

# ClaimBrush: 特許審査官の選好を考慮した 選好最適化に基づいた特許請求の範囲の自動補正モデル

河野 誠也<sup>1,2</sup>, 野中 尋史<sup>3</sup>, 吉野 幸一郎<sup>4,1,2</sup>

<sup>1</sup> 理化学研究所ガーディアンロボットプロジェクト

<sup>2</sup> 奈良先端科学技術大学院大学 <sup>3</sup> 愛知工業大学 <sup>4</sup> 東京科学大学

{seiya.kawano, koichiro.yoshino}@riken.jp, hnonaka@aitech.ac.jp

## 概要

特許出願における特許請求の範囲の自動補正は、知的財産戦略の観点から極めて重要である。本研究では、データセットと書き換えモデルを含む特許文書の自動補正のための新しいフレームワーク“ClaimBrush”を提案する。具体的には、特許請求の範囲の自動補正モデルを学習・評価するためのデータセットを、特許審査過程における実際の特許請求の範囲の補正事例を大量に収集することによって構築した。構築したデータセットを用いて、大規模言語モデルを微調整することにより、特許請求の範囲の自動補正モデルを構築した。さらに、特許審査官による特許出願の拒絶査定を自動予測結果に基づいた選好最適化を適用することで、提案した特許請求の範囲の自動補正モデルの性能を向上させた。評価実験の結果、提案した特許請求の範囲の自動補正モデルは、経験則に基づいたベースラインや最先端の大規模言語モデルを用いたゼロショット学習手法を凌駕することが示された。さらに、特許審査官による拒絶査定を自動予測結果に基づいた選好最適化により特許文書の補正性能が向上することを示した。

## 1 はじめに

特許請求の範囲は、特許を受けようとする発明を特定するための重要な項目であり、一つ又は複数の「請求項」から構成される。請求項は、当該の発明が特許査定を受けるためや、既存の特許と比較してより強い権利を得るために、その記載内容を効果的に推敲することが重要である。しかしながら、一般に、請求項の推敲は多くの時間と労力を要する作業となることが多いため、効果的な請求項の推敲支援ツールが求められている。これまでに、特許検索やパテントマップ生成などの基本的な特許情報処理

のタスクに関する研究 [1, 2] や、特許請求の範囲の読解支援に関する研究 [3] は実施されている一方で、与えた特許請求の範囲を様々な観点からより良く書き換える（補正する）ような書き換え生成モデルに関する実質的な研究は不十分である。より効果的な特許の推敲支援を提供するためには、さまざまな観点から特許請求の範囲の補正案を提案するフレームワークの研究がさらに必要である。

本研究では、特許請求の範囲を自動補正することを目的とした、書き換えモデルと学習および評価用のデータセットを含む新しいフレームワーク“ClaimBrush”を提案する。我々は、特許審査における特許出願の承認前後のプロセスに焦点を当て、特許請求の範囲を特許査定される可能性の高い特許請求の範囲に書き換えるという観点からデータセットを構築する。具体的には、特許出願における審査プロセスに焦点を当て、審査前の特許出願における特許請求の範囲と、特許査定を受けた特許請求の範囲のペアを、特許実務的な観点からの特許請求の範囲の望ましい書き換えの例として見なす。これらの書き換えの例は、出願された発明が特許を受けるために特許審査プロセス中に出願人が行ったすべての修正（自発的な修正とオフィスアクション）への対応の両方の結果を反映する。したがって、特許審査の観点においては、書き換えられた特許請求の範囲は元の特許請求の範囲よりも洗練されており、書き換えモデルの学習および評価データとして使用できる [4, 5]。

構築したデータセットを使用して大規模言語モデル (Large Language Models; LLMs) を微調整することで、特許請求の範囲の自動補正モデルを構築する。さらに、特許審査官のオフィスアクションの予測結果に基づく選好最適化を適用することで、特許請求の範囲の自動補正モデルの性能を実際の特許実務的

