きな構造的変化を遂げている。これに伴い、オンライン求人プラットフォームや専門職向けネットワークサービス、企業の人事管理システムなどを通じて、大規模な職業関連データが蓄積されるようになった。一方で、これらのデータは均一に分布しているわけではなく、多くの場合、べき乗則に従うロングテール構造を示すことが知られている。

実際のデータセットにおいては、一般事務職や汎用的なソフトウェアエンジニア職、小売・販売職といった「頭部職業」が大部分のサンプル数やインタラクションを占めている。一方で、高度に専門化された技術職、地域特化型の職業、新たな社会的要請に基づいて誕生した職業（例えば、グリーン経済や AI 倫理に関連する職種など）は、「ロングテール」領域に位置し、利用可能なデータが極めて限られている。このような職業では、従来の機械学習モデルにおいて安定したパラメータ推定を行うために必要なサンプル数を確保できないことが多く、推薦精度の低下が生じやすい。

この問題の根底には、既存の推薦アルゴリズムに内在する人気バイアスの存在がある。協調フィルタリングやそのニューラル拡張手法は、ユーザーと職業のインタラクション行列の密度に強く依存している。インタラクション数が少ない職業では、十分な勾配情報が得られないため、潜在表現の学習が不安定となり、結果として埋め込み表現の品質が大きく低下する。その結果、推論時には学習が十分に進んだ高頻度職業が優先的に推薦され、全体的な評価指標を最大化する方向にモデルが偏る傾向が生じる。

このようなメカニズムは、人気のある職業がさらに多く推薦され、インタラクションが集中する一方で、希少だが適合性の高い職業が可視化されにくくなるという自己強化的なフィードバックループを生み出す。職業推薦の文脈において、これは単なる技術的課題にとどまらず、求職者のキャリア選択肢を狭め、専門分野や新興分野への人材流動を阻害し、スキルと職業のミスマッチを助長する可能性がある。したがって、ロングテール職業における人気バイアスの緩和は、公平で有効な職業推薦システムを構築する上で不可欠な課題である。

このような背景のもと、本研究では、データ量に依存した学習から脱却し、構造的知識を活用した表現学習へとパラダイムを転換するハイブリッド手法を提案する。具体的には、職業間の関係性を捉えるためにグラフ畳み込みネットワーク (GCN) を用い、極少数サンプル下での判別を可能にするためにプロトタイプ型 Few-Shot Learning (FSL) を組み合わせた枠組みを構築する。

提案手法の基盤となるのは、職業とスキルの関係を明示的に表現した職業・スキル知識

グラフである。このグラフでは、ノードとして職業およびスキルを定義し、職業が要求するスキルの重要度や共起関係に基づいて重み付きエッジを構築する。これにより、インタラクションデータが乏しい職業であっても、スキルという意味的共通基盤を通じて他の職業との関連性を表現することが可能となる。

この知識グラフに対して GCN を適用することで、各職業ノードは近傍ノードから情報を集約し、反復的に表現を更新する。これにより、データが極端に少ない職業であっても、構造的に関連する職業から意味的特徴を継承した埋め込み表現を獲得できる。例えば、医療分野に特化したクラウドセキュリティ職のような希少職種であっても、サイバーセキュリティやクラウド基盤関連職種との関係性を通じて、意味的に妥当な表現が形成される。

しかし、GCN による表現学習のみでは、極端なコールドスタート環境における推薦判断を十分に行うことは困難である。そこで本研究では、第二段階としてプロトタイプ型 Few-Shot Learning を導入する。Few-Shot Learning は、少数のラベル付きデータから新たなクラスに一般化することを目的とした学習枠組みであり、本研究ではエピソード学習を採用することで、実運用時の少数サンプル状況を学習過程に反映させている。

各エピソードでは、職業ごとにごく少数のサンプルからなるサポートセットと、評価用のクエリセットを構成する。ユーザーおよび職業の埋め込み表現は、共通の距離空間へと射影され、サポートセットの平均として職業プロトタイプが計算される。推薦は、ユーザー表現と各職業プロトタイプとの距離に基づくランキング問題として定式化される。このような枠組みにより、推薦判断は出現頻度ではなく相対的な類似性に基づいて行われ、希少職業に対しても柔軟な一般化が可能となる。

提案手法の有効性を検証するため、15 万件以上の職業プロフィール、約 2000 種類の職業カテゴリ、および 1 万 2000 以上のスキルを含む大規模実データを用いた評価実験を行った。職業は出現頻度に基づいて頭部、中頻度、ロングテールの三領域に分類し、データ量の違いによる性能変化を詳細に分析した。

評価指標としては、Precision、Recall、F1 値といった標準的な精度指標に加え、ロングテール職業の露出度を直接評価するための TailShare 指標を導入した。また、推薦結果の多様性を確認するために、Intra-List Diversity を用い、推薦が特定の職業群に偏っていないかを検証した。

実験結果から、提案手法は頭部職業において既存手法と同等の性能を維持しつつ、ロングテール領域において顕著な性能向上を示すことが確認された。特に、従来手法では性能が大きく低下するロングテール環境においても、安定した推薦精度を維持できる点が特徴である。さらに、TailShare 指標の改善により、希少職業が推薦結果に適切に含まれることが示された。

以上より、本研究は、職業推薦におけるロングテール問題が、構造的知識とメタ学習を組み合わせることで克服可能であることを示した。GCN を用いた知識グラフ表現により、データ不足職業に意味的基盤を与え、Few-Shot Learning によって少数サンプル下での高精度推薦を実現する。本手法は、人気バイアスを緩和し、より多様で公平なキャリア推薦を可能にする点で意義を有する。

今後の課題としては、スキルの陳腐化や重要度の変化を考慮した時間的ダイナミクスの導入が挙げられる。また、キャリアカウンセラー等の専門家を交えた Human-in-the-Loop 評価を通じて、ロングテール推薦が実際のキャリア形成にどのような価値をもたらすかを質的に検証する予定である。

# 目次

<b>第 1 章</b>	<b>研究背景</b>	<b>1</b>
1.1	推薦システムの社会的役割と応用分野 . . . . .	1
1.2	職業推薦・人材マッチング分野における現状 . . . . .	2
1.3	データ駆動型手法の普及と課題 . . . . .	2
1.4	本研究の目的 . . . . .	3
1.5	本論文の構成 . . . . .	3
<b>第 2 章</b>	<b>関連研究</b>	<b>4</b>
2.1	職業推薦・人材マッチングに関する研究 . . . . .	4
2.2	推薦システムにおける代表的手法 . . . . .	5
2.3	既存推薦手法における少数職業推薦の課題 . . . . .	7
2.4	ロングテール・少数データに関する研究 . . . . .	8
2.5	本章のまとめ . . . . .	9
<b>第 3 章</b>	<b>提案手法</b>	<b>10</b>
3.1	本研究における職業推薦の基本方針 . . . . .	10
3.2	職業スキル情報に基づく特徴表現 . . . . .	12
3.3	ロングテール・少数データに関する研究 . . . . .	14
3.4	ロングテール・少数データに関する研究 . . . . .	16
3.5	Few-Shot Learning による少数職業への対応 . . . . .	16
<b>第 4 章</b>	<b>実験・評価</b>	<b>18</b>
4.1	実験設定 . . . . .	18
4.2	比較手法 . . . . .	21
4.3	実験結果 . . . . .	22
4.4	考察 . . . . .	26

第 5 章	結論	28
5.1	本研究の総括 . . . . .	28
5.2	今後の課題 . . . . .	29
	謝辞	30
	参考文献	31

# 図目次

2.1	コンテンツベース概念図 . . . . .	5
2.2	協調フィルタリング概念図 . . . . .	7
2.3	ロングテール概念図 . . . . .	8
3.1	CBF と提案手法の比較図 . . . . .	11
3.2	従業員グラフ概念図 . . . . .	15
4.1	近接化（過平滑化）の検証 . . . . .	23
4.2	堅牢性検証 . . . . .	24

# 表目次

3.1	O*NET における職業とスキル構成例 . . . . .	12
4.1	CBF と GCN + FSL による職業推薦性能の比較 (Top-1 Accuracy) . .	23
4.2	Few-Shot 設定における CBF と GCN + FSL の職業推薦性能比較 . . .	25
4.3	各職業区間におけるロングテール推薦性能の比較 . . . . .	25

# 第 1 章

## 研究背景

### 1.1 推薦システムの社会的役割と応用分野

近年、情報通信技術の発展により、インターネット上で取り扱われる情報量は急速に増大している。このような環境では、利用者が膨大な選択肢の中から、自身に適した情報を効率的に選択することが難しくなっている。こうした課題に対する一つの解決手段として、推薦システムが広く利用されている。

推薦システムは、利用者の嗜好や行動履歴をもとに、利用者にとって有用であると考えられる情報や対象を提示する情報処理技術である [1]。これにより、利用者は情報探索に要する負担を軽減でき、サービス提供者側にとっても、利用者満足度の向上や意思決定支援につながる。

推薦システムの応用分野は、電子商取引分野における商品推薦、動画や音楽配信サービスにおけるコンテンツ推薦、ニュースサイトや SNS における情報推薦など、多岐にわたる [2]。これらの分野では、利用者の過去の行動履歴や閲覧履歴を活用した個別化された推薦が行われている。

