

LegalRikai: Open Benchmark - A Benchmark for Complex Japanese Corporate Legal Tasks

Shogo Fujita¹, Yuji Naraki¹, Yiqing Zhu¹, Shinsuke Mori²

¹LegalOn Technologies, Inc., ²Kyoto University
shogo.fujita@legalontech.jp

Abstract

This paper introduces LegalRikai: Open Benchmark, a new benchmark comprising four complex tasks that emulate Japanese corporate legal practices. The benchmark was created by legal professionals under the supervision of an attorney. This benchmark has 100 samples that require long-form, structured outputs, and we evaluated them against multiple practical criteria. We conducted both human and automated evaluations using leading LLMs, including GPT-5, Gemini 2.5 Pro, and Claude Opus 4.1. Our human evaluation revealed that abstract instructions prompted unnecessary modifications, highlighting model weaknesses in document-level editing that were missed by conventional short-text tasks. Furthermore, our analysis reveals that automated evaluation aligns well with human judgment on criteria with clear linguistic grounding, and assessing structural consistency remains a challenge. The result demonstrates the utility of automated evaluation as a screening tool when expert availability is limited. We propose a dataset evaluation framework to promote more practice-oriented research in the legal domain.

Keywords: Legal Applications, Legal Review

1. Introduction

The adoption of LLMs is rapidly increasing, and there are high expectations for their ability to streamline legal tasks such as document generation, summarization, and proofreading. However, actual corporate legal workflows are not single nor simple tasks; they consist of complex operations integrating multiple processes. The ability of LLMs to handle such complex tasks has only been evaluated within limited scopes.

The practical legal work targeted in this paper involves recurring editing workflows such as: (1) Internal communication regarding the business impact of legal amendments, (2) Contract revisions in response to the amendments, (3) Requirement-driven contract revisions based on stakeholder requests, and (4) Risk-driven contract revisions aimed at preventing future disputes and disadvantages. For example, when a law is amended, a legal department typically performs tasks (1) and (2), as illustrated in Figure 1. The former requires multiple processes: (a) understanding the pre-amendment law, (b) comprehending the differences between pre- and post-amendment, (c) summarizing the changes, and (d) listing the impact on contracts. The latter, in addition to these, requires (e) understanding the structure and content of the existing contract, (f) identifying the clauses that need editing, and (g) performing edits while preserving the original contract's format.

Existing legal benchmarks primarily focus on short-answer QA or classification tasks that test legal knowledge. They fail to adequately measure the long-form editing capabilities essential for prac-

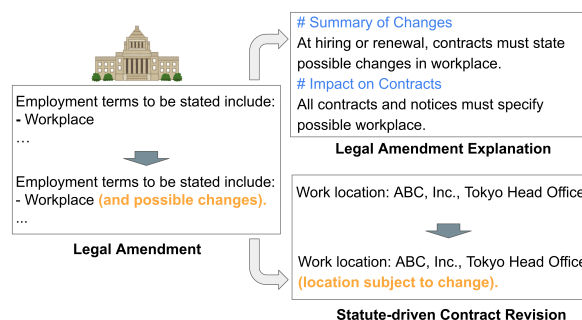


Figure 1: The overview of the legal department's operations regarding a legal amendment.

tical work, such as modifying clauses while maintaining the overall consistency of a contract. This capability gap is critical, as contract drafts generated by LLMs may appear correct at first glance but may contain hidden flaws, such as incorrect clause references, inconsistent definitions, or contextually inappropriate outputs. Therefore, we propose a benchmark of four complex tasks modeled on real-world workflows. We employ both human and automated evaluations to analyze the outputs by leading LLMs, identifying which aspects have reached a practical level and where weaknesses are most prominent.

Research Questions This study aims to answer the following questions:

1. **RQ1:** How do differences in legal tasks affect the editing behavior of LLMs?
2. **RQ2:** To what extent does performance

on the proposed tasks correlate with performance on conventional benchmarks?

3. **RQ3:** How closely do human and automated evaluations align in assessing editing quality, and can automated evaluation effectively substitute for human judgment?

The contributions of this research are as follows:

- We propose LegalRikai: Open Benchmark, a new benchmark consisting of four complex tasks directly tied to major workflows in Japanese legal practice. Legal professionals created the dataset under the supervision of qualified lawyers.
- We conducted inference and evaluation on the benchmark using leading LLMs and analyzed their performance and tendencies.
- We specifically identify future research challenges regarding the adoption of LLMs in the legal domain.

2. Proposed Corpora

In this study, we define the four workflows described in the previous section as tasks: **Legal amendment explanation (AmendExp)** takes pre- and post-amendment statutes as input and outputs the summary of the amendment and its impact on contracts. **Statute-driven contract revision (StatRev)** takes pre- and post-amendment statutes and a contract as input, and outputs a contract that complies with the current statute. **Requirement-driven contract revision (ReqRev)** takes a contract and direct revision instructions as input, and outputs a contract edited according to those instructions. **Risk-driven contract revision (RiskRev)** takes a contract and instructions to mitigate legal risks as input, and outputs a contract edited according to those instructions. Below, we describe each task and its evaluation metrics. For each of the four tasks, we selected evaluation metrics that could be assessed both manually and automatically by LLMs. The metrics are set on a 3-point scale for cases where partial achievement needs to be distinguished, and on a 2-point scale for cases where achievement is clearly binary.

2.1. AmendExp

Legal amendments can have wide-ranging effects on contracts and business operations. AmendExp aims to compare pre- and post-amendment statutes, generating a summary of the changes and an explanation of their impacts on contracts. This task takes pre- and post-amendment statutes

as input. This task simulates the practical work of explaining legal revisions to stakeholders and compiling materials for internal discussions.

An example of this task is shown in Table 1. An amendment to the Penal Code introduced a new "imprisonment" (kōkinkei), necessitating changes to terms such as "imprisonment" (chōeki) and "imprisonment without work" (kinko) in contracts. These terms need to be replaced with "imprisonment" (kōkinkei).

We evaluated this task based on two main aspects: the summary of the amendment and its impact on contracts. The evaluation criteria for the amendment summary are as follows:

Coverage of Amendments (CA): Assesses whether the model covers the main points of the change in the summary. **Accuracy of Amendments (AA):** Assesses whether the model describes the changes accurately in the summary.

Relevance of Amendments (RA): Assesses whether the model excludes unnecessary content from the summary. For the impact on contracts, as follows: **Coverage of Impacts (CI):** Assesses whether the model addresses all relevant aspects that impact contracts in the explanations.

Accuracy of Impacts (AI): Assesses whether the model describes the impacts accurately in the explanations. **Relevance of Impacts (RI):** Assesses whether the model excludes irrelevant information from the explanations. We rated all metrics for AmendExp on a 3-point scale.

2.2. StatRev

Contracts often require revision due to legal amendments. StatRev aims to create a contract compliant with post-amendment statutes. This task takes a contract that is compliant with pre-amendment statutes, as well as pre- and post-amendment statutes, as input. Specifically, this task involves identifying contract clauses that require revision based on the amended statute and generating and applying the revised text. StatRev requires the ability to understand the amended statute and to map it to contract clauses, demanding legal knowledge and statutory interpretation. This task simulates the practical work of updating of contracts after legal amendments.

An example of this task is shown in Table 2. This example shows a case where the amendment to the Labor Standards Act Enforcement Regulations necessitated the explicit definition of the scope of changes to the workplace and the duty clause.

We evaluated this task on five criteria: **Instruction Following (IF):** Assesses whether the model strictly performs the revision as instructed. **Structural Consistency (SC):** Assesses whether the model maintains the resulting contract structure consistently and logically sound after the revision.

Pre-amendment statute	...(2)"imprisonment" (chōeki) consists of confinement in a penal institution with assigned work....
Post-amendment statute	...(2)"imprisonment" (kōkinkei) shall consist of confinement in a penal institution. (3)A person sentenced to "imprisonment" (kōkinkei) may be required to perform necessary labor or be provided with necessary guidance for their rehabilitation and reintegration. ...
Ground truth (Summary of change)	The sentences of "imprisonment" (chōeki) and "imprisonment without work" (kinko) have been abolished and replaced with a newly established, unified sentence of "imprisonment" (kōkinkei). This change aims to improve the treatment of inmates in penal institutions and enhance systems such as the suspension of sentences.
Ground truth (Impact on contracts)	In contracts that grant certain rights to an individual, such as stock option agreements, there may be a provision stipulating the forfeiture of those rights if the individual is convicted of a criminal offense. If such a provision uses the terms "imprisonment" (chōeki) or "imprisonment without work" (kinko), it must be amended to the new term "imprisonment" (kōkinkei)

Table 1: An example of AmendExp.

Change Precision (CP): Assesses whether the model makes any unnecessary revisions, deletions, or additions beyond the scope of the required change. **Terminology Accuracy (TA):** Assesses whether the model uses the correct technical or specialized terminology throughout the revised contract. **Wording Appropriateness (WA):** Assesses whether the model retains appropriate contractual phrasing in the revised contract. We rated IF, TA, and WA on a 3-point scale and SC, CP on a 2-point scale.

2.3. ReqRev

Contracts often require revision not only due to legal amendments but also because of requests from the parties or changes in transaction terms. ReqRev aims to generate a revised contract that accurately reflects all requests. This task takes a contract template and multiple revision requests as input. The revision requests range from simple wording changes to large-scale revisions spanning multiple clauses and may include instructions that do not necessarily require legal knowledge. The task requires identifying the target clauses, generating revised text, and maintaining overall consistency. This task is less abstract than others, as it requires faithfully reflecting explicitly given revision requests. This task simulates the practical work of incorporating requests from a counterparty or making wording changes during contract negotiations.

An example of this task is shown in Table 3. This example has instructions with specific and explicit wording for particular clauses. We evaluated this task on the same criteria as StatRev.