な観点から強化する方法を提案する。具体的には、審査官が先行技術として引用した特許の特許の特許請求の範囲を考慮して、モデルによって生成された特許請求の範囲が受け入れられる可能性が高いか拒否される可能性が高いかを判断する自動予測モデルを開発し、これらの予測結果をモデルの最適化に使用する。評価実験の結果、提案モデルは小規模モデルであったとしても、経験則に基づいたベースラインモデルを上回るだけでなく、最先端の LLM におけるゼロショット学習よりも優れていることを示した。さらに、特許審査官の選好に基づく選好最適化により、特許請求の範囲の補正性能が大幅に向上することが実証された。

## 2 書き換えデータセットの構築

本研究では、2004 年から 2022 年に特許庁のシステムを通じて公開された特許公開公報情報 (A)、特許公報情報 (B9) の集合から、同一の特許出願番号を持つ公開公報 (A)、特許公報 (B9) の特許請求の範囲のペアを抽出した。一般に、多くの特許出願は一度拒絶された後に必要な修正 (補正) を適用したのち登録査定される。また、拒絶の有無に関わらず、手続き上必要な軽微な修正も実施される。特許制度の性質上、特許公報における特許請求の範囲は、特許を受けるために出願時の特許文書 (特許公開公報がこれに対応) から必要な修正が適用されたものである。したがって、特許制度の観点においては、特許公報 (B9) の特許請求の範囲は特許公開公報 (A) のものと比較して「より良い書き換え」の結果として利用できる。さらに、特許出願番号に基づいて、特許庁が提供する特許情報標準データ (審査経過情報等)、拒絶理由条文コード情報 (特許審査官によって特許が拒絶される際にその根拠として引用された条文のコード情報)、IIP パテントデータベース [6] を書き換えペアに紐づけすることで、特許情報処理研究に利用可能な統合的なデータベースを整備した。拒絶理由については、特許法の法律条文<sup>1)</sup>に関連して定義されており 50 以上のユニークなカテゴリが存在する。

構築したデータセットの統計を 1 に示す。ここで、書き換えペアの補正の有無と審査中に拒絶の履歴があるかどうかに基づいて、書き換えペアを複数のタイプに分類した。括弧は A と比較した場合の B9 の請求項数と特許請求の範囲の文字数の変化

率である。表データセットには、合計で 4,856,533 件の特許出願に関する特許公開公報と特許公報のテキストペアが収録されている。ここで、特許公開公報 (A) と特許公報 (B9) のペア 2,245,640 件のうち、特許請求の範囲のテキストに差分がある場合が 1,839,880 件、両者に差分がない場合が 405,760 件存在した。ここで、未登録の特許あるいは拒絶された特許と比較して、登録査定を受けた特許の方が平均トークン数と平均請求項数が減少する傾向が確認できる。これは、実際の知財実務における実際の補正の戦略を反映している。表 4 に、データセットに含まれる実際の書き換え事例と本研究で使用した付加情報の例を示す。

## 3 特許請求の範囲の自動補正モデル

本節では、特許請求の範囲の自動補正 (書き換え生成) タスクを定義し、大規模言語モデルに基づいた特許請求の範囲の自動補正モデルの学習方法について述べる。

### 3.1 タスク設定

本研究が扱う特許請求の範囲の自動補正タスクは書き換え前の特許請求の範囲  $c$  のテキストとその付加情報  $r$  を入力として与えたときに、与えた特許請求の範囲をより良く書き換えた特許請求の範囲  $c'$  のテキストを出力として生成することである。このような書き換え生成モデルを学習するためには、単純には、目的関数  $L = -\sum_{(c,c',r) \in C} \log P(c'|c,r;\theta)$  を最小化する必要がある。ここで、 $C$  は書き換え前の特許請求の範囲  $c$  と書き換え後の特許請求の範囲  $c'$  のペアの集合 (学習データ)、 $\theta$  は書き換え生成モデルの学習可能なパラメタ集合である。さらに、想定される特許の拒絶理由などを、書き換え前の特許請求の範囲  $c$  の付加情報を  $r$  として与えてもよい。本研究では、付加情報として特許審査官によって示された特許の拒絶理由を用いる。前述したように、このような書き換え生成モデルを学習するためのデータは、特許公開公報と特許公報の特許請求の範囲のペアを書き換えの事例として用いることで構築する。