さらに、推薦システムは人材マッチングや職業推薦といった分野などにも応用が進んでいる [3]。これらの応用では、単なる嗜好の類似性に基づく推薦でなく、個人のスキルや経験と職業との関係をどのように捉えるかが重要な課題となる。

このように、推薦システムは多様な分野で活用されている一方で、応用分野の拡大に伴い、推薦対象の多様化やデータ構造の複雑化といった新たな課題も生じている [4]。

## 1.2 職業推薦・人材マッチング分野における現状

近年、技術革新や自動化の進展に伴い、職業構成や求められるスキル構造が変化していることが指摘されている [5]。このような環境では、個人が自身に適した職業を見つけることや、企業が求める人材を効率的に探索することが、従来に比べて難しくなっている。

現在の職業推薦・人材マッチングサービスでは、履歴書や職務経歴書に記載された情報、保有スキル、過去の職務経験などをもとに、求職者と職業との適合度を評価する方法が広く用いられている [6]。これらの手法は、条件に基づいた検索や絞り込みを行う点では有効である。

しかし、実際の人材データや職業データは、十分な量が常に確保されているとは限らない。新規ユーザ/新規アイテムで履歴が乏しいコールドスタート問題では推薦精度が不安定になることが指摘されている。そのため、特に新卒者や転職初期の求職者、新たに定義された職業や専門性の高い職業についての推薦精度には課題が残る [7]。

また、職業推薦では、単純なスキル一致だけでなく、職業間の類似性や関連性、キャリアパス上のつながりといった関係性を考慮することが重要である [8]。しかし、多くの既存システムでは、職業や人材を独立した要素として扱う傾向があり、こうした関係性が十分に活用されていない。

さらに、職業データには分布の偏りが存在し、一部の職業にデータが集中する一方で、データ量の少ない職業も多く存在する。このような偏りは、推薦結果が特定の職業に集中しやすくなる要因となる。

## 1.3 データ駆動型手法の普及と課題

近年、計算資源の向上および機械学習技術の発展により、データに基づいてモデルを構築する手法が広く用いられるようになってきている。推薦システム分野においても、大量のデータから利用者の行動傾向を学習し、推薦を行うアプローチが一般的となっている [9]。

職業推薦や人材マッチングにおいては、求職者のスキル情報や職務経歴、応募履歴などのデータを利用することで、条件に基づく検索に比べて柔軟な推薦が可能となっている。

一方で、データに基づく手法は、学習に利用できるデータの量やその分布に強く依存する [10]。十分なデータが得られない場合には、学習結果が不安定になり、推薦結果に偏りが生じることがある。特に、職業数が多く、職業ごとのデータ量にばらつきがある状況では、この傾向が顕著となる。

また、過去のデータに基づいて学習を行う手法では、出現頻度の低い「ロングテール」に属する職業への対応が課題となる。こうした希少なアイテム（職業）はデータの希薄化（Data Sparsity）の問題を引き起こし、一般的な手法では十分な推薦品質を得ることが難しい [11]。特に新た出現した職業においては、この傾向がより顕著となる。さらに、モデルの内部構造が複雑になるにつれて、推薦結果の根拠を明確に説明することが難しくなるという側面も指摘されている [12]。

## 1.4 本研究の目的

本研究の目的は、職業推薦タスクにおいて職業ごとのデータ量に大きな偏りが存在する状況を想定し、データ量の少ないロングテール職業に対する推薦性能の向上を目的とした推薦手法を構築し、その有効性を検証することである。従来の嗜好類似性のみに基づく推薦手法では、十分な学習データを持たない職業に対して適切な推薦を行うことが難しく、推薦結果が一部の高頻度職業に偏る傾向がある。

そこで本研究では、従業員が有するスキルや経験に着目し、それらと職業との関係性を考慮した表現を用いることで、ロングテール職業に対しても有効な推薦を行う枠組みを検討する。

## 1.5 本論文の構成

本論文の構成は以下のとおりである。第 1 章では、研究背景および既存研究における課題を整理したうえで、本研究の目的を述べる。第 2 章では、職業推薦システムおよび関連する推薦手法に関する既存研究について概観する。第 3 章では、本研究で提案する推薦手法の全体構成および GCN を用いた表現学習の方法について説明する。第 4 章では、実験設定および評価指標を示し、提案手法の有効性を実験結果に基づいて検証する。最後に第 5 章では、本研究のまとめと今後の課題について述べる。

## 第2章

# 関連研究

### 2.1 職業推薦・人材マッチングに関する研究

職業推薦および人材マッチングに関する研究では、求職者と職業との適合関係をどのように表現し、推定するかが主要な検討対象となってきた。既存研究においては、テキストデータから求職者や職業のスキル情報を抽出し [13]、それらを特徴量の集合として表現することで、両者の適合性を評価する試みが行われている。

従来の研究では、求職者のスキル、経験年数、資格などの情報を用いて個人を特徴ベクトルとして表現し [14]、職業側についても要求スキルや職務内容に基づく特徴量を定義することで、両者を同一の特徴空間上で扱う手法が提案されてきた。このような表現に基づき、職業推薦は適合度推定問題、分類問題、あるいはランキング問題として定式化される場合が多い。

職業を単なるカテゴリとして扱うのではなく、職務内容やスキル [15] 構成に着目して表現することで、職種の特徴をより精緻に捉えようとする研究も報告されている。このような表現学習は、求職者と職業との対応関係を分析する上で有用であると考えられる。

このように、職業推薦・人材マッチングに関する既存研究では、求職者および職業の表現方法や、両者の関係をどのような学習問題として定式化するかについて、多様なアプローチが提案されてきた。

## 2.2 推薦システムにおける代表的手法

### 2.2.1 コンテンツベース推薦

コンテンツベース推薦は、利用者や推薦対象が持つ属性情報に基づいて類似性を評価し、推薦を行う手法である [16]。利用者の過去の選択や行動履歴から特徴を抽出し、それと類似した特徴を持つ対象を推薦する。

図 2.1 に、本手法による職業推薦の概念図を示す。この手法では、推薦対象（職種）をスキル等の属性ベクトルとして表現し、利用者の嗜好（保有スキル）を同様に特徴空間上で表現することで、両者の類似度を計算する。例えば図中の例では、求職者が「プログラミング」「データ分析」「英語」というスキルセットを持つ場合、アイテムデータベース内の職種の中から、同様のスキル属性を持つ「ソフトウェアエンジニア」や「データサイエンティスト」が類似性の高い対象として抽出され、推薦される。一方、保有スキルと属性が大きく異なる「介護士」のような職種は、類似度が低いため推薦候補から除外される。また、コンテンツベース推薦は、利用者が過去に選択した対象との関係に基づいて推薦を行うため、推薦理由を属性レベルで説明しやすいという特徴を持つ。一方で、あらかじめ定義された特徴表現に基づいて推薦が行われるため、特徴設計の内容が推薦結果に大きな影響を与える。

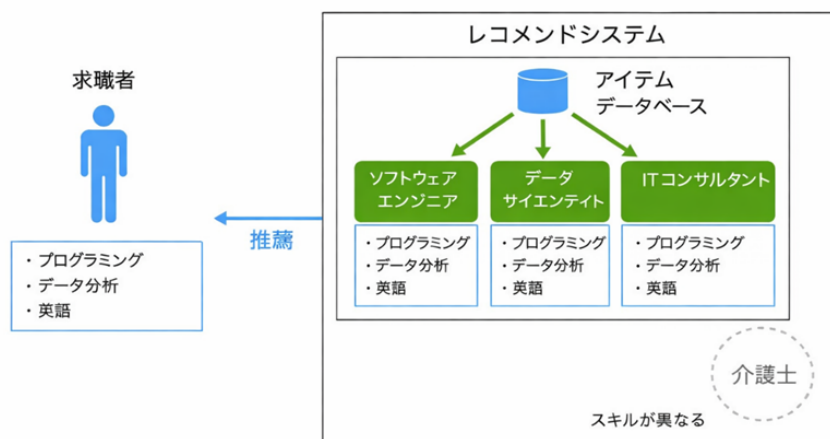


図 2.1 コンテンツベース概念図

推薦は、このように計算された類似度に基づいて行われるため、他の利用者の行動データに依存せず、個々の利用者に対して独立した推薦が可能である。また、属性レベルでのマッチングを行うため、「特定のスキルを保有しているからこの職種を勧める」といった推薦理由の提示が容易であるという特徴を持つ。一方で、あらかじめ定義された特徴表現に依存するため、属性設計の内容が推薦精度に大きな影響を与える。

### 2.2.2 協調フィルタリング

協調フィルタリングは、利用者とアイテム間の行動履歴や評価情報をもとに、類似性を推定し、推薦を行う手法である [17]。利用者同士、あるいはアイテム同士の行動パターンの類似性を計算し、それに基づいて推薦対象を決定する点に特徴がある。

代表的な手法としては、利用者間の類似性に基づくユーザベース手法や、アイテム間の類似性に基づくアイテムベース手法が挙げられる。また、利用者とアイテムの関係を行列として表現し、その潜在構造を学習する行列分解に基づく手法も広く研究されている [18]。