2.4. RiskRev

Contracts contain potential risks that could lead to future disputes or disadvantages. RiskRev aims

to generate a revised contract with minimal legal risks. This task takes a contract template and multiple revision requests designed to mitigate legal risks as input. Some cases include instructions that do not require revision. This task contributes to pre-contractual reviews and risk reduction during negotiations. In all cases, the input contract for RiskRev and ReqRev is identical. The difference is that ReqRev provides clear instructions on how to revise, whereas RiskRev provides high-level instructions to revise based on a stated risk. Therefore, RiskRev requires risk identification and the formulation of revised text based on legal knowledge. RiskRev simulates the practical work of reviewing by legal staff and supporting negotiations.

An example of this task is shown in Table 3. While ReqRev specifies the exact wording to be changed, RiskRev provides a legally oriented instruction, such as "revise to be more favorable to the contractor." We evaluated this task on the same criteria as StatRev.

2.5. Datasets

We created 25 data instances for each task. Legal professionals created the data under the supervision of an attorney employee. We created the dataset used in RiskRev, ReqRev, and StatRev based on contracts and templates for actual practice. The statutes in StatRev and AmendExp are based on actual Japanese statutes. We show statistical information in Table 4. All tasks require handling over 6,500 characters of information. Among them, StatRev and AmendExp have significant average character counts for the input statutes. Since StatRev requires referring to 27,000 characters of statute and AmendExp 23,000 characters, long-context processing

Pre-amendment statute	...Article 5 (1) The working conditions which the employer shall clearly indicate to the worker under the provisions of the first sentence of paragraph....(i)-3 Matters concerning workplace and work engaged in...
Post-amendment statute	...Article 5 (1) The working conditions which the employer shall clearly indicate to the worker under the provisions of the first sentence of paragraph....(i)-3 Matters concerning workplace and work engaged in (including the scope of changes to the place of work and duties to be engaged in)...
Input contract	...Place of work: Immediately after hiring: Tokyo Head Office...
Ground truth (Revised contract)	...Place of work: Immediately after hiring: Tokyo Head Office (Scope of change: Any place of work separately designated by the Company)...

Table 2: An Example of StatRev.

Instruction in ReqRev	Please amend Article 8 (Subcontracting) to state that "subcontracting is permissible only with the prior written consent of the Consignor."
Instruction in RiskRev	Regarding the clause on subcontracting, if the contract contains a corresponding item, please amend the expression to be more favorable to the Consignor. If deleting the clause is more advantageous, you may do so.
Input Contract	...Article 8 (Subcontracting) 1. Party B may, at its own responsibility, subcontract a portion of the consigned duties to a third party. ...
Ground Truth (Revised Contract)	...Article 8 (Subcontracting) 1. Party B may, at its own responsibility, subcontract a portion of the consigned duties to a third party only upon obtaining the prior written consent of Party A. ...

Table 3: Examples of ReqRev and RiskRev.

capability has a significant impact.¹

3. Experiments

For each of the four tasks, we conducted a human evaluation experiment and an automated evaluation experiment. In the human evaluation experiment, we performed inference with three models—GPT-5²(OpenAI, 2025), Gemini 2.5 Pro³(Google, 2025), and Claude Opus 4.1⁴(Anthropic, 2025)—and had legal professionals evaluate the outputs under the supervision of an attorney employee. In the automated evaluation experiment, we similarly evaluated three models—GPT-5, Gemini 2.5 Pro, and Claude Opus 4.1—as the evaluation models.

We used a task-specific template that specified the output format and constraints for each task. We provided contracts in Markdown format, and statutes in text format, converted from information obtained from the API published by Digital Agency, Government of Japan (2025)⁵. For AmendExp, the model outputted the summary of amendments

¹The dataset is available at: <https://huggingface.co/datasets/legalontech/Legal-Rikai-Open-Benchmark>

²The Model version is gpt-5-2025-08-07.

³The Model version is gemini-2.5-pro.

⁴The Model version is claude-opus-4-1-20250805.

⁵For articles exceeding the LLM’s maximum context length, trailing portions without differences between the pre- and post-amendment versions were truncated to ensure consistent input across models.

and impact on contracts in Markdown. For StatRev, the model only outputted the clauses requiring changes in Markdown due to context length limitations. For ReqRev and RiskRev, the model outputted the entire edited contract in Markdown.

For each model, we set the temperature to 0.0. We used GPT-5 directly via the official API, while we used Gemini 2.5 Pro and Claude Opus 4.1 via the Vertex AI Platform.

3.1. Human Evaluation Experiment

We conducted inference for each task using GPT-5, Gemini 2.5 Pro, and Claude Opus 4.1, and legal professionals conducted a human evaluation of each output. Each sample was independently scored by two legal professionals using the metrics defined in Section 2 (AmendExp: CA/AA/RA, CI/AI/RI; other three tasks: IF/SC/CP-TA/WA). When scores differed, we used the arithmetic mean. We reported Inter-annotator agreement using Cohen’s κ coefficient in Table 5. Note that for metrics where all samples received the same label, κ score is nan. Overall, we observed high agreement, but κ score for WA in ReqRev and RiskRev were low, indicating that judgments on appropriate contractual phrasing vary considerably among individuals. We mapped the scores to an interval scale and then normalized them to [0, 1] (Table 6).

As shown in Table 6, in AmendExp, Gemini 2.5 Pro performed best overall, with scores of AA (0.86), AI (0.54), RI (0.44), and RA (0.80). GPT-

	ReqRev	RiskRev	StatRev	AmendExp
Number of samples	25	25	25	25
Avg. char. count in input contract	6,530	6,530	9,412	-
Avg. articles in input contract	16	16	38	-
Avg. char. count in pre-amendment statute	-	-	27,033	32,149
Avg. provisions in pre-amendment statute	-	-	292	318
Ground truth char. count	253	228	300	397
Char. count of statute amendment diff.	-	-	3,122	4,924

Table 4: Statistics for the four tasks. The ground truth char. counts for ReqRev, RiskRev, and StatRev are the character count of the difference between the input and ground truth contracts. For AmendExp, it is the character count of the ground-truth summary and the impact on contracts.

5 exhibits high coverage with CA (0.66) and CI (0.52), but its relevance is weaker, with RA (0.76) and RI (0.22), falling short of Gemini 2.5 Pro. Claude Opus 4.1 did not stand out in any metric compared to the other models.

In StatRev, Gemini 2.5 Pro scored highest in IF (0.73) and CP (0.44), excelling in coverage and precision. Claude Opus 4.1 scored highest in SC (0.40) and WA (1.00), demonstrating a strength in maintaining the proper format of a contract. However, it also had the lowest CP score (0.20), indicating that it often made extra changes not specified in the instructions. GPT-5’s performance was intermediate between the other two. All models scored TA (1.00), showing no issues with the use of technical terminology.

In ReqRev, all models scored similarly on IF (0.85), suggesting that when “what to change” is explicitly stated, there is no significant difference in the ability to follow instructions. There were no significant differences in SC, TA, or WA, but GPT-5 scored CP (0.58), indicating an exceptionally high number of unnecessary revisions compared to the other models.

In RiskRev, the trends were generally similar to those in ReqRev. Since ReqRev and RiskRev have the same input/output format, they are likely to produce similar trends. While there was little difference in IF and SC, GPT-5 tended to perform lower than the other two models in SC, TA, and WA. GPT-5’s CP (0.22) score was especially low, indicating a tendency for unnecessary revisions.

A general trend emerging from the experimental results is that the specificity of instructions has a significant influence on model behavior. In ReqRev, where we provided specific revision points and wording, all models achieved high scores in IF, demonstrating their ability to faithfully execute instructions. In contrast, in StatRev, which requires interpreting amended statutes, and RiskRev, which demands abstract risk mitigation, model performance varied greatly, with a notable increase in unnecessary modifications. The results suggest that when models attempt to interpret

	CA	AA	RA	CI	AI	RI
	1.00	1.00	1.00	0.98	0.98	0.91
Task	IF	SC	CP	TA	WA	
ReqRev	0.78	1.00	0.74	1.00	0.49	
RiskRev	0.78	1.00	0.69	0.53	0.60	
StatRev	1.00	0.90	1.00	nan	1.00	

Table 5: Cohen’s κ coefficient for the evaluation results of two evaluators per task. Top row: AmendExp; Bottom row: ReqRev, RiskRev, StatRev. For the TA of StatRev, the evaluation results were identical in all cases, hence marked as nan.

and supplement abstract parts of instructions, they tend to perform excessive edits or make changes that deviate from the practitioner’s intended meaning. This behavior, while seemingly producing beneficial modifications, can actually increase review costs and introduce unintended legal risks.

Furthermore, model-specific characteristics became apparent. Gemini 2.5 Pro shows strength in accuracy, while Claude Opus 4.1 excelled at maintaining contract format. The results could reflect the fundamental characteristics of each model: the former specializes in careful, fact-based text generation, while the latter is adept at preserving the format and stylistic consistency of the entire document. GPT-5 demonstrated intermediate performance, exhibiting high versatility but lacking outstanding capabilities in any specific aspect. These results indicate that when selecting an LLM for legal practice, it is necessary to consider not only a single score but also the nature of the task, such as the specificity of instructions, and the model’s particular strengths.

3.2. Automated Evaluation Experiment

In this section, we conducted an automated evaluation to verify whether they can replace or assist legal professionals in their annotation work. We measured Spearman’s correlation coefficient in Table 7 and Mean Absolute Error (MAE) in Table 8 between the automated scores and human evaluations for the criteria defined in Section 2.

Model	CA	AA	RA	CI	AI	RI
GPT-5	0.66	0.74	0.76	0.52	0.44	0.22
Gemini	0.64	0.86	0.80	0.52	0.54	0.44
Claude	0.64	0.68	0.70	0.49	0.49	0.32

Task	Model	IF	SC	CP	TA	WA
StatRev	GPT-5	0.69	0.36	0.32	1.00	0.94
	Gemini	0.73	0.36	0.44	1.00	0.96
	Claude	0.57	0.40	0.20	1.00	1.00
ReqRev	GPT-5	0.85	0.92	0.58	0.94	0.79
	Gemini	0.85	0.80	1.00	1.00	0.90
	Claude	0.85	0.92	0.96	1.00	0.87
RiskRev	GPT-5	0.69	0.88	0.22	0.79	0.59
	Gemini	0.61	0.96	0.40	0.95	0.78
	Claude	0.65	1.00	0.56	0.96	0.75

Table 6: Manual evaluation results for LLM outputs. Top row: AmendExp; bottom row: StatRev, ReqRev, RiskRev. All have their value ranges changed to [0,1].