### 3.2 選好最適化に基づいた微調整

本研究では、さらに自動補正モデルの出力をより特許実務の観点を反映するように選好最適化の枠組みを導入する。具体的には、特許審査官の選好に基

1) <https://www.japaneselawtranslation.go.jp/ja/laws/view/4097>

表1 構築したデータセットの統計

Types	Freq.	Avg.chars	Avg.claims
Type 1: A only (No corresponding B9)	2,610,893	1402.16	7.84
Type 2: A and B9 are identical (No reasons for refusal)	369,807	1259.83 (+0.0%)	6.16 (+0.0%)
Type 3: A and B9 are identical (With reasons for refusal)	35,953	822.14 (+0.0%)	4.64 (+0.0%)
Type 4: A and B9 differ (No reasons for refusal)	628,882	1438.76 (-13.2%)	6.79 (-25.9%)
Type 5: A and B9 differ (With reasons for refusal)	1,210,998	1401.28 (-14.8%)	6.60 (-28.5%)

づいた Kahneman-Tversky 最適化 (KTO) に基づいたアプローチを提案する。

### 3.3 Kahneman-Tversky 最適化

KTO は、損失関数に人間の意思決定バイアスを組み込んだプロスペクト理論に基づく選好の最適化手法である [7]。DPO などの既存の手法が選好の対数尤度を最大化するのに対し、生成物のユーティリティ自体を直接最大化することを目指す。KTO の損失関数は次のように定義される。

$$L_{KTO}(\pi_{\theta}, \pi_{ref}) = \mathbb{E}_{(x,y) \sim D} [\lambda y - v(x, y)] \quad (1)$$

ここで、 $\lambda_y$  は、 $y$  が望ましい (望ましくない) 応答である場合に  $\lambda_D$  ( $\lambda_U$ ) になる重み付け項であり、 $v(x, y)$  は次のように定義される関数である。

$$v(x, y) = \begin{cases} \lambda_D \sigma(\beta(r_{\theta}(x, y) - z_0)) & , y \sim y^{desirable} \\ \lambda_U \sigma(\beta(z_0 - r_{\theta}(x, y))) & , y \sim y^{undesirable} \end{cases} \quad (2)$$

$$r_{\theta}(x, y) = \log \frac{\pi_{\theta}(y|x)}{\pi_{ref}(y|x)} \quad (3)$$

$$z_0 = \mathbb{E}_{(x', y') \sim D} \text{KL}(\pi_{\theta}(y'|x') \parallel \pi_{ref}(y'|x')) \quad (4)$$

ここで、 $x$  は言語モデルへの入力、 $y = c'$  はモデルの応答、 $\pi_{\theta}$  は学習する言語モデル、 $\pi_{ref}$  は固定パラメータを持つ参照モデル、 $\sigma$  はシグモイド関数、 $\beta > 0$  はリスク回避の度合いを制御するハイパーパラメータである。言語モデルの従来のアライメントアプローチとして、PPO に基づく人間のフィードバックからの強化学習 (RLHF) は有望なオプションである [8, 9]。しかし、KTP とは異なり、RLHF では学習プロセス中にモデルから生成結果を順次サンプリングと評価する必要があり、計算コストが大きい。