図 2.2 に、就職支援における本手法の概念図を示す。本手法では、特定の求職者に対し、「スキルや経歴が類似した他者の行動」を参照することで推薦を行う。例えば図中の例では、ターゲットとなる求職者と経歴が似ている他者が、過去に「システムエンジニア」や「データアナリスト」に応募していた場合、それらの職業を適合度の高い対象として推薦する。また、類似した他者が「ロボットエンジニア」や「商品企画」へ応募・就業した実績があれば、ターゲット自身にその経験がなくても、「志望する可能性がある職種」として新たな選択肢を提示することが可能である。

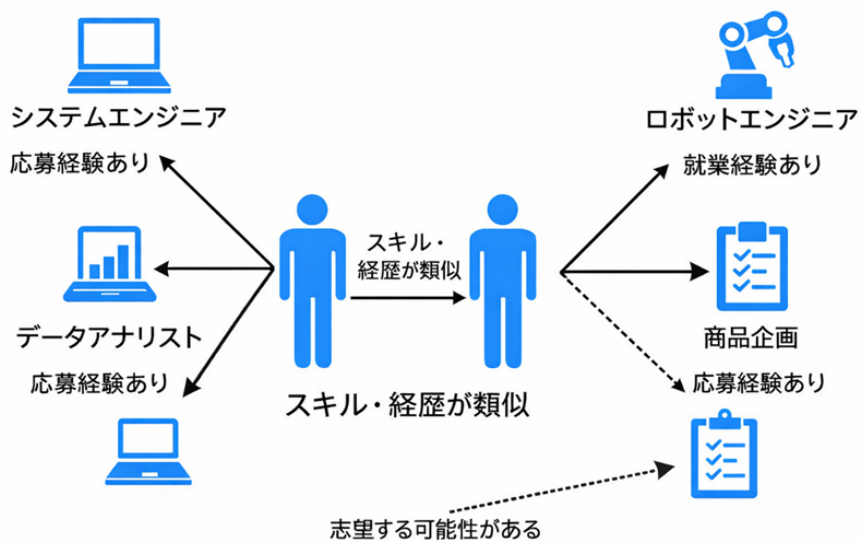


図 2.2 協調フィルタリング概念図

このように、協調フィルタリングは職業の明示的なスキル属性を事前に定義する必要がなく、行動履歴のみから「他の似た人が選んでいる」という事実に基づいた柔軟な推薦を可能にしている。

## 2.3 既存推薦手法における少数職業推薦の課題

既存の推薦システムにおいて広く用いられているコンテンツベース推薦および協調フィルタリングは、多くのタスクにおいて有効性が確認されている [19]。一方で、推薦対象となる職業のサンプル数が限られている場合、これらの手法は十分な性能を発揮できない場合があることが指摘されている [20]。

コンテンツベース推薦では、職業の属性情報やスキル情報に基づいて推薦を行うため、対象となる職業の特徴を適切に表現できるかどうかは性能に大きく影響する。しかし、データ量の少ない職業については、特徴情報が限定的である場合も多く、職業の特性を十分に捉えることが難しい。このため、類似度計算に基づく推薦が不安定になる可能性がある。

また、協調フィルタリングでは、ユーザと職業のインタラクション履歴をもとに類似性を推定するため、履歴データが乏しい職業に対しては、類似性の計算自体が困難となる。このような場合、新規職業や応募数の少ない職業は推薦対象として扱われにくくなる傾向

がある。

このように、既存の代表的な推薦手法は、職業数が多く、かつ職業ごとのデータ量にばらつきが存在する環境において、特にデータ量の少ない職業に対する推薦が難しいという共通の課題を抱えている。

## 2.4 ロングテール・少数データに関する研究

推薦システムに関する研究において、データ分布の偏り、特にロングテール構造に着目した分析が数多く報告されている [21]。ロングテール構造とは、一部の対象に多数のサンプルが集中する一方で、多くの対象が少数のサンプルしか持たない分布特性を指し、推薦タスクにおいて一般的に観察される特徴である。

就職支援の文脈において、図 2.3 の「データ量／応募数」の偏りは、特定の人気職種への応募集中を意味する。例えば、図中の「ヘッド職業」には、事務職や一般的な営業職といった求人数・応募者数ともに多い職種が位置し、モデルの学習に利用可能なデータが豊富に存在する。一方で、「ロングテール職業」には、専門性の高い技術職や希少な職種が含まれ、これらは「多くの職業が少数のデータしか持たない」という状態にある。

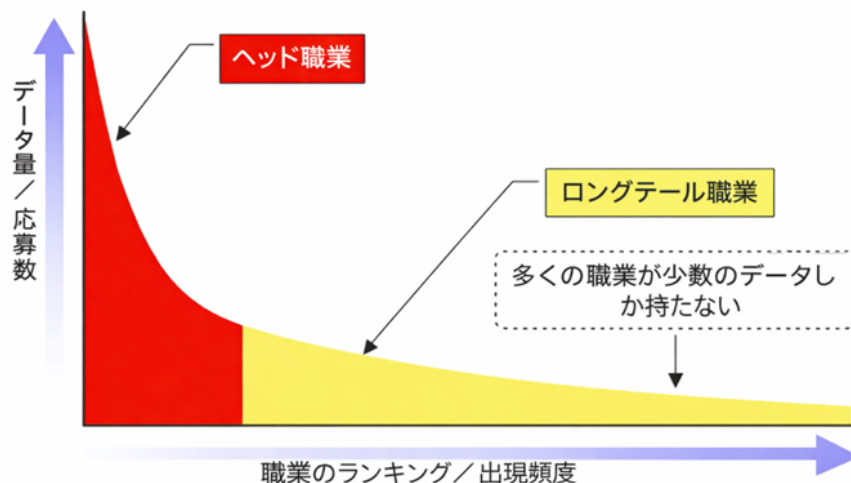


図 2.3 ロングテール概念図

既存研究においては、ロングテール分布を持つデータに対する学習や評価の在り方について、さまざまな観点から議論が行われている。特に、対象ごとのサンプル数の偏りは、

推薦結果が一部の人気対象に集中する要因となることが報告されている [22]。ヘッド職業では統計的に安定した学習が可能であるのに対し、データが枯渇しているロングテール職業では、個々の職種の特徴を十分に学習できず、推薦結果から除外されやすいという課題がある。

また、ロングテール構造を持つデータでは、評価の観点からも課題が存在する。全体的な性能指標のみを用いた評価では、データ量の少ない対象に対する推薦性能を適切に把握できない可能性があるため、対象の出現頻度に応じた分析や評価方法を採用する研究も行われている [23]。

さらに、一部の研究では、データ量の少ない対象に対して、対象間の類似性や関係性に着目することで、推薦性能の向上を図ろうとする試みが報告されている。このようなアプローチでは、個々の対象を独立に扱うのではなく、関連する他の対象との関係を考慮することが重要な視点として位置付けられている [24]。

## 2.5 本章のまとめ

本章では、職業推薦および人材マッチング分野に関する既存研究を整理し、代表的な推薦手法、ならびにロングテール構造や少数データ条件に関する研究動向について概観した。これらの研究から、既存手法は有効である一方で、データ量の少ない職業や新規職業に対する適応には課題が残されていることが示唆される。次章では、これらの課題を踏まえ、本研究で提案する手法の概要について述べる。

## 第 3 章

# 提案手法

### 3.1 本研究における職業推薦の基本方針

本研究は、職業推薦タスクにおいて、職業数の多さやデータ分布の偏りによって生じる推薦の困難性に対応することを目的とする。特に、データ量の少ない職業に対しても、安定した推薦を実現するための枠組みについて検討する。

この目的のため、本研究では職業を単独のカテゴリとして扱うのではなく、各職業が要求するスキル情報に着目し、職業間の関係性を考慮した表現を用いる方針を採用する。これにより、個々の職業が持つ情報に加え、他の職業との関連性を反映した形で推薦を行うことを目指す。