We used GPT-5, Gemini 2.5 Pro, and Claude Opus 4.1 as evaluator models, setting the temperature to 0 for deterministic scoring. We provided the task definition, input, model output, and scoring criteria for each aspect, and required a structured output consisting only of the criterion name and the rationale. We also experimented with a score, Avg, which is the arithmetic mean of the scores from the three models.

As shown in Table 7, in AmendExp, a significant positive correlation was observed overall. The results indicate that judgments with easily demonstrable linguistic evidence, such as identifying differences in amendments and organizing their practical impacts, are well-suited for automated scoring by LLMs. As shown in Table 8, there is a difference between the summary of amendments (CA, AA, RA) and the impact on contracts (CI, AI, RI). The metrics associated with the more complex impact on contracts generally show a larger deviation from human evaluation.

In StatRev, as shown in Table 7, there are moderate correlations for IF and CP, while weak correlations for SC and WA. We were unable to obtain a correlation coefficient for TA because all human evaluations were identical. The MAE scores for TA ranged from 0.28 to 0.79 in Table 8, which is comparable to IF and CP, suggesting a certain level of agreement with human evaluation.

In ReqRev, as shown in Table 7, there are moderate correlations for IF and WA, while weak correlations for SC and CP, and a weak negative correlation for TA. The results are likely due to the fact that simple instructions, such as explicit replacement or addition, tend to cluster densely in human scores for each model, making it challenging to establish a rank correlation.

In RiskRev, as shown in Table 7, there are mod-

erate correlations for CP and WA, and weak correlations for IF, SC, and TA. Since this task has a high level of instruction abstraction, evaluating IF was likely the most difficult among the four tasks.

A general trend is that for tasks like AmendExp, where contained linguistic evidence in the text, there was a significant correlation between automated and human evaluations. However, the markedly weak correlation in contract revision tasks, especially for SC and TA, highlights the limitations of LLM-based evaluation.

The difficulty in evaluating SC is likely due to LLMs processing text as a linear sequence of tokens. Human evaluators perceive the visual and logical structure of a document as a whole, such as clause number references and indentation breaks. In contrast, LLM evaluators are adept at assessing local semantic meaning but struggle to accurately track the consistency of global references, such as "Article 15 refers to Article 9."

The discrepancy in TA evaluation is rooted in the nuanced context of legal terminology. For example, while "immediately" and "promptly" are similar, their levels of obligation differ in legal documents. Human experts judge these nuances, whereas LLM evaluators tend to assess based on dictionary correctness or word frequency, failing to evaluate the appropriateness of term choice in context. From these considerations, it is evident that automated evaluation is practical for screening aspects related to content, such as coverage and instruction following. However, for assessing formal and contextual validity, such as document structure and professional nuance, supervision by human experts remains necessary. Furthermore, the Avg score tended to improve correlation by offsetting systemic biases, proving effective in achieving a more accurate evaluation.

3.3. Performance Variation by LLM Scale

We investigated how model scale affects performance on document-level editing tasks. Table 9 compares the results of the full-GPT-5 model with its lightweight versions, GPT-5-mini⁶ and GPT-5-nano⁷. As shown in Table 9, reducing the model scale resulted in a significant performance drop, especially in aspects that require understanding the entire document's context, such as CA and CI. For instance, the CI score dropped by 0.25 from 0.52 for the full model to 0.27 for the nano model. To verify whether this rate of performance degradation is specific to our proposed tasks, we compare it with the benchmark results published (OpenAI, 2025). In the GPQA diamond benchmark, which measures graduate-level question-answering abil-

⁶The Model version is gpt-5-mini-2025-08-07.

⁷The Model version is gpt-5-nano-2025-08-07.

Model	CA	AA	RA	CI	AI	RI
GPT-5	0.72 [†]	0.32 [†]	0.41 [†]	0.50 [†]	0.44 [†]	0.23 [†]
Gemini	0.58 [†]	0.36 [†]	0.47 [†]	0.36 [†]	0.31 [†]	0.13
Claude	0.53 [†]	0.37 [†]	0.46 [†]	0.53 [†]	0.54 [†]	0.41 [†]
Avg	0.68 [†]	0.38 [†]	0.51 [†]	0.55 [†]	0.47 [†]	0.31 [†]

Task	Model	IF	SC	CP	TA	WA
StatRev	GPT-5	0.34 [†]	0.07	0.47 [†]	nan	-0.04
	Gemini	0.43 [†]	0.11	0.46 [†]	nan	0.08
	Claude	0.34 [†]	0.08	0.58 [†]	nan	0.19
	Avg	0.49 [†]	0.12	0.65 [†]	nan	0.14
ReqRev	GPT-5	0.17	0.09	0.15	-0.05	0.00
	Gemini	0.10	0.08	0.17	-0.06	0.27 [†]
	Claude	0.26 [†]	0.16	nan	-0.12	0.07
	Avg	0.23 [†]	0.12	0.18	-0.15	0.23 [†]
RiskRev	GPT-5	0.16	-0.08	0.36 [†]	0.14	0.22
	Gemini	-0.13	0.01	0.26 [†]	-0.02	0.20
	Claude	0.20	0.07	0.35	0.11	0.26 [†]
	Avg	0.11	-0.07	0.41 [†]	0.19	0.34 [†]

Table 7: Spearman correlation coefficients between automated and manual evaluations. Top row: AmendExp; Bottom row: StatRev, ReqRev, RiskRev. [†] denotes a statistically significant correlation with manual evaluation ($p < 0.05$).

Model	CA	AA	RA	CI	AI	RI
GPT-5	0.31	0.47	0.71	0.66	0.66	0.64
Gemini	0.39	0.44	0.47	0.69	0.75	1.01
Claude	0.44	0.53	0.56	0.58	0.55	0.63
Avg	0.37	0.47	0.58	0.58	0.60	0.71

Task	Model	IF	SC	CP	TA	WA
StatRev	GPT-5	0.54	0.60	0.24	0.52	0.31
	Gemini	0.58	0.57	0.25	0.28	0.36
	Claude	0.75	0.57	0.23	0.79	0.59
	Avg	0.56	0.58	0.24	0.53	0.41
ReqRev	GPT-5	0.33	0.15	0.21	0.09	0.31
	Gemini	0.35	0.21	0.19	0.13	0.28
	Claude	0.42	0.27	0.17	0.17	0.28
	Avg	0.34	0.21	0.17	0.17	0.28
RiskRev	GPT-5	0.43	0.15	0.33	0.25	0.52
	Gemini	0.62	0.27	0.42	0.24	0.52
	Claude	0.46	0.43	0.38	0.24	0.48
	Avg	0.49	0.28	0.36	0.23	0.49

Table 8: Mean Absolute Error(MAE) between manual and automated evaluations. Top row: AmendExp; Bottom row: StatRev, ReqRev, RiskRev

ity, the performance drop was only 14.5%, with the score decreasing from 85.7% for GPT-5 to 71.2% for GPT-5-nano. This comparison reveals that the reduction in model scale leads to significantly more severe performance degradation in specialized, long-text reading and editing tasks, such as those in our study, compared to the performance difference observed in general-purpose reasoning tasks. The results suggest that the ability to perform tasks while retaining complex information, such as the overall structure of a contract

Model	CA	AA	RA	CI	AI	RI
GPT-5	0.66	0.74	0.76	0.52	0.44	0.22
GPT-5-mini	0.63	0.83	0.55	0.37	0.42	0.37
GPT-5-nano	0.51	0.65	0.44	0.27	0.28	0.27

Table 9: Evaluation results for AmendExp using each GPT-5 model by Avg evaluator. All have their value ranges changed to [0,1].

and inter-clause references, is strongly dependent on model scale. Therefore, although lightweight models may be attractive in terms of cost and speed, applying them carelessly to tasks where document-wide consistency is critical, such as contract review, carries a high risk of inducing fatal oversights. The results emphasize the importance of selecting a model of appropriate scale based on the task’s difficulty.

4. Related work

With the advancement of LLMs, research on natural language processing tasks in the legal domain has become active. In particular, numerous benchmark datasets have been proposed to evaluate the legal knowledge and reasoning abilities of LLMs, with diverse designs corresponding to the legal systems and document formats of various countries and languages. Below, we organize prior research from three perspectives relevant to our study.

Several benchmarks have been proposed to evaluate the legal knowledge and reasoning ability of LLMs. Comprehensive surveys and datasets such as MMLU (Hendrycks et al., 2021), LawBench (Fei et al., 2024), LegalBench (Guha et al., 2023), LegalAgentBench (Li et al., 2025), and LexGLUE (Chalkidis et al., 2022) cover diverse aspects of legal understanding, from factual recall to multi-hop reasoning and case law analysis (Zhong et al., 2020). LEXam (Fan et al., 2025) is built from 340 law exams across 116 law school courses, spanning multiple subjects and degree levels. BriefMe (Woo et al., 2025) focuses on trial preparation tasks such as argument summarization, completion, and case retrieval. In addition, multi-task benchmarks based on non-English legal systems, including those of South Korea and China, have also been introduced (Hwang et al., 2022; Ma et al., 2021; Li et al., 2024).

On the other hand, benchmarks specific to the Japanese legal domain have not received sufficient attention. Therefore, in the next section, we will review the current state of LLM evaluation in Japanese, as well as datasets for the legal domain.