#### 3.3.1 選好モデルからの自動フィードバック

特許審査官の選好をモデル化するために、事前学習済み LLM を微調整する。具体的には、2つのバージョンの特許請求の範囲を考慮する。 $c$  は特許公開公報からの特許請求の範囲、 $c'$  は修正後の特許公報からの特許請求の範囲である。評価対象の特許請求の範囲  $\hat{c} \in \{c, c'\}$  を用いてプロンプトテキストを作

成する。ここで、 $\hat{c}$  は元のテキスト  $c$  または修正されたテキスト  $c'$ 、指定された拒絶理由  $r$ 、および  $\hat{c}$  に関連する先行特許の特許請求の範囲  $a$  である。モデルの学習段階では、 $\hat{c}$  は、審査前の公開  $c$  (拒絶を克服できなかった望ましくない例) または特許査定後の公開  $c'$  (拒絶をうまく克服した望ましい例) から取得される。これらの過去の成功例と失敗例から学習することで、モデルは一連のクレームが拒絶を回避できるかどうか (つまり、特許を付与できるかどうか) を判断することを学習し、特許審査官の好みを効果的に捉える。選好モデルは次のように定式化される。

$$p_{\phi}(y|\hat{c}, r, a) = \sigma(\mathbf{w}^T \mathbf{h} + b) \quad (5)$$

ここで、 $\mathbf{h} = f_{LM}(\hat{c}, r, a)$  は、事前トレーニングされたレイヤーの最終レイヤーの出力、 $\mathbf{w}, b$  は学習可能なパラメータ、 $\sigma$  はシグモイド関数である。これにより、手動による注釈を必要とせずに、選好モデルから、書き換えモデルによって元のクレーム  $c$  に対応する生成された書き換え  $\hat{c}$  の望ましさを決定することができる (本研究では予測確率が 0.5 以上を望ましいサンプル、0.5 以下を望ましくないサンプルと定義)。また、このような特許審査官の選好モデルは、特許審査の自動化や特許の品質の自動評価に適用できる可能性がある。

## 4 評価実験

構築したデータセットから、公開特許公報/特許公報の特許請求の範囲が変化している場合のペアを抽出し、LLM と選好モデルの学習用 (317,182 件)・検証用 (1,000 件)・評価用 (1,000 件) データとして用いた。ここで、評価実験に用いる言語モデルが想定する最大トークン長と利用できる計算リソースには制限があるため長大なテキストを含むものは除外した。実験の詳細については、本論文の付録と国際会議版を参照されたい [5]。LLM には、Qwen1.5 シリーズと GPT4o-mini, GPT3.5-turbo を用いた。また、モデルの目的関数には、通常の交差エントロピー誤

差に基づいた SFT（フルパラ学習）と LoRA を適用した場合、選好モデルを用いた KTO を適用した場合、ゼロショット学習を用いた場合をそれぞれ比較した。選好モデルの学習には、Qwen1.5 の 0.5B モデルを用いた。

**特許審査官の選好モデルの性能** 表 2 は、評価セットにおける特許審査官の選好モデルの予測結果を示している。言い換えれば、与えた特許請求の範囲が拒絶された特許公開公報らしいか、登録査定された特許公報らしいかの予測性能を示している。結果は、望ましい予測と望ましくない予測の両方が 73% を超える F1 スコアを達成したことを示している。各ラベルの頻度は均一であるため、チャンスレート精度 50% を大幅に上回っていることがわかる。言い換えると、選好モデルは、書き換えられた特許請求の範囲が先行特許の特許請求の範囲に対して審査官によって受け入れ可能と判断されるかを高い信頼度で予測でき、特許審査官による特許出願の妥当性の判断を自動評価に置き換える可能性を示唆している。ただし、実際の特許出願事例を用いたクローズドな評価であり、実際の LLM の出力に適用した場合とギャップが存在することには留意する必要がある。

表 2 特許審査官の選好の予測性能

Labels	Prec. [%]	Recall [%]	F1 [%]	Freq.
Undesirable	71.81	77.70	74.64	1000
Desirable	75.71	69.50	72.47	1000