図 3.1 は、従来のコンテンツベース推薦（CBF）と、本研究で提案する GCN + FSL 手法の違いを示した概念図である。

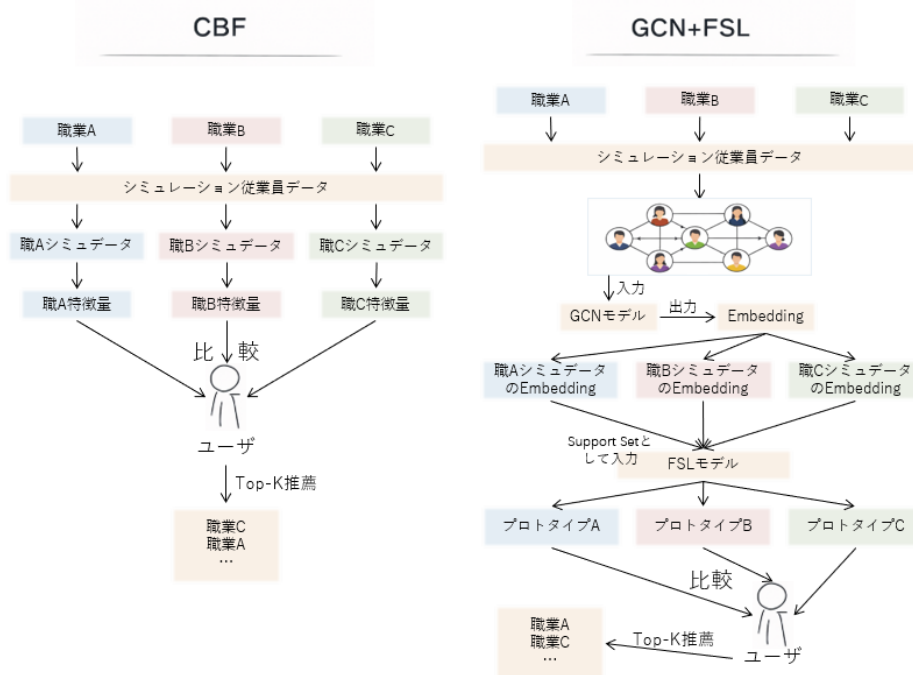


図 3.1 CBF と提案手法の比較図

従来の CBF では、各職業プロフィールを独立した特徴ベクトルとして扱い、ユーザーのスキルベクトルとの類似度を個別に計算する。そのため、職業間の潜在的な共通性や関連性が考慮されない。ここで、サンプル数の少ない職業においては、その職業の本質的な要求スキルではなく、特定のデータに含まれる特異な経歴やノイズが特徴表現に過大に反映される「過学習」に近い状態が生じる。その結果、特徴ベクトルが潜在空間上で不適切な位置に配置され、統計的な分散が大きくなるため、推薦性能が著しく不安定になるという課題がある。

一方、提案手法では、まず職業間のスキル共有関係に基づくグラフ構造上で GCN (Graph Convolutional Network) によるメッセージパッシングを行い、データが豊富な職業から少ない職業へ情報を伝播させる。これにより、個々の職業が持つ情報に加え、他職業との関係情報を反映したロバストな埋め込み表現を獲得する。さらに、この安定した表現を基盤として Few-Shot Learning (FSL) を導入することで、職業ごとのデータ量に大きな偏りがあるロングテールな状況においても、少数サンプルから職業の「プロトタイプ (代表表現)」を適切に推論し、高精度な推薦を可能とする。

以上の方針に基づき、本研究では、限られたデータから有効な職業表現を獲得し、新規職業やデータ量の少ない職業に対しても柔軟に対応可能な職業推薦手法の構築を基本方針

とする。

## 3.2 職業スキル情報に基づく特徴表現

### 3.2.1 O\*NET データの採用と職業ベクトルの定義

本研究では、職業推薦のための基礎データとして、米国労働省が提供する O\*NET (Occupational Information Network) [25] データセットを採用した。O\*NET は米国労働省の標準職業分類に基づく 879 種類の職種に対して、必要とされるスキルや能力が体系的に整理され、数値化されており、職業分析において高い信頼性を有している。

まず、各職業  $j \in \mathcal{J}$  について、対応するスキル項目とその重要度を用いて、職業を数値ベクトルとして表現する。各次元は特定のスキルに対応しており、その値は当該スキルが職業においてどの程度重要であることを示す。職業  $j$  の基準スキルベクトルを次式で定義する。

$$\mathbf{p}_j = [s_{j,1}, s_{j,2}, \dots, s_{j,D}]^\top \in R^D. \quad (3.1)$$

ここで、 $D$  はスキル項目の総数、 $s_{j,d} \in [0, 5]$  は職業  $j$  におけるスキル  $d$  の重要度スコアである。

表 3.1 O\*NET における職業とスキル構成例

職業	必要なスキル	重要さ (0-5)
Chief Executives	Reading Comprehension	4.12
Chief Executives	Active Listening	4.00
Chief Executives	Writing	4.12
Self-Enrichment Teachers	Reading Comprehension	3.12
Self-Enrichment Teachers	Active Listening	3.38
Self-Enrichment Teachers	Writing	3.00
⋮	⋮	⋮

### 3.2.2 シミュレーション従業員データ生成の必要性と背景

職業推薦システムの評価には、個々の従業員が保有するスキルセットを定量的に記述したデータが不可欠である。しかし、既存の求職者データセットを調査した結果、スキル情

報が自由記述形式で記録されており O\*NET のスキル体系と互換性がないことや、特定の職業にサンプルが偏っているため統計的な分析に適さないといった問題が確認された。また、実社会における詳細な従業員データは、個人のプライバシーや企業の機密情報に関わるため、網羅的な収集は困難である。

以上の背景から、本研究では O\*NET の職業スキル情報を基盤とし、数理モデルに基づいて人工的に従業員データを生成する手法を採用する。これにより、制御された実験環境下でアルゴリズムの性能を厳密に評価することが可能となる。

### 3.2.3 シミュレーション従業員データの分布特性

本研究では、職業間のデータ量の偏りが推薦精度に与える影響を多角的に分析するため、分布特性の異なる二種類の従業員データセットを構築した。

#### 1. 均一型データセット (Uniform Distribution)

職業間でデータ量の差が存在しない理想的な状況を想定し、全職業  $j$  に対して従業員数  $N_j$  が一定となるように設定した。具体的には、データ供給源となる組織の規模を 3 段階 ( $n_{\text{Large}} = 20$ 、 $n_{\text{Mid}} = 10$ 、 $n_{\text{Small}} = 5$ ) と仮想的に定義し、これらを組み合わせることで、各職業に対して一律で

$$N_j = 35 \quad (3.2)$$

名の従業員を生成した。

#### 2. ロングテール型データセット (Long-tail Distribution)

実際の労働市場で観察される、少数の主要職種に労働者が集中し、多くの専門職種では労働者が少ないという不均衡な分布を再現するため、職業ごとに異なる従業員数を設定した。全 879 職業に対し、JobID に基づく次の分段関数を用いて従業員数  $N_j$  を決定する。

$$N_j = \begin{cases} 500, & 1 \leq \text{JobID}(j) \leq 60 \\ 200, & 61 \leq \text{JobID}(j) \leq 200 \\ 50, & 201 \leq \text{JobID}(j) \leq 600 \\ 20, & 601 \leq \text{JobID}(j) \leq 879 \end{cases} \quad (3.3)$$

この設定により、少数のヘッド職種は大量のサンプルを持つ一方で、大多数のテール職種は極めて少数のサンプルしか持たない状況を構築する。

### 3.2.4 従業員スキルベクトルの生成アルゴリズム

各従業員のスキルベクトル生成にあたっては、同一職種内における個人の能力差や多様性を表現するため、職業基準ベクトル  $\mathbf{p}_j$  に対して確率的な分散を付加する。従業員  $e$  のスキルベクトル  $\mathbf{h}_e \in R^D$  は、次式によって定義される。

$$\mathbf{h}_e = \mathbf{p}_j + \boldsymbol{\epsilon}, \quad \boldsymbol{\epsilon} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I}). \quad (3.4)$$

ここで、 $\boldsymbol{\epsilon}$  は平均ベクトル  $\mathbf{0}$ 、共分散行列  $\sigma^2 \mathbf{I}$  を持つ多変量ガウス分布からサンプリングされるノイズ項である。 $\sigma$  はスキル分散を制御するパラメータであり、職業の特徴を保持しつつ適度な多様性が得られるよう設定した。

さらに、生成された各スキル要素が O\*NET の定義域を逸脱しないよう、以下の射影操作を適用する。

$$h_{e,d} = \max(0.0, \min(5.0, h_{e,d})). \quad (3.5)$$

以上の手順により生成された従業員データは、後続の KNN グラフ構築において、スキル空間上の近傍関係を定義するための基礎情報として利用される。

## 3.3 ロングテール・少数データに関する研究

本研究では、スキル構成が近い従業員同士の関係を明示的に扱うため、従業員をノードとするグラフ構造を構築する（図 3.2 参照）。本グラフにおいて、ノード間のエッジは従業員間のスキルの類似性を表している。例えば、図中の E1 から E5 は互いに類似したスキルセットを保有しているためエッジで結ばれているが、一方で E6 のように他の従業員とスキル構成が大きく異なる場合は、孤立したノードとして表現される。このようにグラフ構造を採用することで、単なる個々のデータ点としてではなく、労働市場における従業員間の相対的な関係性を考慮した推薦が可能となる。