4.1. Benchmark Datasets in Japanese

Recent studies have developed diverse benchmarks for evaluating Japanese LLMs. The llm-jp-eval platform (LLM-jp et al., 2024) enables unified automatic evaluation across tasks such as classification, summarization, and reasoning, while judge-based and judge-free approaches, including Japanese Vicuna QA, Japanese MT-Bench, and Judge-free Benchmark (Sun et al., 2024; Imajo et al., 2025), leverage LLMs themselves for scalable assessment. Domain-specific benchmarks have also emerged, such as FinBench for finance (Hirano, 2024), JMedBench for medicine (Jiang et al., 2025), JFLD for formal logic reasoning (Morishita et al., 2024), and LCTG Bench for controllable generation (Kurihara et al., 2025). Moreover, LawQA-JP (Digital Agency, Government of Japan, 2025) tests understanding of Japanese laws and regulations. Despite such progress, no benchmark yet captures the practical context of Japanese legal work. To address this gap, we construct a benchmark reflecting real-world tasks of Japanese legal professionals.

4.2. Complex Task Benchmarks and Evaluation Design

In LLM evaluation, complex tasks involving multiple reasoning steps or processes, rather than single knowledge recall or classification, are gaining attention. The trend is relevant to the design of tasks like contract review, which require multi-stage processing such as "understanding document structure," "interpreting clause meaning," and "risk identification or legal judgment." Recent benchmarks have explored LLMs' practical and reasoning capabilities through diverse complex tasks. GAIA (Mialon et al., 2024) and Humanity's Last Exam (Phan et al., 2025) evaluate general and expert-level reasoning, while SWE-bench (Jimenez et al., 2024) and PaperBench (Starace et al., 2025) assess multi-stage problem solving in realistic settings such as software debugging and paper reproduction. Benchmarks like ProcBench, ToolComp, and Multi-LogiEval (Fujisawa et al., 2024; Nath et al., 2025; Patel et al., 2024) further emphasize the importance of stepwise reasoning and tool use. These studies have laid the groundwork for a multifaceted understanding of LLM capabilities, ranging from knowledge recall to the evaluation of complex reasoning processes. Existing legal benchmarks often remain confined to assessing knowledge of statutes and case law, or limited reasoning tasks, lacking tasks that require complex reasoning processes. We have addressed this challenge.

5. Conclusion

This paper proposes a new benchmark consisting of four complex tasks (AmendExp, StatRev, ReqRev, RiskRev) that align with Japanese corporate legal practice. We analyzed leading LLMs using both human evaluation and automated evaluation. To clarify the outcomes of this paper, we revisit the research questions (RQ1–3) presented at the beginning and summarize the answers obtained from our research below:

RQ1: In ReqRev, which involves explicit revision instructions, all models demonstrated high performance. In contrast, for revision tasks with a higher degree of abstraction, such as StatRev and RiskRev, unnecessary alterations and structural breakdowns occurred frequently, confirming that the nature of the task can expose the model's weaknesses. **RQ2:** A comparison with the results of general-purpose benchmarks published by OpenAI revealed that performance degradation due to a reduction in model scale is far more severe in the legal tasks proposed in this study than in general-purpose tasks. The results demonstrate that scores on conventional tasks alone cannot predict practical performance in specialized domains, supporting the importance of domain-specific benchmarks. **RQ3:** For tasks like AmendExp, which involve summarizing amendments and their impacts, a significant correlation was found between the two evaluation methods. For StatRev, ReqRev, and RiskRev, moderate correlations were also confirmed for certain aspects, with high agreement on criteria with linguistic grounding, such as the absence of unnecessary changes and coverage. However, the correlation was weak for aspects like document structural consistency and the naturalness of technical terminology, making a complete substitution difficult. Overall, our findings suggest that automated evaluation is practical for screening or as a supplementary tool in environments where experts are not available.

As shown above, the analysis for each research question has concretely clarified the strengths and limitations of LLMs. Based on this, our benchmark provides a common foundation for evaluating LLM performance on legal tasks by releasing the data design, evaluation design, and experimental setup for reproducibility.

Future Work Future research directions include applying the language-independent framework to other legal systems for comparative analysis, expanding the dataset to support few-shot learning and fine-tuning, and extending the tasks to additional legal documents such as complaints, legal opinions, and internal regulations.

6. Limitations

This study has several limitations. First, the evaluation was limited to three major closed-source LLMs and did not include the open-source models that have seen recent performance improvements. Validation with a broader range of models is a task for the future. Second, the dataset consists of 25 samples per task, totaling 100 samples, which may introduce a bias toward specific contract types or legal fields. To enhance statistical robustness, it is necessary to expand the diversity and scale of the dataset.

7. Bibliographical References

Anthropic. 2025. Claude opus 4.1. <https://www.anthropic.com/news/claude-opus-4-1>. Accessed on October 17, 2025.

Digital Agency, Government of Japan. 2025. e-gov laws and regulations search api swagger ui. <https://laws.e-gov.go.jp/api/2/swagger-ui>. Accessed on October 17, 2025.

Google. 2025. Gemini 2.5 pro: Our newest model with thinking. <https://developers.googleblog.com/en/gemini-2-5-thinking-model-updates/>. Accessed on October 17, 2025.

LLM-jp, Akiko Aizawa, Eiji Aramaki, Bowen Chen, Fei Cheng, Hiroyuki Deguchi, Rintaro Enomoto, Kazuki Fujii, Kensuke Fukumoto, Takuya Fukushima, Namgi Han, Yuto Harada, Chikara Hashimoto, Tatsuya Hiraoka, Shohei Hisada, Sosuke Hosokawa, Lu Jie, Keisuke Kamata, Teruhito Kanazawa, Hiroki Kanezashi, Hiroshi Kataoka, Satoru Katsumata, Daisuke Kawahara, Seiya Kawano, Atsushi Keyaki, Keisuke Kiryu, Hirokazu Kiyomaru, Takashi Kodama, Takahiro Kubo, Yohei Kuga, Ryoma Kumon, Shuhei Kurita, Sadao Kurohashi, Conglong Li, Taiki Maekawa, Hiroshi Matsuda, Yusuke Miyao, Kentaro Mizuki, Sakae Mizuki, Yugo Murawaki, Akim Moustrou, Ryo Nakamura, Taishi Nakamura, Kouta Nakayama, Tomoka Nakazato, Takuro Niitsuma, Jiro Nishitoba, Yusuke Oda, Hayato Ogawa, Takumi Okamoto, Naoaki Okazaki, Yohei Oseki, Shintaro Ozaki, Koki Ryu, Rafal Rzepka, Keisuke Sakaguchi, Shota Sasaki, Satoshi Sekine, Kohei Suda, Saku Sugawara, Issa Sugiura, Hiroaki Sugiyama, Hisami Suzuki, Jun Suzuki, Toyotaro Suzumura, Kensuke Tachibana, Yu Takagi, Kyosuke Takami, Koichi Takeda, Masashi Takeshita, Masahiro Tanaka, Kenjiro Taura, Arseny Tolmachev, Nobuhiro Ueda, Zhen Wan,

Shuntaro Yada, Sakiko Yahata, Yuya Yamamoto, Yusuke Yamauchi, Hitomi Yanaka, Rio Yokota, and Koichiro Yoshino. 2024. [Llm-jp: A cross-organizational project for the research and development of fully open japanese llms](#).

OpenAI. 2025. Introducing gpt-5 for developers. <https://openai.com/ja-JP/index/introducing-gpt-5-for-developers/>. Accessed on October 17, 2025.

Haoxi Zhong, Chaojun Xiao, Cunchao Tu, Tianyang Zhang, Zhiyuan Liu, and Maosong Sun. 2020. [How does NLP benefit legal system: A summary of legal artificial intelligence](#). In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, pages 5218–5230, Online. Association for Computational Linguistics.

8. Language Resource References

Ilias Chalkidis, Abhik Jana, Dirk Hartung, Michael Bommarito, Ion Androutsopoulos, Daniel Katz, and Nikolaos Aletras. 2022. [LexGLUE: A benchmark dataset for legal language understanding in English](#). In *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 4310–4330, Dublin, Ireland. Association for Computational Linguistics.

Digital Agency, Government of Japan. 2025. [Legal System Related Dataset \(LawQA_JP\)](#). GitHub Repository. Accessed on October 17, 2025.

Yu Fan, Jingwei Ni, Jakob Merane, Yang Tian, Yoan Hermstrüwer, Yinya Huang, Mubashara Akhtar, Etienne Salimbeni, Florian Geering, Oliver Dreyer, Daniel Brunner, Markus Leopold, Mrinmaya Sachan, Alexander Stremitzer, Christoph Engel, Elliott Ash, and Joel Niklaus. 2025. [Lexam: Benchmarking legal reasoning on 340 law exams](#).

Zhiwei Fei, Xiaoyu Shen, Dawei Zhu, Fengzhe Zhou, Zhuo Han, Alan Huang, Songyang Zhang, Kai Chen, Zhixin Yin, Zongwen Shen, Jidong Ge, and Vincent Ng. 2024. [LawBench: Benchmarking legal knowledge of large language models](#). In *Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing*, pages 7933–7962, Miami, Florida, USA. Association for Computational Linguistics.