**特許請求の範囲の補正性能** 表 3 に、各特許請求の範囲の自動補正モデルの評価セットにおける性能を示す。評価指標には、生成文と参照分の類似度を考慮した GLEU と SARI を用いた。ここで、Accept. Rate は、書き換えられた特許請求の範囲が実際に特許査定を受けることができると見込まれる割合であり、学習した選好モデルを用いて自動評価した。LLM の微調整に基づいたモデルは、最先端の LLM のゼロショット学習の性能を大幅に上回っていることがわかる。一方で、最先端の LLM に基づいたモデルは、0.5B 程度の小さいモデルと比較しても低い性能を示している。これは、既存の LLM が特許ドメインに十分に対応しておらず、特許ドメインに特化した追加学習の必要性を示唆している。SFT(フルパラ学習) と LoRA の比較においては、SFT が最も有効であり、0.5B 程度の小さいモデル対する SFT は、7B のような大きいモデルの LoRA 学習に匹敵する性能を示している。また、KTO を適用したモデ

表 3 特許請求の範囲の自動補正性能

Models	$ \theta $	GLEU $\uparrow$	SARI $\uparrow$	Accept. Rate $\uparrow$
Reference	-	100.0	100.0	0.69
Copy	-	63.23	28.38	0.22
RDC	-	47.22	28.38	0.30
DMMC	-	57.85	28.38	0.23
gpt4o-mini (zero-shot)	-	47.04	32.00	0.70
gpt3.5-turbo (zero-shot)	-	40.19	29.62	0.17
Qwen-72B (zero-shot)	72B	29.97	27.23	0.69
Qwen-0.5B-LoRA	0.5B	54.16	34.55	0.53
Qwen-0.5B-LoRA w/o r	0.5B	32.47	34.19	0.53
Qwen-1.8B-LoRA	1.8B	41.29	34.22	0.49
Qwen-7B-LoRA	7B	55.67	35.42	0.57
Qwen-0.5B-SFT	0.5B	55.06	36.66	0.63
Qwen-0.5B-SFT w/o r	0.5B	57.25	36.72	0.60
Qwen-0.5B-KTO	0.5B	58.45	38.95	0.96

ルは、特許審査官の選好モデルにアラインメントすることで、特許請求の範囲の書き換え結果の受率率が 96 % を達成し、SFT モデルから 36 % の改善を示した。同様に、GLEU と SARI の評価も SFT モデルからの改善を示しており、少なくとも特許の書き換え性能を維持しながら、特許審査官の特許審査の選好に適用できる可能性を示唆している。拒絶理由情報をモデルへの入力として活用することの効果については、LoRA 学習を適用した場合は一定の効果を示したが、SFT を適用した場合は限定的であった。

## 5 まとめと今後の課題

本研究では、データセットと書き換えモデルを含む特許文書の自動補正のための新しいフレームワーク “ClaimBrush” を提案した。構築したデータセットを用いて、大規模言語モデルを微調整することにより、特許請求の範囲の自動補正モデルを構築した。さらに、特許審査官による特許出願の拒絶査定の自動予測結果に基づいた選好最適化を適用することで、提案した特許請求の範囲の自動補正モデルの性能を向上させた。評価実験の結果、提案した特許審査官の特許請求の範囲の自動補正モデルは、経験則に基づいたベースラインや最先端の大規模言語モデルを用いたゼロショット学習手法を凌駕することが示された。また、特許審査官による拒絶査定の予測結果に基づいた選好最適化により特許文書の補正性能が向上することを示した。今後の課題ととしては、発明の詳細内容や先行技術などの様々な追加情報を入力として用いることを検討する。また、人間の判断と一致するより適切な評価指標の開発や人手評価の実施に向けたガイドラインを整備を進める。