従業員スキル類似度に基づくグラフ構造の概念図

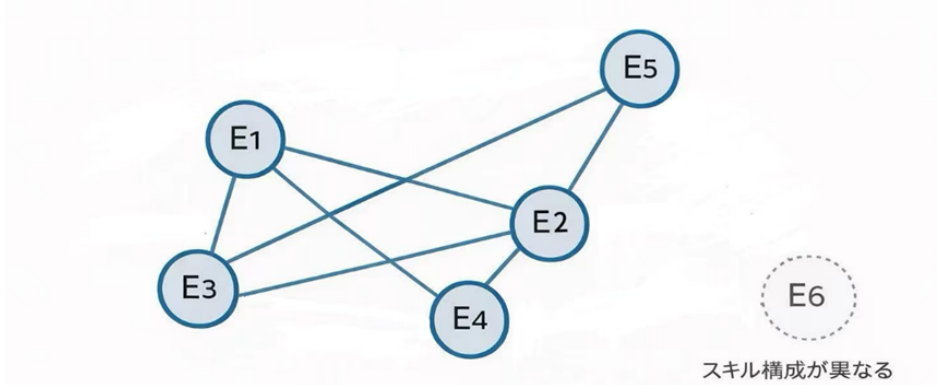


図 3.2 従業員グラフ概念図

各従業員は、保有スキルに基づく特徴ベクトルを持ち、従業員間の類似性に基づいてエッジを定義する。従業員集合を

$$E = \{e_1, e_2, \dots, e_{|E|}\} \quad (3.6)$$

とする。各従業員  $e_i$  は、スキル情報に基づく特徴ベクトル

$$\mathbf{x}_i \in R^d. \quad (3.7)$$

として表現される。

従業員間の類似度指標としてコサイン類似度を用い、すべての従業員間を接続するとグラフが過密になるため、 $K$  近傍法 (KNN) によりエッジを構築する。具体的には、各従業員  $e_i$  に対して類似度の高い上位  $K$  人の集合を近傍として選択し、これらの集合を

$$\mathcal{N}_K(e_i) \quad (3.8)$$

と定義する。これらの間にエッジを張る。

これにより、スキルが近い従業員同士が接続された疎なグラフが得られ、後続の表現学習において近傍情報を集約できるようになる。

ここで、各職種に基づいたデータ生成を行っているため、スキル類似度に基づく KNN グラフ構築において、同一職種内の従業員同士が接続されやすく、局所的なクラスターを形成する傾向がある。しかし、本研究のグラフ構築プロセスにおいては、職種ラベルによる制約を一切設けていない。そのため、異なる職種間であっても、スキル構成に共通性や高い類似性が認められる場合にはエッジが形成される。これにより、職種という既存の枠組みに縛られない、スキルベースの潜在的な関連性を捉えることが可能となっている。

### 3.4 ロングテール・少数データに関する研究

本研究では、前節で構築した従業員グラフを用いて、従業員間の関係性を考慮した表現学習を行う。そのための手法として、Graph Convolutional Network (GCN) を採用する。

GCN は、グラフ構造上のノード特徴を、近傍ノードの情報と統合しながら更新していく手法である [26]。これにより、各従業員は、自身が持つスキル情報だけでなく、類似した職業の情報を反映した表現を獲得することが可能となる。

本研究では、各従業員をノードとし、スキル情報に基づく特徴ベクトルを初期特徴として与える。GCN による従業員表現の更新は、隣接する従業員との関係を考慮しながら、次式により行われる。

$$\mathbf{H}^{(l+1)} = \sigma\left(\tilde{\mathbf{D}}^{-\frac{1}{2}}\tilde{\mathbf{A}}\tilde{\mathbf{D}}^{-\frac{1}{2}}\mathbf{H}^{(l)}\mathbf{W}^{(l)}\right), \quad (3.9)$$

ここで、 $\mathbf{H}^{(l)}$  は  $l$  層目における従業員ノードの表現行列を表し、初期状態  $\mathbf{H}^{(0)}$  は従業員のスキル特徴行列に対応する。また、 $\tilde{\mathbf{A}}$  は自己ループを加えた隣接行列、 $\tilde{\mathbf{D}}$  はその次数行列、 $\mathbf{W}^{(l)}$  は学習可能な重み行列、 $\sigma(\cdot)$  は活性化関数である。

この更新操作により、各従業員ノードは、近傍従業員の特徴を集約しながら表現を更新していく。結果として、従業員間のスキルの近さや関係性が、低次元の埋め込み表現として反映される。

本研究では、このようにして得られた従業員表現を用い、後続の推薦および Few-Shot Learning に基づく評価を行う。

### 3.5 Few-Shot Learning による少数職業への対応

本研究では、職業ごとのデータ量が極端に異なる状況を想定し、少数サンプルしか持たない職業に対しても精度高く推定が可能となるよう、Few-Shot Learning (少人数データ学習) の枠組みを導入する。現実の労働市場においては、一部の職業に従業員が集中する一方で、多くの職業では高度な専門性が求められるにもかかわらず、対象となるデータは少数であるという不均衡な分布が一般的である。

このような状況下では、従来の教師あり学習モデルでは学習データが不足する職業 (ロングテール職種) の推薦精度が低下するという課題がある。そこで、本研究では、各職業の代表的な特徴を少数のサンプルから抽出するプロトタイプネットワーク (Prototypical

Networks) の考え方を採用し、この課題を解決する。

まず、前節までで構築した GCN (Graph Convolutional Network) を用いて、従業員グラフ上の各従業員を低次元の埋め込みベクトル  $\mathbf{h}_e$  として表現する。次に、これらの埋め込みベクトルを用い、各職業  $j$  に属する少数の従業員データ (サポートセット)  $\mathcal{E}_j$  を抽出して、その平均をとることで職業プロトタイプ  $\mathbf{p}_j$  を次式のように構成する。

$$\mathbf{p}_j = \frac{1}{|\mathcal{E}_j|} \sum_{e \in \mathcal{E}_j} \mathbf{h}_e. \quad (3.10)$$

ここで、職業プロトタイプは、その職業が要求するスキルセットの中心をベクトル空間上で表現したものである。GCN を介した埋め込みを使用することで、各職業のサンプル数が少数であっても、グラフ構造を通じて集約された周辺のスキル情報をコンテキストとして反映できるため、単なる統計的な平均以上の頑健な職業表現を得ることが可能となる。

具体的な推薦プロセスにおいては、この構築された職業プロトタイプを基準としたメトリック学習 (度量学習) [27] の枠組みを適用する。推薦対象となる従業員  $e_q$  (クエリ) の特徴ベクトル  $\mathbf{h}_q$  が与えられた際、各職業  $j$  のプロトタイプ  $\mathbf{p}_j$  との類似度を算出する。本研究では、ベクトル間の角度の類似性を評価するため、以下の余弦類似度 (Cosine Similarity) を類似度スコアとして採用している。

$$\text{score}(e_q, j) = \frac{\mathbf{h}_q \cdot \mathbf{p}_j}{\|\mathbf{h}_q\| \|\mathbf{p}_j\|}. \quad (3.11)$$

算出されたスコアに基づき、全職業を適合度の高い順にランキングし、上位  $N$  件を推薦結果として提示する。

この手法の最大の利点は、職種ごとのラベルに直接依存した分類を行うのではなく、入力サンプルとプロトタイプとの距離に基づいてマッチングを行う点にある。これにより、学習データが極端に少ない職種であっても、プロトタイプを介して職種の本質的なスキル構成と従業員の保有スキルとの整合性を評価できる。

また、本研究では実験において、職業ごとのサンプル数を意図的に制限した Few-Shot 設定を用いることで、実社会のデータ分布に近い条件下での有効性を厳密に検証する。これにより、データ量の偏りに左右されない、汎用性の高い職業推薦システムの構築を可能にしている。

## 第4章

# 実験・評価

### 4.1 実験設定

本節では、本研究において行った実験の設定について説明する。使用したデータセット、従業員データの生成方法、グラフ構築およびモデル設定、ならびに評価タスクと評価指標について述べる。

#### 4.1.1 使用するデータセット

本研究の評価実験では、3.2節で述べたO\*NETデータを基盤として使用する。O\*NETは職業ごとのスキルや能力が体系化された信頼性の高いデータベースであり、本実験においては、特に職業ごとのスキル構成とその重要度（0～5の数値データ）に着目して評価を行う。

具体的には、3.2.1で定義したスキルベクトルを職業の表現として採用し、これに基づいて生成されたシミュレーション従業員データを用いて推薦精度の検証を行う。なお、本実験では職業名や説明文といったテキスト情報は用いず、スキルの数値情報のみに限定して分析を行うことで、スキルベースの推薦アルゴリズムの純粋な性能を評価する。

#### 4.1.2 従業員データの生成方法

O\*NETデータには実際の従業員データは含まれていないため、本研究では職業ごとのスキル情報をもとに、従業員データを人工的に生成した。具体的には、各職業に対応するスキルベクトルを基準とし、個人の能力差やスキルの多様性を表現するために、3.2.4項に基づき、従業員データを生成した。本実験では、スキルの多様性を適切に表現するため、

分散パラメータ  $\sigma$  を 0.25 に設定した。この設定値により、同一職業内でのスキルの重複を許容しつつ、異なる職業間の境界を判別可能なデータセットを構築した。これにより、職業推薦タスクの評価に必要な「従業員-職業」の関係データを疑似的に構築している。

本実験では、データ分布の違いが推薦精度に与える影響を検証するため、3.2.2 の定義に従い、以下の二種類のデータセットを用いた。

1. 均一分布データセット (Uniform Dataset) :

職業間のサンプル数の不均衡による影響を排除し、モデルの基礎的な推薦性能を評価することを目的とする。全 879 職種に対して均一なサンプル数を割り当てた理想的な環境であり、提案手法のベースラインとしての精度を確認するために使用する。

2. ロングテール分布データセット (Long-tail Dataset) :

実際の労働市場に即した不均衡な分布を再現したデータセットである。全職種をサンプル数に応じて「ヘッド」「ミドル」「テール」「極少数」の四段階に区分するロングテール構造を構築することで、特にサンプル数が限られた職種において、Few-Shot Learning を含む提案手法がどの程度有効に機能するかを検証する。