Ipppei Fujisawa, Sensho Nobe, Hiroki Seto, Rina Onda, Yoshiaki Uchida, Hiroki Ikoma, Pei-Chun Chien, and Ryota Kanai. 2024. [Procbench](#):

- Benchmark for multi-step reasoning and following procedure.
- Neel Guha, Julian Nyarko, Daniel Ho, Christopher Ré, Adam Chilton, Aditya K, Alex Chohlas-Wood, Austin Peters, Brandon Waldon, Daniel Rockmore, Diego Zambrano, Dmitry Talisman, Enam Hoque, Faiz Surani, Frank Fagan, Galit Sarfaty, Gregory Dickinson, Haggai Porat, Jason Hegland, Jessica Wu, Joe Nudell, Joel Niklaus, John Nay, Jonathan Choi, Kevin Tobias, Margaret Hagan, Megan Ma, Michael Livermore, Nikon Rasumov-Rahe, Nils Holzenberger, Noam Kolt, Peter Henderson, Sean Rehaag, Sharad Goel, Shang Gao, Spencer Williams, Sunny Gandhi, Tom Zur, Varun Iyer, and Zehua Li. 2023. [Legalbench: A collaboratively built benchmark for measuring legal reasoning in large language models](#). In *Advances in Neural Information Processing Systems*, volume 36, pages 44123–44279. Curran Associates, Inc.
- Dan Hendrycks, Collin Burns, Steven Basart, Andy Zou, Mantas Mazeika, Dawn Song, and Jacob Steinhardt. 2021. [Measuring massive multitask language understanding](#). In *ICLR*. OpenReview.net.
- Masanori Hirano. 2024. [Construction of a Japanese Financial Benchmark for Large Language Models](#). In *Joint Workshop of the 7th Financial Technology and Natural Language Processing (FinNLP), the 5th Knowledge Discovery from Unstructured Data in Financial Services (KDF), and The 4th Workshop on Economics and Natural Language Processing (ECONLP)*, pages 1–9.
- Wonseok Hwang, Dongjun Lee, Kyoungyeon Cho, Hanuhl Lee, and Minjoon Seo. 2022. [A multi-task benchmark for korean legal language understanding and judgement prediction](#). In *Advances in Neural Information Processing Systems*, volume 35, pages 32537–32551. Curran Associates, Inc.
- Kentaro Imajo, Masanori Hirano, Shuji Suzuki, and Hiroaki Mikami. 2025. [A judge-free llm opened generation benchmark based on the distributional hypothesis](#).
- Junfeng Jiang, Jiahao Huang, and Akiko Aizawa. 2025. [JMedBench: A benchmark for evaluating Japanese biomedical large language models](#). In *Proceedings of the 31st International Conference on Computational Linguistics*, pages 5918–5935, Abu Dhabi, UAE. Association for Computational Linguistics.
- Carlos E Jimenez, John Yang, Alexander Wettig, Shunyu Yao, Kexin Pei, Ofir Press, and Karthik R Narasimhan. 2024. [SWE-bench: Can language models resolve real-world github issues?](#) In *The Twelfth International Conference on Learning Representations*.
- Kentaro Kurihara, Masato Mita, Peinan Zhang, Shota Sasaki, Ryosuke Ishigami, and Naoaki Okazaki. 2025. [Lctg bench: Llm controlled text generation benchmark](#).
- Haitao Li, Junjie Chen, Jingli Yang, Qingyao Ai, Wei Jia, Youfeng Liu, Kai Lin, Yueyue Wu, Guozhi Yuan, Yiran Hu, Wuyue Wang, Yiqun Liu, and Minlie Huang. 2025. [LegalAgentBench: Evaluating LLM agents in legal domain](#). In *Proceedings of the 63rd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 2322–2344, Vienna, Austria. Association for Computational Linguistics.
- Haitao Li, Yunqiu Shao, Yueyue Wu, Qingyao Ai, Yixiao Ma, and Yiqun Liu. 2024. [Lecardv2: A large-scale chinese legal case retrieval dataset](#). In *Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR '24*, page 2251–2260, New York, NY, USA. Association for Computing Machinery.
- Yixiao Ma, Yunqiu Shao, Yueyue Wu, Yiqun Liu, Ruizhe Zhang, Min Zhang, and Shaoping Ma. 2021. [Lecard: A legal case retrieval dataset for chinese law system](#). In *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR '21*, page 2342–2348, New York, NY, USA. Association for Computing Machinery.
- Grégoire Mialon, Clémentine Fourier, Craig Swift, Thomas Wolf, Yann LeCun, and Thomas Scialom. 2024. [Gaia: A benchmark for general ai assistants](#). Publisher Copyright: © 2024 12th International Conference on Learning Representations, ICLR 2024. All rights reserved.; 12th International Conference on Learning Representations, ICLR 2024 ; Conference date: 07-05-2024 Through 11-05-2024.
- Terufumi Morishita, Atsuki Yamaguchi, Gaku Morio, Hikaru Tomonari, Osamu Imaichi, and Yasuhiro Sogawa. 2024. [JFLD: A Japanese benchmark for deductive reasoning based on formal logic](#). In *Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024)*, pages 9526–9535, Torino, Italia. ELRA and ICCL.

Vaskar Nath, Pranav Raja, Claire Yoon, and Sean Hendryx. 2025. [Toolcomp: A multi-tool reasoning & process supervision benchmark](#).

Nisarg Patel, Mohith Kulkarni, Mihir Parmar, Aashna Budhiraja, Mutsumi Nakamura, Neeraj Varshney, and Chitta Baral. 2024. [Multi-LogiEval: Towards evaluating multi-step logical reasoning ability of large language models](#). In *Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing*, pages 20856–20879, Miami, Florida, USA. Association for Computational Linguistics.

Long Phan, Alice Gatti, Ziwen Han, Nathaniel Li, Josephina Hu, Hugh Zhang, Chen Bo Calvin Zhang, Mohamed Shaaban, John Ling, Sean Shi, Michael Choi, Anish Agrawal, Arnav Chopra, Adam Khoja, Ryan Kim, Richard Ren, Jason Hausenloy, Oliver Zhang, Mantas Mazeika, Dmitry Dodonov, Tung Nguyen, Jaeho Lee, Daron Anderson, Mikhail Doroshenko, Alun Cennyth Stokes, Mobeen Mahmood, Oleksandr Pokutnyi, Oleg Iskra, Jessica P. Wang, John-Clark Levin, Mstyslav Kazakov, Fiona Feng, Steven Y. Feng, Haoran Zhao, Michael Yu, Varun Gangal, Chelsea Zou, Zihan Wang, Serguei Popov, Robert Gerbicz, Geoff Galgon, Johannes Schmitt, Will Yeadon, Yongki Lee, Scott Sauers, Alvaro Sanchez, Fabian Giska, Marc Roth, Søren Riis, Saiteja Utpala, Noah Burns, Gashaw M. Goshu, Mohinder Maheshbhai Naiya, Chidozie Agu, Zachary Giboney, Antrell Cheatom, Francesco Fournier-Facio, Sarah-Jane Crowson, Lennart Finke, Zerui Cheng, Jennifer Zampese, Ryan G. Hoerr, Mark Nandor, Hyunwoo Park, Tim Gehringer, Jiaqi Cai, Ben McCarty, Alexis C Garretson, Edwin Taylor, Damien Sileo, Qiuyu Ren, Usman Qazi, Lianghui Li, Jungbae Nam, John B. Wydallis, Pavel Arkhipov, Jack Wei Lun Shi, Aras Bacho, Chris G. Willcocks, Hangrui Cao, Sumeet Motwani, Emily de Oliveira Santos, Johannes Veith, Edward Vendrow, Doru Cojoc, Kengo Zenitani, Joshua Robinson, Longke Tang, Yuqi Li, Joshua Vendrow, Natanael Wildner Fraga, Vladyslav Kuchkin, Andrey Pupasov Maksimov, Pierre Marion, Denis Efremov, Jayson Lynch, Kaiqu Liang, Aleksandar Mikov, Andrew Gritsevskiy, Julien Guillod, Gözdenur Demir, Dakotah Martinez, Ben Pageler, Kevin Zhou, Saeed Soori, Ori Press, Henry Tang, Paolo Rissone, Sean R. Green, Lina Brüssel, Moon Twayana, Aymeric Dieuleveut, Joseph Marvin Imperial, Ameya Prabhu, Jinzhou Yang, Nick Crispino, Arun Rao, Dimitri Zvonkine, Gabriel Loiseau, Mikhail Kalinin, Marco Lukas, Ciprian Manolescu, Nate Stambaugh, Subrata Mishra, Tad Hogg, Carlo Bosio, Brian P Coppola, Julian Salazar, Jae-

hyeok Jin, Rafael Sayous, Stefan Ivanov, Philippe Schwaller, Shaipranesh Senthilkuma, Andres M Bran, Andres Algaba, Kelsey Van den Houte, Lynn Van Der Sypt, Brecht Verbeken, David Noever, Alexei Kopylov, Benjamin Myklebust, Bikun Li, Lisa Schut, Evgenii Zheltonozhskii, Qiaochu Yuan, Derek Lim, Richard Stanley, Tong Yang, John Maar, Julian Wykowski, Martí Oller, Anmol Sahu, Cesare Giulio Ardito, Yuzheng Hu, Ariel Ghislain Kemogne Kamdoun, Alvin Jin, Tobias Garcia Vilchis, Yuexuan Zu, Martin Lackner, James Koppel, Gongbo Sun, Daniil S. Antonenko, Steffi Chern, Bingchen Zhao, Pierrot Arsene, Joseph M Cavanagh, Daofeng Li, Jiawei Shen, Donato Crisostomi, Wenjin Zhang, Ali Dehghan, Sergey Ivanov, David Perrella, Nurdin Kaparov, Allen Zang, Ilya Sucholutsky, Arina Kharlamova, Daniil Orel, Vladislav Poritski, Shalev Ben-David, Zachary Berger, Parker Whitfill, Michael Foster, Daniel Munro, Linh Ho, Shankar Sivarajan, Dan Bar Hava, Aleksey Kuchkin, David Holmes, Alexandra Rodriguez-Romero, Frank Sommerhage, Anji Zhang, Richard Moat, Keith Schneider, Zakayo Kazibwe, Don Clarke, Dae Hyun Kim, Felipe Meneguitti Dias, Sara Fish, Veit Elser, Tobias Kreiman, Victor Efren Guadarrama Vilchis, Immo Klose, Ujjwala Anantheswaran, Adam Zweiger, Kaivalya Rawal, Jeffery Li, Jeremy Nguyen, Nicolas Daans, Haline Heidinger, Maksim Radionov, Václav Rozhoň, Vincent Ginis, Christian Stump, Niv Cohen, Rafał Poświata, Josef Tkadlec, Alan Goldfarb, Chenguang Wang, Piotr Padlewski, Stanislaw Barzowski, Kyle Montgomery, Ryan Stendall, Jamie Tucker-Foltz, Jack Stade, T. Ryan Rogers, Tom Goertzen, Declan Grabb, Abhishek Shukla, Alan Givré, John Arnold Ambay, Archan Sen, Muhammad Fayez Aziz, Mark H Inlow, Hao He, Ling Zhang, Younesse Kaddar, Ivar Ångquist, Yanxu Chen, Harrison K Wang, Kalyan Ramakrishnan, Elliott Thornley, Antonio Terpin, Hailey Schoelkopf, Eric Zheng, Avisy Carmi, Ethan D. L. Brown, Kelin Zhu, Max Bartolo, Richard Wheeler, Martin Stehberger, Peter Bradshaw, JP Heimonen, Kaustubh Sridhar, Ido Akov, Jennifer Sandlin, Yury Makarychev, Joanna Tam, Hieu Hoang, David M. Cunningham, Vladimir Goryachev, Demosthenes Patramanis, Michael Krause, Andrew Redenti, David Aldous, Jesyin Lai, Shannon Coleman, Jiangnan Xu, Sangwon Lee, Ilias Magoulas, Sandy Zhao, Ning Tang, Michael K. Cohen, Orr Paradise, Jan Hendrik Kirchner, Maksym Ovchynnikov, Jason O. Matos, Adithya Shenoy, Michael Wang, Yuzhou Nie, Anna Sztzyber-Betley, Paolo Faraboschi, Robin Riblet, Jonathan Crozier, Shiv Halasyamani, Shreyas Verma, Prashant