## 謝辞

本研究は、JST/ACT-X「特許文書読解支援のための  
談話構造解析基盤の確立（課題番号: JPMJAX22A4）」  
の支援により実施された。

## 参考文献

- [1] Mihai Lupu, Katja Mayer, Noriko Kando, and Anthony J Trippe. **Current challenges in patent information retrieval**, Vol. 37. Springer, 2017.
- [2] Atsushi Fujii, Makoto Iwayama, and Noriko Kando. Overview of the patent retrieval task at the ntcir-6 workshop. In **NTCIR**, 2007.
- [3] Akihiro Shinmori, Manabu Okumura, Yuzo Marukawa, and Makoto Iwayama. Patent claim processing for readability-structure analysis and term explanation. In **Proc. of the ACL-2003 workshop on Patent corpus processing**, pp. 56–65, 2003.
- [4] 河野誠也, 野中尋史, 吉野幸一郎ほか. 大規模言語モデルに基づいた特許請求の範囲の自動書き換え生成モデル. 研究報告自然言語処理 (NL), Vol. 2023, No. 24, pp. 1–6, 2023.
- [5] Seiya Kawano, Hirofumi Nonaka, and Koichiro Yoshino. Claimbrush: A novel framework for automated patent claim refinement based on large language models. **arXiv preprint arXiv:2410.05575**, 2024.
- [6] Akira Goto and Kazuyuki Motohashi. Construction of a japanese patent database and a first look at japanese patenting activities. **Research Policy**, Vol. 36, No. 9, pp. 1431–1442, 2007.
- [7] Kawin Ethayarajh, Winnie Xu, Niklas Muennighoff, Dan Jurafsky, and Douwe Kiela. Kto: Model alignment as prospect theoretic optimization. **arXiv preprint arXiv:2402.01306**, 2024.
- [8] Long Ouyang, Jeffrey Wu, Xu Jiang, Diogo Almeida, Carroll Wainwright, Pamela Mishkin, Chong Zhang, Sandhini Agarwal, Katarina Slama, Alex Ray, et al. Training language models to follow instructions with human feedback. **Advances in neural information processing systems**, Vol. 35, pp. 27730–27744, 2022.
- [9] Harrison Lee, Samrat Phatale, Hassan Mansoor, Kellie Lu, Thomas Mesnard, Colton Bishop, Victor Carbune, and Abhinav Rastogi. Rlaif: Scaling reinforcement learning from human feedback with ai feedback. **arXiv preprint arXiv:2309.00267**, 2023.
- [10] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Lukasz Kaiser, and Illia Polosukhin. Attention is all you need. **Advances in neural information processing systems**, Vol. 30, , 2017.
- [11] Jieh-Sheng Lee and Jieh Hsiang. Patent claim generation by fine-tuning openai gpt-2. **World Patent Information**, Vol. 62, p. 101983, 2020.
- [12] Jieh-Sheng Lee. Evaluating generative patent language models. **World Patent Information**, Vol. 72, p. 102173, 2023.
- [13] 新森昭宏, 大屋由香里, 谷川英和ほか. 特許請求項に

おける多重多数項引用の検出と書き換え. 情報処理  
学会論文誌, Vol. 49, No. 7, pp. 2692–2702, 2008.

## A 付録

### A.1 実際の補正事例

特許請求の範囲の補正事例を表 4 に示す。この補正の例では、複数に記載された請求項を一つにまとめて、詳細化し発明の権利範囲の詳細化をすることで拒絶査定を受けた特許を登録査定できるようにした事例である。ここで、Refusal Reasons が特許審査官によって示された特許の拒絶理由（関連する特許法の条文）で、Prior Patent は特許審査官によって提示された先行特許のリストである。本研究が扱う補正タスクにおいては、単に特許請求の範囲を書き換えるだけでなく予想される拒絶理由と先行特許との関係を考慮した実践的な書き換えを生成することが求められる。