### 4.1.3 従業員データの生成方法

3.3 節で述べた手法に基づき、生成した従業員データを用いてグラフ構造の構築およびモデルの学習を行った。本節では、実験における具体的な設定値について説明する。

1.  $K$  近傍グラフの構築

各従業員のスキルベクトル間の類似度計算にはコサイン類似度を用い、 $K$  近傍法 ( $k$ -Nearest Neighbor) によってエッジを定義した。本実験では、グラフの接続性と計算効率のバランスを考慮し、近傍数を次のように設定した。

$$K = 10. \tag{4.1}$$

これにより、スキル構成が類似した従業員同士が接続された疎な隣接行列  $\mathbf{A}$  を構築した。

2. GCN モデルの構成

従業員埋め込みを学習するための GCN アーキテクチャとして、以下の設定を用いた。

- 層数：2 層
- 隠れ層の次元数：128
- 活性化関数：ReLU
- ドロップアウト率：0.5
- 学習率：0.01

学習によって得られた従業員埋め込みは、3.5 節で詳述した職業プロトタイプの構築および Few-Shot Learning に基づく職業推薦の評価に用いられる。

#### 4.1.4 評価タスクおよび評価指標

本研究では、提案手法の有効性を多角的に検証するため、以下の 3 つの評価タスクを設定した。

##### 1. 全職業推薦タスク (Global Recommendation)

各従業員に対し、全 879 職種を推薦候補としてスコア付けを行い、最も適合度の高い職種を 1 つ選択するタスクである。評価指標には Top-1 Accuracy を用い、全従業員に対する正解率を測定する。本タスクは、大規模な識別空間におけるモデルの基礎的な識別性能を評価することを目的とする。

##### 2. Few-Shot 分類タスク (N-way K-shot Classification)

少数サンプル条件下での学習能力を評価するため、メタ学習の枠組みを用いた 5-way 5-shot 設定を採用する。各エピソードにおいてランダムに 5 つの職種を選択し、各職種 5 件のサポートセットからプロトタイプを構築した上で、各 10 件のクエリセットを分類する。評価指標にはエピソードごとの平均精度 (Mean Accuracy) を用いる。

##### 3. 未知職業に対するコールドスタート評価 (Cold Start Evaluation)

学習時に一度も出現しなかった「未知の職業 (学習サンプル 0)」に対する推薦の頑健性を評価するタスクである。まず、全 879 職種のうち 156 職種をテスト専用の「コールドスタート職種」として完全に除外する。この際、出現頻度の影響を分析するため、「ヘッド」「ミドル」「テール」「極少数」の各区間からテスト職種をサンプリングする。残りの 723 職種を学習および推薦候補 (ターゲット) とし、テスト職種の従業員をクエリとして入力した際の推薦結果を分析する。評価指標には、上位 10 件の推薦結果に含まれるロングテール職種の割合を示す TailShare@10 を用いる。これにより、未知の入力に対し、モデルが人気バイアスに囚われず多様な職

種を提示できるかを検証する。

## 4.2 比較手法

本研究では、提案手法の有効性を検証するため、既存の代表的な推薦手法との比較を行った。比較手法としては、職業のスキル特徴のみに基づいて推薦を行うコンテンツベース推薦手法を用い、これをベースラインとした。

### 4.2.1 コンテンツベース推薦手法

コンテンツベース推薦手法では、職業および従業員をスキル特徴ベクトルとして表現し、両者の類似度に基づいて推薦を行う。具体的には、従業員が保有するスキルベクトルと、各職業のスキルベクトルとの間で類似度を計算し、その値が高い職業を推薦結果として出力する。

本研究では、類似度指標としてコサイン類似度を用い、すべての職業を推薦候補とした上で、上位の職業を順位付けすることで Top-K 推薦を行った。この手法は、職業間の関係性やデータ分布を明示的に考慮しない単純な推薦方法であるが、職業のスキル構成に基づく直感的な推薦が可能であり、比較手法として適している。

### 4.2.2 提案手法 (GCN + Few-Shot Learning)

提案手法では、第 3 章で定義したモデル構成および 4.1.3 項で詳述したハイパーパラメータに基づき学習および推論を行った。まず、GCN による表現学習フェーズでは、構築された K 近傍グラフを用いて従業員間の潜在的なスキル関係を埋め込みベクトルへと反映させた。学習プロセスでは、4.1.3 項の設定に従い、ベクトルが十分に収束するまで最適化を実施した。

次に、学習済みの GCN から得られた従業員埋め込みを用い、各職業のプロトタイプを構成した。推薦フェーズにおいては、3.5 節で定義した Few-Shot Learning の枠組みに従い、プロトタイプと対象従業員の余弦類似度に基づくランキングを実施した。

本実験では、特にロングテール分布データセットを用いることで、コンテンツベース手法では捉えきれない「グラフ構造を通じた潜在的なスキル関係」が、データ量の少ない職業（各 20 サンプル）の推薦においてどの程度寄与するかを重点的に検証する。

## 4.3 実験結果

本節では、前節で述べた実験設定に基づき、職業推薦および少数サンプル条件下での分類タスクに関する実験結果を示す。特に、従業員データの分布の違いが推薦性能に与える影響に着目し、均一分布データおよびロングテール分布データのそれぞれについて結果を比較する。

### 4.3.1 均一分布データにおける推薦結果

まず、各職業に属する従業員数が同程度となるように生成した均一分布データを用いて評価を行った。本研究では、同じデータに対して、評価条件の異なる二つの設定で結果を確認した。ひとつは全職業を推薦候補とする Top-1 推薦、もうひとつは少数クラスを想定した 5-way 5-shot のエピソード評価である。

#### 1. 全職業を候補とした Top-1 推薦（全職業 Top-1）

表 4.1 は、全職種を対象とした Top-1 推薦設定における、CBF と提案手法 (GCN + FSL) の精度比較を示している。評価指標として Top-1 Accuracy を用いた結果、CBF が 64% だったのに対し、GCN + FSL は 11% と大幅に低い値となった。

この結果については、職業プロトタイプに基づく表現が大規模な識別設定において不利に働いた可能性が考えられる。すなわち、従業員埋め込みを平均化して職種表現を構成するプロトタイプ化は、ノイズ除去や代表性向上の効果を持つ一方で、職種間の差異を縮約し、識別境界を曖昧化するリスクを伴うと考えられる。

Few-shot 分類の分野では、複雑なメタ学習手法よりも表現学習の質が性能に大きく寄与することが報告されている [28]。本研究においては、全職種を同時に識別する設定において、このようなプロトタイプ表現の性質が Top-1 精度の低下として顕在化した可能性がある。

一方、CBF は 35 次元の生スキル特徴量を直接比較するため、個別スキルの微細な差異を保持したまま類似度計算を行うことができる点が有利に作用したと考えられる。

実際に、カテゴリ間の区別がどの程度失われるかを検証するため、本研究では本章の主実験とは独立に構築したランダム生成のシミュレーションデータを用い、二つの仮想カテゴリ間の類似度を算出した。図 4.1 のように、CBF における両カテゴリのコサイン類似度は 0.65 であったのに対し、提案手法により生成されたプロト

タイプ間では 0.92 と著しく高い値を示した。

これは、GCN による情報伝播とプロトタイプ化が重なることで、各カテゴリ固有の特徴が埋め込み空間内で相殺され、過度に近接する（Over-smoothing）現象が生じたことを示唆している。

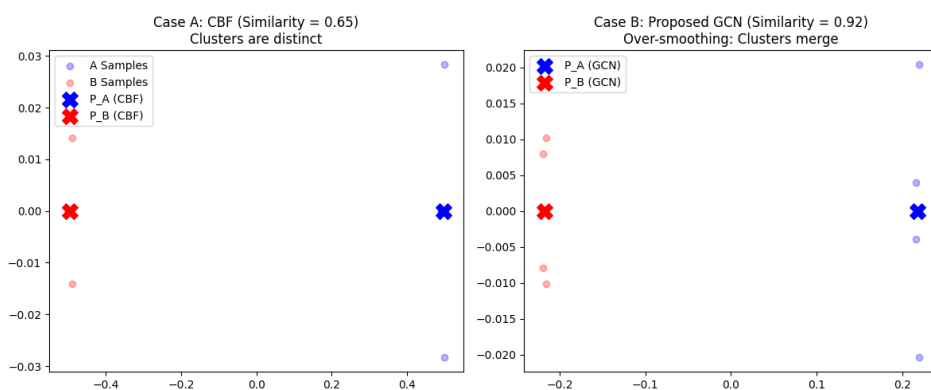


図 4.1 近接化（過平滑化）の検証

また、GCN による近傍情報の集約が、類似職種間の境界を曖昧にしたことも影響していると推察される。以上の結果から、全職種を一括で識別する広域な推薦においては Over-smoothing が課題となる一方、候補群が限定された状況下では、グラフ構造に基づく微細な関係性が有効に機能する可能性が考えられる。したがって、今後は「限定的な候補内での少数職種推薦」といったシナリオにおける本手法の有用性を詳しく検証する必要がある。