Joshi, Eli Meril, Ziqiao Ma, Jérémy Andréoletti, Raghav Singhal, Jacob Platnick, Volodymyr Nevirkovets, Luke Basler, Alexander Ivanov, Seri Khoury, Nils Gustafsson, Marco Piccardo, Hamid Mostaghimi, Qijia Chen, Virendra Singh, Tran Quoc Khánh, Paul Rosu, Hannah Szlyk, Zachary Brown, Himanshu Narayan, Aline Menezes, Jonathan Roberts, William Alley, Kunyang Sun, Arkil Patel, Max Lamparth, Anka Reuel, Linwei Xin, Hanmeng Xu, Jacob Loader, Freddie Martin, Zixuan Wang, Andrea Achilleos, Thomas Preu, Tomek Korbak, Ida Bosio, Fereshteh Kazemi, Ziyue Chen, Biró Bálint, Eve J. Y. Lo, Jiaqi Wang, Maria Inês S. Nunes, Jeremiah Milbauer, M Saiful Bari, Zihao Wang, Behzad Ansarinejad, Yewen Sun, Stephane Durand, Hossam Elgnainy, Guillaume Douville, Daniel Tordera, George Balabanian, Hew Wolff, Lynna Kvistad, Hsiaoyun Milliron, Ahmad Sakor, Murat Eron, Andrew Favre D. O., Shailesh Shah, Xiaoxiang Zhou, Firuz Kamalov, Sherwin Abdoli, Tim Santens, Shaul Barkan, Allison Tee, Robin Zhang, Alessandro Tomasiello, G. Bruno De Luca, Shi-Zhuo Looi, Vinh-Kha Le, Noam Kolt, Jiayi Pan, Emma Rodman, Jacob Drori, Carl J Fossum, Niklas Muennighoff, Milind Jagota, Ronak Pradeep, Honglu Fan, Jonathan Eicher, Michael Chen, Kushal Thaman, William Merrill, Moritz Firsching, Carter Harris, Stefan Ciobâcă, Jason Gross, Rohan Pandey, Ilya Gusev, Adam Jones, Shashank Agnihotri, Pavel Zhelnov, Mohammadreza Mofayez, Alexander Piperski, David K. Zhang, Kostiantyn Dobarskyi, Roman Leventov, Ignat Soroko, Joshua Dersch, Vage Taamazyan, Andrew Ho, Wenjie Ma, William Held, Ruicheng Xian, Armel Randy Zebaze, Mohanad Mohamed, Julian Noah Leser, Michelle X Yuan, Laila Yacar, Johannes Lengler, Katarzyna Olszewska, Claudio Di Fratta, Edson Oliveira, Joseph W. Jackson, Andy Zou, Muthu Chidambaram, Timothy Manik, Hector Haffenden, Dashiell Stander, Ali Dasouqi, Alexander Shen, Bitra Golshani, David Stap, Egor Kretov, Mikalai Uzhou, Alina Borisovna Zhidkovskaya, Nick Winter, Miguel Orbezo Rodriguez, Robert Lauff, Dustin Wehr, Colin Tang, Zaki Hossain, Shaun Phillips, Fortuna Samuele, Fredrik Ekström, Angela Hammon, Oam Patel, Faraz Farhidi, George Medley, Forough Mohammadzadeh, Madellene Peñaflor, Haile Kassahun, Alena Friedrich, Rayner Hernandez Perez, Daniel Pyda, Taom Sakal, Omkar Dhamane, Ali Khajegili Mirabadi, Eric Hallman, Kenchi Okutsu, Mike Battaglia, Mohammad Maghsoudimehrabani, Alon Amit, Dave Hulbert, Roberto Pereira, Simon Weber, Handoko, Anton Peristy, Stephen Malina, Mustafa Mehkary, Rami Aly, Frank Reidegeld, Anna-Katharina

Dick, Cary Friday, Mukhwinder Singh, Hassan Shapourian, Wanyoung Kim, Mariana Costa, Hubeyb Gurdogan, Harsh Kumar, Chiara Cecconello, Chao Zhuang, Haon Park, Micah Carroll, Andrew R. Tawfeek, Stefan Steinerberger, Daattavya Aggarwal, Michael Kirchhof, Linjie Dai, Evan Kim, Johan Ferret, Jainam Shah, Yuzhou Wang, Minghao Yan, Krzysztof Burdzy, Lixin Zhang, Antonio Franca, Diana T. Pham, Kang Yong Loh, Joshua Robinson, Abram Jackson, Paolo Giordano, Philipp Petersen, Adrian Cosma, Jesus Colino, Colin White, Jacob Votava, Vladimir Vinnikov, Ethan Delaney, Petr Spelda, Vit Stritecky, Syed M. Shahid, Jean-Christophe Mourrat, Lavr Vetoshkin, Koen Sponselee, Renas Bacho, Zheng-Xin Yong, Florencia de la Rosa, Nathan Cho, Xiuyu Li, Guillaume Malod, Orion Weller, Guglielmo Albani, Leon Lang, Julien Laurendeau, Dmitry Kazakov, Fatimah Adesanya, Julien Portier, Lawrence Holom, Victor Souza, Yuchen Anna Zhou, Julien Degorre, Yiğit Yalın, Gbenga Daniel Obikoya, Rai, Filippo Bigi, M. C. Boscá, Oleg Shumar, Kaniuar Bacho, Gabriel Recchia, Mara Popescu, Nikita Shulga, Ngefor Mildred Tanwie, Thomas C. H. Lux, Ben Rank, Colin Ni, Matthew Brooks, Alesia Yakimchyk, Huanxu, Liu, Stefano Cavalleri, Olle Häggström, Emil Verkama, Joshua Newbould, Hans Gundlach, Leonor Brito-Santana, Brian Amaro, Vivek Vajipey, Rynaa Grover, Ting Wang, Yosi Kratish, Wen-Ding Li, Sivakanth Gopi, Andrea Caciolai, Christian Schroeder de Witt, Pablo Hernández-Cámara, Emanuele Rodolà, Jules Robins, Dominic Williamson, Vincent Cheng, Brad Raynor, Hao Qi, Ben Segev, Jingxuan Fan, Sarah Martinson, Erik Y. Wang, Kaylie Hausknecht, Michael P. Brenner, Mao Mao, Christoph Demian, Peyman Kassani, Xinyu Zhang, David Avagian, Eshawn Jessica Scipio, Alon Ragoler, Justin Tan, Blake Sims, Rebeka Plecnik, Aaron Kirtland, Omer Faruk Bodur, D. P. Shinde, Yan Carlos Leyva Labrador, Zahra Adoul, Mohamed Zekry, Ali Karakoc, Tania C. B. Santos, Samir Shamseldeen, Loukmane Karim, Anna Liakhovitskaia, Nate Resman, Nicholas Farina, Juan Carlos Gonzalez, Gabe Maayan, Earth Anderson, Rodrigo De Oliveira Pena, Elizabeth Kelley, Hodjat Mariji, Rasoul Pouriamanesh, Wentao Wu, Ross Finocchio, Ismail Alarab, Joshua Cole, Danyelle Ferreira, Bryan Johnson, Mohammad Safdari, Liangti Dai, Siriphan Arthornthurasuk, Isaac C. McAlister, Alejandro José Moyano, Alexey Pronin, Jing Fan, Angel Ramirez-Trinidad, Yana Malysheva, Daphiny Pottmaier, Omid Taheri, Stanley Stepanic, Samuel Perry, Luke Askew, Raúl Adrián Huerta Rodríguez, Ali M. R. Minissi, Ricardo Lorena,