## B 関連研究

Transformer 言語モデルに基づいた大規模言語モデルの登場により、文章要約、質問応答、機械翻訳、文法誤り訂正といった、様々な自然言語処理のタスクで、大規模言語モデルを活用した手法が最先端の性能を示している [10]。大規模言語モデルの性能向上に伴いこうした応用タスクの性能も進化を続けている一方で、一般のコーパスとは語彙が異なる特許ドメイン（特に米国特許）に特化した特許言語モデルの開発と特許ドメインにおける様々なタスクへの応用が進んでいる [11, 12]。こうした特許言語モデルの性能評価では、しばしば特許請求項の自動生成タスクや特許の要約タスクに焦点があてられるが、与えられた請求項に対する実用的な書き換えを生成するようなタスクも存在する [13]。請求項の書き換えタスクでは、単純な生成タスクとは異なり、元々の請求項の意味内容を概ね保持しつつ、その品質を向上させた書き換えを生成する必要がある。ここで、書き換えの品質は、単に言語モデル的に自然であるということではなく、特許が拒絶されない、より強い権利範囲を持つ、といった特許制度上の観点から決定されることに注意されたい。請求項の書き換えタスクに関しては、ルールベース手法に基づいた多重多数項引用の請求項（マルチマルチクレーム）を複数の請求項に分解して書き換えるような研究が存在するが、非常に限定された目的のみでの書き換え支援にとどまっている [13]。また、単一の請求項だけでなく特許請求の範囲全体の構造を考慮し

表 4 実際の特許出願の補正例 (特開 2011-229635)

Section	特許請求の範囲
Original Claims	【請求項 1】 四角形状の板材の表面に所定の装飾シートが貼付されてなり、所定の遊技領域を有する遊技機用の遊技盤を構成する装飾板であって、前記遊技領域の領域外に相当する部位でかつ前記板材の所定のコーナー部の近傍に相当する部位における前記装飾シートの樹脂表面層に対し、所定の情報を含んだ二次元コードよりなる識別コードがレーザー刻印されていることを特徴とする装飾板。 【請求項 2】 請求項 1 に記載の装飾板からなる遊技盤。 【請求項 3】 請求項 2 に記載の遊技盤を備えてなる遊技機。
Amended Claims	【請求項 1】 四角形状の板材の表面に所定の装飾シートが貼付されてなり、所定の遊技領域を有する遊技盤であって、遊技機の種別を特定可能な情報を含んだ第 1 識別コードが第 1 のコーナー部の近傍において付された四角形状をなす前記装飾シートを前記板材に貼付するシート貼付工程と、前記板材に貼付された装飾シートにおける前記遊技領域の領域外に相当する部位でかつ前記第 1 のコーナー部と対角にあたる第 2 のコーナー部の近傍に相当する部位における前記装飾シートの樹脂表面層に対し、前記遊技機の種別を特定可能な情報を含んだ二次元コードよりなる第 2 識別コードをレーザー刻印により付す表面コード付け工程と、前記コード付け工程を行うにあたり、前記第 1 識別コードの内容と前記第 2 識別コードの内容とを照合する照合工程と、前記板材のうち、前記第 2 識別コードが付された部位を含む所定範囲を残して、前記第 1 識別コードが付された部位を切除する切除工程と、前記板材の側面に対し、第 3 識別コードを付す側面コード付け工程とを経て形成された前記遊技盤を備えたことを特徴とする遊技機。
Refusal Reasons	22: 第 29 条第 1 項   第 29 条第 2 項   第 29 条第 1 項 + 第 29 条第 2 項
Prior Patent Numbers	特開 2008-113853 号公報 特開 2003-126393 号公報 特開 2000-84166 号公報 特開 2008-119277 号公報 特開昭 60-21777 号公報

た一貫的な書き換えを自動生成するような研究は存在しない。また、そのような書き換え生成モデルを学習・評価するためのデータセットも存在しない。そこで、本研究では多目的に対応した特許請求の範囲の書き換えを自動生成するモデルを実現するためのデータセットの構築と大規模言語モデルの応用可能性を検討する。