表 4.1 CBF と GCN + FSL による職業推薦性能の比較 (Top-1 Accuracy)

項目	CBF	GCN + FSL
入力	原始 35 次元スキル	GCN (+ FSL) 埋め込み
候補職業	全職業	全職業
出力	Top-1 職業	Top-1 職業
評価指標	Top-1 Accuracy	Top-1 Accuracy
結果	64%	11%

## 2. 5-way 5-shot によるエピソード評価 (5 職業に限定した推薦・識別)

表 4.2 は、候補職種を 5 職種に限定し、各職種 5 サンプルのサポートセットからプロトタイプを構築する 5-way 5-shot 設定における推薦精度の比較である。

結果を確認すると、CBF の Accuracy が 66% であるのに対し、提案手法 (GCN + FSL) は 78% と大幅に上回る精度を達成した。前述の「全職種推薦」における結果 (表 4.1) とは対照的に、候補職種を限定した Few-Shot 設定においては、提案手法の有効性が顕著に現れることが確認された。

この精度の逆転が生じた要因として、GCN による「構造的特徴の抽出」が挙げられる。CBF は個々のスキルの数値的一致のみに依存するため、サンプル数が極めて少ない状況では、個人のスキルのバラつき (ノイズ) の影響を受けやすい。一方で、提案手法は GCN を通じて従業員間のグラフ構造 (スキルの類似関係) を学習に取り入れているため、少数のサンプルからでも職種の本質的な特徴を捉えた堅牢 (Robust) なプロトタイプを構成できたと考えられる。

この堅牢性を具体的に検証するため、主実験とは独立に構築したランダム生成のシミュレーションデータを用い、少数サンプル条件下におけるプロトタイプ生成過程の挙動を分析した。図 4.2 のように、特定のサンプルに対して基準ベクトルから大きく乖離した特徴成分を付与した結果、CBF ではノイズが平均化によりそのまま反映され、類似度は 0.72 まで低下した。

一方、提案手法では、GCN による近傍集約を通じて外れ値の影響が緩和され、0.88 という高い類似度を保持することが確認された。

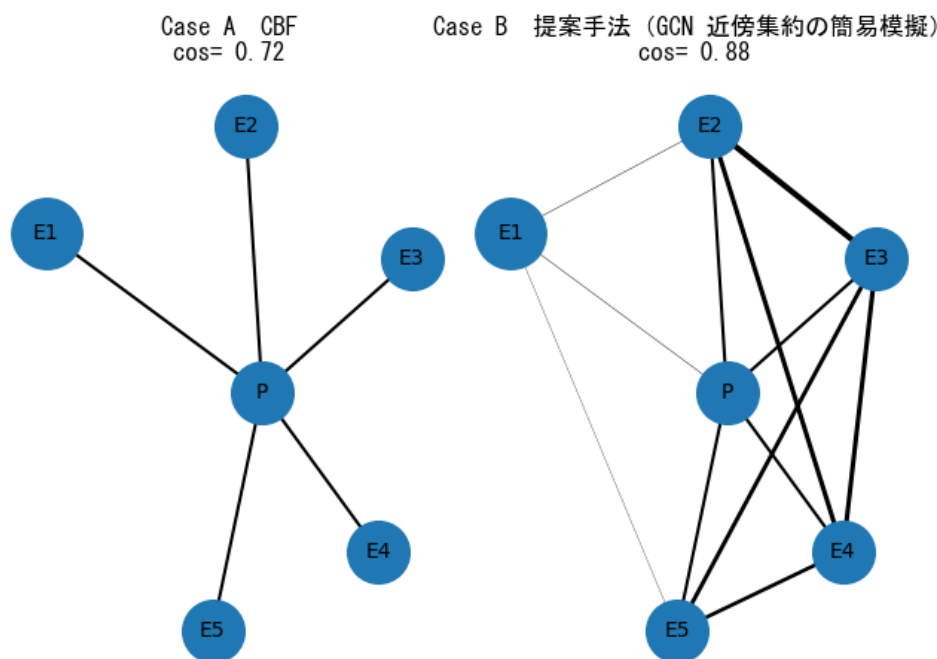


図 4.2 堅牢性検証

以上の結果は、本研究の核となる「グラフ構造に基づく表現学習」と「プロトタイプ理論による少数データへの適応」の組み合わせが、データ稀少性の高い職業推薦タスクにおいて極めて有効に機能することを示している。

表 4.2 Few-Shot 設定における CBF と GCN + FSL の職業推薦性能比較

項目	CBF	GCN + FSL
入力	35 次元スキル	GCN + FSL 埋め込み
候補職業数	5 職業	5 職業
サポートセット	5-shot	5-shot
クエリセット	10-query	10-query
評価方法	episode 平均 Accuracy	episode 平均 Accuracy
結果	66%	78%

#### 4.3.2 ロングテール分布データにおける推薦結果

本節では、実社会の労働市場を模したロングテール分布データを用い、提案手法が推薦結果の偏りをどの程度緩和し、多様な職業を提示できるかを検証した。表 4.3 に、各クエリ職業区間における TailShare@10（上位 10 件の推薦結果に含まれるロングテール職業の割合）の比較結果を示す。各値は、各職業区間に属するすべてのクエリに対して個別に TailShare@10 を算出し、その平均値と標準偏差（mean ± std）を示したものである。

表 4.3 各職業区間におけるロングテール推薦性能の比較

クエリ職業区間	JobID 範囲	クエリ人数	CBF	GCN+FSL
頭部職業	1-12	6000	0.312 ± 0.155	0.422 ± 0.147
中部職業	61-88	5600	0.284 ± 0.139	0.323 ± 0.155
中低頻度職業	201-280	4000	0.288 ± 0.141	0.330 ± 0.156
ロングテール職業	601-636	720	0.371 ± 0.143	0.375 ± 0.155

表 4.3 の結果より、すべてのクエリ職業区間において、提案手法（GCN+FSL）がベースラインである CBF を上回る TailShare@10 を記録した。特に、クエリが「頭部職業」に属する場合、提案手法の TailShare は 0.422 となり、CBF の 0.312 を大幅に上回る結果となった。これは、提案手法が未知の入力に対しても、推薦結果をロングテール側へ分

散させる傾向を持つことを示している。

なお、これらの結果に対する詳細な考察および分析については、4.4 節にて後述する。

## 4.4 考察

### 4.4.1 均一分布データにおける結果の考察

均一分布データを用いた実験では、各職業に属する従業員数がほぼ同程度であるため、すべての職業に対して十分な学習サンプルが存在する状況となっている。このような条件下では、職業ごとの特徴がデータとして明確に観測されやすく、単純な手法でも安定した推薦が可能である。

実験結果において、GCN + FSL が CBF を上回らなかった要因は、データ密度が十分に高い環境下では、グラフ構造による情報の補完や Few-Shot Learning による少ⓧ本への適応という本手法の強みが、相対的に機能しにくいためと考えられる。

一方で、サンプル数が極めて少ない「少数データ」のケースに注目すると、均一分布下では周囲の職種も同様に十分なデータを持つため、グラフを通じた関係情報の集約が過剰な平滑化を招き、各職種の個別の専門性が埋没した可能性がある。これに対し、ロングテール分布における少数職種では、データ不足を補う手段としてグラフ構造が有効に機能した。以上の結果は、提案手法が単にデータ分布に依存するだけでなく、「データが稀少な状況 (Few-Shot シナリオ) において、いかに構造情報を活用して不足を補えるか」という点にその有効性の本質があることを示している。

### 4.4.2 ロングテール構造が推薦結果に与える影響

ロングテール分布データを用いた実験では、一部の職業にデータが集中し、多くの職業でサンプル数が極めて少ない不均衡な状況下での性能を評価した。

実験の結果、CBF においては推薦結果が頭部職業へ偏る傾向が確認された。これは、CBF のアルゴリズム自体に頻度を優先する仕組みがあるわけではなく、データの性質とプロトタイプの質に起因するものと考えられる。具体的には、データ量の多い職種はスキルセットの汎用性が高く、スキル空間において多くのクエリと部分的に一致しやすい。一方で、ロングテール職種はサンプル不足によりプロトタイプの表現が不安定になりやすく、単純なベクトル類似度比較では相対的にスコアが低くなる。その結果、統計的に「より多く、一般的な特徴を持つ」職種に推薦が集中する「人気バイアス」が生じたと推察される [29]。

一方で、提案手法（GCN + FSL）がロングテール職業に対しても一定の推薦機会を与えられたのは、以下の2点が寄与していると考えられる。第一に、GCNにより職業間の構造的な関係性を学習に取り入れたことで、サンプル数が少ない職種の表現を近傍ノードの情報で補完できている点である。第二に、Few-Shot Learningの枠組みが「少数データからの特徴抽出」を前提としているため、識別空間において各職種の境界をより適切に定義できた点である。特に、頭部職業をクエリとした場合でも TailShare が向上した事実は、提案手法が単純な数値的一致を超えて、潜在的なキャリアの関連性を提示できていることを示唆している。

以上の考察から、ロングテール構造を持つ職業推薦においては、単なるベクトル間の類似度計算だけでなく、職種間の構造的な相関関係を明示的に考慮し、データの稀少性を補う手法が極めて重要であることが明らかとなった。