Krishnamurthy Iyer, Arshad Anil Fasiludeen, Ronald Clark, Josh Ducey, Matheus Piza, Maja Somrak, Eric Vergo, Juehang Qin, Benjámín Borbás, Eric Chu, Jack Lindsey, Antoine Jallon, I. M. J. McInnis, Evan Chen, Avi Semler, Luk Gloor, Tej Shah, Marc Carauleanu, Pascal Lauer, Tran Duc Huy, Hossein Shahrtash, Emilien Duc, Lukas Lewark, Assaf Brown, Samuel Albanie, Brian Weber, Warren S. Vaz, Pierre Clavier, Yiyang Fan, Gabriel Poesia Reis e Silva, Long, Lian, Marcus Abramovitch, Xi Jiang, Sandra Mendoza, Murat Islam, Juan Gonzalez, Vasilios Mavroudis, Justin Xu, Pawan Kumar, Laxman Prasad Goswami, Daniel Bugas, Nasser Heydari, Ferenc Jeanplong, Thorben Jansen, Antonella Pinto, Archimedes Apronti, Abdallah Galal, Ng Ze-An, Ankit Singh, Tong Jiang, Joan of Arc Xavier, Kanu Priya Agarwal, Mohammed Berkani, Gang Zhang, Zhehang Du, Benedito Alves de Oliveira Junior, Dmitry Malishev, Nicolas Remy, Taylor D. Hartman, Tim Tarver, Stephen Mensah, Gautier Abou Loume, Wiktor Morak, Farzad Habibi, Sarah Hoback, Will Cai, Javier Gimenez, Roselynn Grace Montecillo, Jakub Łucki, Russell Campbell, Asankhaya Sharma, Khalida Meer, Shreen Gul, Daniel Espinosa Gonzalez, Xavier Alapont, Alex Hoover, Gunjan Chhablani, Freddie Vargus, Arunim Agarwal, Yibo Jiang, Deepakkumar Patil, David Outevsky, Kevin Joseph Scaria, Rajat Maheshwari, Abdelkader Dendane, Priti Shukla, Ashley Cartwright, Sergei Bogdanov, Niels Mündler, Sören Möller, Luca Arnaboldi, Kunvar Thaman, Muhammad Rehan Siddiqi, Prajvi Saxena, Himanshu Gupta, Tony Fruhauff, Glen Sherman, Mátyás Vincze, Siranut Usawasutsakorn, Dylan Ler, Anil Radhakrishnan, Innocent Enyekwe, Sk Md Salauddin, Jiang Muzhen, Aleksandr Maksapetyan, Vivien Rossbach, Chris Harjadi, Mohsen Bahalooohoreh, Claire Sparrow, Jasdeep Sidhu, Sam Ali, Song Bian, John Lai, Eric Singer, Justine Leon Uro, Greg Bateman, Mohamed Sayed, Ahmed Menshawy, Darling Duclosel, Dario Bezzi, Yashaswini Jain, Ashley Aaron, Murat Tiryakioglu, Sheeshram Siddh, Keith Krenek, Imad Ali Shah, Jun Jin, Scott Creighton, Denis Peskoff, Zienab EL-Wasif, Ragavendran P V, Michael Richmond, Joseph McGowan, Tejal Patwardhan, Hao-Yu Sun, Ting Sun, Nikola Zubčić, Samuele Sala, Stephen Ebert, Jean Kadour, Manuel Schottdorf, Dianzhuo Wang, Gerol Petruzella, Alex Meiburg, Tilen Medved, Ali ElSheikh, S Ashwin Hebbar, Lorenzo Vaquero, Xianjun Yang, Jason Poulos, Vilém Zouhar, Sergey Bogdanik, Mingfang Zhang, Jorge Sanz-Ros, David Anugraha, Yinwei Dai, Anh N. Nhu, Xue Wang, Ali Anil Demircali, Zhibai Jia, Yuyin

Zhou, Juncheng Wu, Mike He, Nitin Chandok, Aarush Sinha, Gaoxiang Luo, Long Le, Mickaël Noyé, Michał Perelkiewicz, Ioannis Pantidis, Tianbo Qi, Soham Sachin Purohit, Letitia Parcalabescu, Thai-Hoa Nguyen, Genta Indra Winata, Edoardo M. Ponti, Hanchen Li, Kaustubh Dhole, Jongee Park, Dario Abbondanza, Yuanli Wang, Anupam Nayak, Diogo M. Caetano, Antonio A. W. L. Wong, Maria del Rio-Chanona, Dániel Kondor, Pieter Francois, Ed Chilstrey, Jakob Zsambok, Dan Hoyer, Jenny Reddish, Jakob Hauser, Francisco-Javier Rodrigo-Ginés, Suchandra Datta, Maxwell Shepherd, Thom Kamphuis, Qizheng Zhang, Hyunjun Kim, Ruiji Sun, Jianzhu Yao, Franck Deroncourt, Satyapriya Krishna, Sina Rismanchian, Bonan Pu, Francesco Pinto, Yingheng Wang, Kumar Shridhar, Kalon J. Overholt, Glib Briia, Hieu Nguyen, David, Soler Bartomeu, Tony CY Pang, Adam Wecker, Yifan Xiong, Fanfei Li, Lukas S. Huber, Joshua Jaeger, Romano De Maddalena, Xing Han Lù, Yuhui Zhang, Claas Beger, Patrick Tser Jern Kon, Sean Li, Vivek Sanker, Ming Yin, Yihao Liang, Xinlu Zhang, Ankit Agrawal, Li S. Yifei, Zechen Zhang, Mu Cai, Yasin Sonmez, Costin Cozianu, Changhao Li, Alex Slen, Shoubin Yu, Hyun Kyu Park, Gabriele Sarti, Marcin Briański, Alessandro Stolfo, Truong An Nguyen, Mike Zhang, Yotam Perlitz, Jose Hernandez-Orallo, Runjia Li, Amin Shabani, Felix Juefei-Xu, Shikhar Dhingra, Orr Zohar, My Chiffon Nguyen, Alexander Pondaven, Abdurrahim Yilmaz, Xuandong Zhao, Chuanyang Jin, Muyan Jiang, Stefan Todoran, Xinyao Han, Jules Kreuer, Brian Rabern, Anna Plassart, Martino Maggetti, Luther Yap, Robert Geirhos, Jonathon Kean, Dingsu Wang, Sina Mollaei, Chenkai Sun, Yifan Yin, Shiqi Wang, Rui Li, Yaowen Chang, Anjiang Wei, Alice Bizeul, Xiaohan Wang, Alexandre Oliveira Arrais, Kushin Mukherjee, Jorge Chamorro-Padial, Jiachen Liu, Xingyu Qu, Junyi Guan, Adam Bouyamourn, Shuyu Wu, Martyna Plomecka, Junda Chen, Mengze Tang, Jiaqi Deng, Shreyas Subramanian, Haocheng Xi, Haoxuan Chen, Weizhi Zhang, Yinuo Ren, Haoqin Tu, Sejong Kim, Yushun Chen, Sara Vera Marjanović, Junwoo Ha, Grzegorz Luczyna, Jeff J. Ma, Zewen Shen, Dawn Song, Cedegao E. Zhang, Zhun Wang, Gaël Gendron, Yunze Xiao, Leo Smucker, Erica Weng, Kwok Hao Lee, Zhe Ye, Stefano Ermon, Ignacio D. Lopez-Miguel, Theo Knights, Anthony Gitter, Namkyu Park, Boyi Wei, Hongzheng Chen, Kunal Pai, Ahmed Elkhanany, Han Lin, Philipp D. Siedler, Jichao Fang, Ritwik Mishra, Károly Zsolnai-Fehér, Xilin Jiang, Shadab Khan, Jun Yuan, Rishab Kumar Jain, Xi Lin, Mike Peterson, Zhe Wang, Aditya

Malusare, Maosen Tang, Isha Gupta, Ivan Fosin, Timothy Kang, Barbara Dworakowska, Kazuki Matsumoto, Guangyao Zheng, Gerben Sewuster, Jorge Pretel Villanueva, Ivan Rannev, Igor Chernyavsky, Jiale Chen, Deepayan Banik, Ben Racz, Wenchao Dong, Jianxin Wang, Laila Bashmal, Duarte V. Gonçalves, Wei Hu, Kaushik Bar, Ondrej Bohdal, Atharv Singh Patlan, Shehzaad Dhuliawala, Caroline Geirhos, Julien Wist, Yuval Kansal, Bingsen Chen, Kutay Tire, Atak Talay Yücel, Brandon Christof, Veerupaksh Singla, Zijian Song, Sanxing Chen, Jiaxin Ge, Kaustubh Ponkshe, Isaac Park, Tianheng Shi, Martin Q. Ma, Joshua Mak, Sherwin Lai, Antoine Moulin, Zhuo Cheng, Zhanda Zhu, Ziyi Zhang, Vaidehi Patil, Ketan Jha, Qiutong Men, Jiakuan Wu, Tianchi Zhang, Bruno Hebling Vieira, Alham Fikri Aji, Jae-Won Chung, Mohammed Mahfoud, Ha Thi Hoang, Marc Sperzel, Wei Hao, Kristof Meding, Sihan Xu, Vassilis Kostakos, Davide Manini, Yueying Liu, Christopher Toukmaji, Jay Paek, Eunmi Yu, Arif Engin Demircali, Zhiyi Sun, Ivan Dewerpe, Hongsen Qin, Roman Pflugfelder, James Bailey, Johnathan Morris, Ville Heilala, Sybille Rosset, Zishun Yu, Peter E. Chen, Woongyeong Yeo, Eeshaan Jain, Ryan Yang, Sreekar Chigurupati, Julia Chernyavsky, Sai Prajwal Reddy, Subhashini Venugopalan, Hunar Batra, Core Francisco Park, Hieu Tran, Guilherme Maximiano, Genghan Zhang, Yizhuo Liang, Hu Shiyu, Rongwu Xu, Rui Pan, Siddharth Suresh, Ziqi Liu, Samaksh Gulati, Songyang Zhang, Peter Turchin, Christopher W. Bartlett, Christopher R. Scotese, Phuong M. Cao, Aakaash Nattanmai, Gordon McKellips, Anish Cheraku, Asim Suhail, Ethan Luo, Marvin Deng, Jason Luo, Ashley Zhang, Kavin Jindel, Jay Paek, Kasper Halevy, Allen Baranov, Michael Liu, Advait Avadhanam, David Zhang, Vincent Cheng, Brad Ma, Evan Fu, Liam Do, Joshua Lass, Hubert Yang, Surya Sunkari, Vishruth Bharath, Violet Ai, James Leung, Rishit Agrawal, Alan Zhou, Kevin Chen, Tejas Kalpathi, Ziqi Xu, Gavin Wang, Tyler Xiao, Erik Maung, Sam Lee, Ryan Yang, Roy Yue, Ben Zhao, Julia Yoon, Sunny Sun, Aryan Singh, Ethan Luo, Clark Peng, Tyler Osbey, Taozhi Wang, Daryl Echeazu, Hubert Yang, Timothy Wu, Spandan Patel, Vidhi Kulkarni, Vijaykaarti Sundarapandian, Ashley Zhang, Andrew Le, Zafir Nasim, Srikar Yalam, Ritesh Kasamsetty, Soham Samal, Hubert Yang, David Sun, Nihar Shah, Abhijeet Saha, Alex Zhang, Leon Nguyen, Laasya Nagumalli, Kaixin Wang, Alan Zhou, Aidan Wu, Jason Luo, Anwith Teluri, Summer Yue, Alexandr Wang, and Dan Hendrycks. 2025. [Humanity's last exam](#).