## 第 5 章

# 結論

### 5.1 本研究の総括

本研究では、労働市場において一般的に観察される「職業ごとの従業員（サンプル）数の著しい偏り」という課題に対し、グラフニューラルネットワーク（GCN）と Few-Shot Learning（FSL）を組み合わせた新たな職業推薦手法を提案した。

一連の実験を通じて得られた知見を以下にまとめる。

1. 少数サンプル条件における有効性 5-way 5-shot 設定を用いた少数職業分類タスクにおいて、提案手法はベースラインである CBF を 12% 上回る精度を達成した。これは、GCN による職業間の構造的な関係性の学習と、FSL による少数データからの特徴抽出が、データ稀少性の高い状況下で極めて有効に機能することを示している。
2. 未知の職業に対する頑健性学習データに存在しない「コールドスタート職種」をクエリとした実験において、すべての職業区間（頭部、中部、中低頻度、ロングテール）で CBF を上回る TailShare@10 を記録した。特に、一般的なスキルを持つクエリに対しても、提案手法は人気バイアスを抑制し、潜在的に適合するロングテール職種を提示できる多様性を備えていることが確認された。
3. 手法の適用境界一方で、全職業を一括で識別する大規模な推薦設定や、十分な学習サンプルが存在する均一分布下においては、CBF と比較して明確な優位性は見られなかった。このことから、提案手法は「データ分布の偏りが顕著な場面」や「限定された候補群からの少数職種推薦」においてその真価を発揮する手法であると位置付けられる。

## 5.2 今後の課題

本研究で得られた成果をさらに発展させるため、今後の課題として以下の点が挙げられる。

1. 人的評価による推薦妥当性の検証  
本研究ではオフライン指標（Accuracy、Tail-Share）を用いて評価を行ったが、提案手法が提示する「ロングテール職種」が、求職者にとって真に納得感のあるキャリアパスであるかを検証する必要がある。今後は、実際の求職者やキャリアアドバイザーを対象とした被験者実験を行い、推薦結果に対する満足度やキャリアの選択肢の広がりといった観点から、人的評価データを収集し、分析することが不可欠である。
2. 動的なスキル変化への対応  
新設される職種や、時代とともに変化するスキルセットを効率的にグラフ構造へ反映し、動的に学習を更新する枠組みの構築が求められる。

# 謝辞

本論文の完成にあたり、多くの方々から多大なるご支援とご協力を賜りました。

まず、主指導教官である長谷川教授に心より感謝申し上げます。先生には、研究の構想段階から論文の執筆に至るまで、終始熱心かつ丁寧なご指導をいただきました。特に、研究が行き詰まった際にかけていただいた的確なご助言や温かい励ましが、本研究を完遂する大きな支えとなりました。

次に、研究室の皆様へ深く感謝いたします。毎月のゼミにおいて、皆様からいただいた鋭いご質問や多角的な視点からのご意見は、私の思考を広げ、本研究の質を向上させる貴重な糧となりました。共に切磋琢磨し、自由に議論できる環境があったからこそ、今日の日を迎えることができました。

最後に、公私ともに支えてくれた家族、ならびに友人に心からの感謝を捧げます。

## 参考文献

- [1] Francesco Ricci, Lior Rokach, and Bracha Shapira. Introduction to recommender systems handbook. In *Recommender Systems Handbook*, pages 1–35. Springer, Boston, 2010.
- [2] Francesco Ricci, Lior Rokach, and Bracha Shapira. Recommender systems: Techniques, applications, and challenges. In *Recommender Systems Handbook*, pages 1–35. Springer, 2021.
- [3] Cong Zhu, Hongzhi Zhu, Hui Xiong, Cheng Ma, Fang Xie, Ping Ding, and Peng Li. Person-job fit: Adapting the right talent for the right job with joint representation learning. *ACM Transactions on Management Information Systems*, 9(3):1–17, 2018.
- [4] Matevž Kunaver and Tomaž Požrl. Diversity in recommender systems: A survey. *Knowledge-Based Systems*, 123:154–162, 2017.
- [5] David H. Autor. Why are there still so many jobs? the history and future of workplace automation. *Journal of Economic Perspectives*, 29(3):3–30, 2015.
- [6] Cheng Qin, Hongzhi Zhu, Tong Xu, Cong Zhu, Liang Jiang, Enhong Chen, and Hui Xiong. Enhancing person-job fit for talent recruitment: An ability-aware neural network approach. In *Proceedings of the 41st International ACM SIGIR Conference on Research and Development in Information Retrieval*, pages 25–34, 2018.
- [7] Apostolos Panteli and Vasileios Boutsinas. Addressing the cold-start problem in recommender systems based on frequent patterns. *Algorithms*, 16(4):182, 2023.
- [8] Nicholas Dawson, Melissa A. Williams, and Marian-Andrei Rizoiu. Skill-driven recommendations for job transition pathways. *PLOS ONE*, 16(8):e0254722, 2021.
- [9] Shuai Zhang, Lina Yao, Aixin Sun, and Yi Tay. Deep learning based recommender

- system: A survey and new perspectives. *ACM Computing Surveys*, 52(1):1–38, 2019.
- [10] Chen Sun, Abhinav Shrivastava, Saurabh Singh, and Abhinav Gupta. Revisiting unreasonable effectiveness of data in deep learning era. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 843–852, 2017.
- [11] Young-Joo Park and Alexander Tuzhilin. The long tail of recommender systems and how to leverage it. In *Proceedings of the ACM Conference on Recommender Systems*, pages 11–18, 2008.
- [12] Yongfeng Zhang and Xu Chen. Explainable recommendation: A survey and new perspectives. *Foundations and Trends in Information Retrieval*, 14(1):1–101, 2020.
- [13] Ilkka Kivimäki, Alexander Panchenko, Adrien Dessy, Damien Verdegem, Pascal Francq, Hugues Bersini, and Marco Saerens. A graph-based approach to skill extraction from text. In *Proceedings of TextGraphs-8*, pages 79–87, 2013.
- [14] Jing Jiang, Shu Ye, Wei Wang, Jun Xu, and Xue Luo. Learning effective representations for person-job fit by feature fusion. In *Proceedings of the 29th ACM International Conference on Information and Knowledge Management*, pages 2549–2556, 2020.
- [15] Ioannis Paparrizos, B. Barla Cambazoglu, and Aristides Gionis. Machine learned job recommendation. In *Proceedings of the Fifth ACM Conference on Recommender Systems*, pages 325–328. ACM, 2011.
- [16] Pasquale Lops, Marco De Gemmis, and Giovanni Semeraro. Content-based recommender systems: State of the art and trends. In *Recommender Systems Handbook*, pages 73–105. Springer, 2010.
- [17] Xiaoyuan Su and Taghi M. Khoshgoftaar. A survey of collaborative filtering techniques. *Advances in Artificial Intelligence*, 2009:421425, 2009.
- [18] Yehuda Koren, Robert Bell, and Chris Volinsky. Matrix factorization techniques for recommender systems. *Computer*, 42(8):30–37, 2009.
- [19] Gediminas Adomavicius and Alexander Tuzhilin. Toward the next generation of recommender systems. *IEEE Transactions on Knowledge and Data Engineering*, 17(6):734–749, 2005.
- [20] Saad T. Al-Otaibi and Mourad Ykhlef. A survey of job recommender systems. *International Journal of Physical Sciences*, 7(29):5127–5142, 2012.

- [21] Jianxin Chen, Handong Dong, Xiang Wang, Fuli Feng, Meng Wang, and Xiangnan He. Bias and debias in recommender system. *ACM Transactions on Information Systems*, 41(3):1–39, 2023.
- [22] Himan Abdollahpouri, Masoud Mansoury, Robin Burke, and Bamshad Mobasher. The unfairness of popularity bias in recommendation. *arXiv preprint arXiv:1907.13286*, 2019.
- [23] Harald Steck. Item popularity and recommendation accuracy. In *Proceedings of the ACM Conference on Recommender Systems*, pages 125–132, 2011.
- [24] Xiang Wang, Xiangnan He, Meng Wang, Fuli Feng, and Tat-Seng Chua. Neural graph collaborative filtering. In *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, pages 165–174, 2019.
- [25] O\*NET Online. O\*net online. <https://www.onetonline.org/>. Accessed: 2025-03-22.
- [26] Thomas N. Kipf and Max Welling. Semi-supervised classification with graph convolutional networks. *arXiv preprint arXiv:1609.02907*, 2016.
- [27] Jake Snell, Kevin Swersky, and Richard Zemel. Prototypical networks for few-shot learning. In *Advances in Neural Information Processing Systems*, volume 30, 2017.
- [28] Yonglong Tian, Yue Wang, Dilip Krishnan, Joshua B. Tenenbaum, and Phillip Isola. Rethinking few-shot image classification: A good embedding is all you need. In *European Conference on Computer Vision*, pages 266–282. Springer, 2020.
- [29] Himan Abdollahpouri, Robin Burke, and Bamshad Mobasher. Controlling popularity bias in learning-to-rank recommendation. In *Proceedings of the ACM Conference on Recommender Systems*, pages 42–46, 2017.