Giulio Starace, Oliver Jaffe, Dane Sherburn,

James Aung, Jun Shern Chan, Leon Maksin, Rachel Dias, Evan Mays, Benjamin Kinsella, Wyatt Thompson, Johannes Heidecke, Amelia Glaese, and Tejal Patwardhan. 2025. [Paperbench: Evaluating ai's ability to replicate ai research](#).

Yikun Sun, Zhen Wan, Nobuhiro Ueda, Sakiko Yahata, Fei Cheng, Chenhui Chu, and Sadao Kurohashi. 2024. [Rapidly developing high-quality instruction data and evaluation benchmark for large language models with minimal human effort: A case study on Japanese](#). In *Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024)*, pages 13537–13547, Torino, Italia. ELRA and ICCL.

Jesse Woo, Fateme Hashemi Chaleshtori, Ana Marasovic, and Kenneth Marino. 2025. [BriefMe: A legal NLP benchmark for assisting with legal briefs](#). In *Findings of the Association for Computational Linguistics: ACL 2025*, pages 13139–13190, Vienna, Austria. Association for Computational Linguistics.

A. Dataset Example

In this section, we present concrete examples of the input data and gold data for each task.

A.1. AmendExp

As an example of AmendExp, we show a case related to an amendment to the Penal Code. Information on legal amendments was obtained from the Digital Agency's e-Gov Law Database. The text before the amendment (version enforced on May 23, 2025) is available at https://laws.e-gov.go.jp/law/140AC0000000045/20250523_507AC0000000039, and the text after the amendment (version enforced on June 1, 2025) is available at https://laws.e-gov.go.jp/law/140AC0000000045/20250601_504AC0000000067. Based on these, an example output summarizing the overview of the amendment and its impact on contracts is shown in summary 1.

A.2. StatRev

As an example of StatRev, we show a case related to an amendment to labor law. The text before the amendment (version enforced on January 18, 2023) is available at https://laws.e-gov.go.jp/law/322M40000100023/20230118_505M60000100006, and the text after the amendment (version enforced on April

1, 2024) is available at https://laws.e-gov.go.jp/law/322M40000100023/20240401_505M60000100039. Contract 1 corresponds to the pre-amendment contract, and contract 2 corresponds to the post-amendment contract.

A.3. ReqRev and RiskRev

As examples of ReqRev and RiskRev, we present a case involving the revision of a service agreement. In both ReqRev and RiskRev examples, the pre-edit contract corresponds to contract 3, and the post-edit contract corresponds to contract 4. Although the two tasks share a common input structure, the user instructions differ: ReqRev uses prompt 1, while RiskRev uses prompt 2.

B. Prompt settings

Since each task was handled by different personnel, there are differences in implementation approaches. AmendExp and StatRev directly call APIs, while ReqRev and RiskRev use LangChain. Because the input/output formats differ among tasks, no direct comparison was made; this difference does not affect the analysis results. For reproducibility, all prompt templates are publicly available.

B.1. Inference prompts

This subsection describes the inference-time prompt settings for each task. We used prompt 3 for AmendExp, prompt 4 for StatRev, prompt 5 for ReqRev, and prompt 6 for RiskRev.

B.2. Evaluation prompt

This subsection describes the evaluation-time prompt settings for each task. During evaluation, task-specific legal-domain evaluation criteria were applied to each task's output, and the evaluation LLM was instructed to produce structured outputs in JSON format with a fixed schema. As inputs, we provided `{original_prompt}`, `{instruction}`, `{llm_response}`, and the ground-truth data `{ground_truth}`, enabling automatic evaluation by the LLM.

The evaluation prompts used were: prompt 7 for AmendExp, prompt 8 for StatRev, prompt 9 for ReqRev, and prompt 10 for RiskRev. We used LangChain to generate structured output.

Summary 1: An Example of the output for AmendExp

改正の概要
刑事施設における受刑者の処遇及び執行猶予制度等のより一層の充実を図るため、懲役及び禁錮を廃止して拘禁刑を創設。

改正による契約書への影響
ストックオプション割当契約等、個人に何らかの権利を付与する契約において、その個人が刑罰に処せられた場合はその権利を喪失する旨が定められている場合がある。その規定において、「懲役」「禁錮」という文言が使われていたら、「拘禁刑」に改正する必要がある。

Contract 1: An example of pre-revised contract for StatRev

雇用契約書兼労働条件通知書(正社員)
株式会社AAA(以下「使用者」という)とBBB(以下「従業員」という)とは、以下のとおり雇用契約(以下「本契約」という)を締結する。

1. ** (目的) **
使用者は、従業員を正社員として雇用し、賃金を支払うことを約し、従業員は使用者の指揮に従い誠実に勤務することを約する。

2. ** (雇用期間等) ** 1. 本契約は、雇用期間の定めのない契約とする。2. 従業員の就業開始日は、2025年4月1日とする。3. 就業開始日から3か月間は試用期間とする。

3. ** (就業場所及び業務内容) **
従業員は、下記の就業場所において下記の業務を使用者の指示に従い誠実にを行う。

記就業場所 東京本社業務 営業業務以上
4. ** (就業時間) ** 1. 従業員の就業時間は、以下のとおりとする。始業 午前9時終業 午後18時 2. 休憩時間は、60分とする。3. 使用者は、業務の必要がある場合には、法令の範囲内で本条第1項の各時刻を変更し、時間外労働を命ずることがある。

5. ** (休日) ** 1. 従業員の休日は、以下のとおりとする。1) 土曜日 2) 日曜日 3) 年末年始(12月29日から12月31日まで並びに1月2日及び1月3日) 4) 国民の祝日に関する法律に定める休日 5) 国民の祝日が日曜日に当たるときはその翌日 2. 使用者は業務の必要がある場合には、前項各号の休日に従業員を臨時に就業させ、他の日を振替休日とすることができる。

6. ** (休暇) ** 1. 従業員は、法令に従い、所定の年次有給休暇を取得することができる。2. 従業員は、以下のとおり特別休暇を取得することができる。1) 有給 慶弔休暇、ボランティア休暇、リフレッシュ休暇 2) 無給 私傷病休暇

7. ** (賃金) **
従業員の賃金は、以下のとおりとする。

1) 従業員の賃金は、職能制とする。2) 基本給は、金350,000円とする。3) 諸手当として以下のものを支給する。1. 通勤手当月額40,000円まで/計算方法: 距離に応じて支給 2. 職務手当月額100,000円まで/計算方法: 職務遂行能力に応じて支給 4) 所定時間外労働等に対する割増賃金の計算方法は、以下のとおりとする。1. 所定時間外かつ法定時間内の労働にかかる部分 100% 2. 法定時間外 1か月60時間以下の労働にかかる部分 125% 3. 125% 4. 125% 5. 150% 6. 150% 7. 150% 8. 150% 9. 150% 10. 150% 11. 150% 12. 150% 13. 150% 14. 150% 15. 150% 16. 150% 17. 150% 18. 150% 19. 150% 20. 150% 21. 150% 22. 150% 23. 150% 24. 150% 25. 150% 26. 150% 27. 150% 28. 150% 29. 150% 30. 150% 31. 150% 32. 150% 33. 150% 34. 150% 35. 150% 36. 150% 37. 150% 38. 150% 39. 150% 40. 150% 41. 150% 42. 150% 43. 150% 44. 150% 45. 150% 46. 150% 47. 150% 48. 150% 49. 150% 50. 150% 51. 150% 52. 150% 53. 150% 54. 150% 55. 150% 56. 150% 57. 150% 58. 150% 59. 150% 60. 150% 61. 150% 62. 150% 63. 150% 64. 150% 65. 150% 66. 150% 67. 150% 68. 150% 69. 150% 70. 150% 71. 150% 72. 150% 73. 150% 74. 150% 75. 150% 76. 150% 77. 150% 78. 150% 79. 150% 80. 150% 81. 150% 82. 150% 83. 150% 84. 150% 85. 150% 86. 150% 87. 150% 88. 150% 89. 150% 90. 150% 91. 150% 92. 150% 93. 150% 94. 150% 95. 150% 96. 150% 97. 150% 98. 150% 99. 150% 100. 150%

Contract 2: An example of post-revised contract for StatRev

雇用契約書兼労働条件通知書(正社員)
株式会社AAA(以下「使用者」という)とBBB(以下「従業員」という)とは、以下のとおり雇用契約(以下「本契約」という)を締結する。

1. ** (目的) **
使用者は、従業員を正社員として雇用し、賃金を支払うことを約し、従業員は使用者の指揮に従い誠実に勤務することを約する。

2. ** (雇用期間等) ** 1. 本契約は、雇用期間の定めのない契約とする。2. 従業員の就業開始日は、2025年4月1日とする。3. 就業開始日から3か月間は試用期間とする。

3. ** (就業場所及び業務内容) **
従業員は、下記の就業場所において下記の業務を使用者の指示に従い誠実にを行う。

記就業場所 雇入れ直後: 東京本社 変更の範囲: 会社の別途指定する業務以上
4. ** (就業時間) ** 1. 従業員の就業時間は、以下のとおりとする。始業 午前9時終業 午後18時 2. 休憩時間は、60分とする。3. 使用者は、業務の必要がある場合には、法令の範囲内で本条第1項の各時刻を変更し、時間外労働を命ずることがある。

5. ** (休日) ** 1. 従業員の休日は、以下のとおりとする。1) 土曜日 2) 日曜日 3) 年末年始(12月29日から12月31日まで並びに1月2日及び1月3日) 4) 国民の祝日に関する法律に定める休日 5) 国民の祝日が日曜日に当たるときはその翌日 2. 使用者は業務の必要がある場合には、前項各号の休日に従業員を臨時に就業させ、他の日を振替休日とすることができる。

6. ** (休暇) ** 1. 従業員は、法令に従い、所定の年次有給休暇を取得することができる。2. 従業員は、以下のとおり特別休暇を取得することができる。1) 有給 慶弔休暇、ボランティア休暇、リフレッシュ休暇 2) 無給 私傷病休暇

7. ** (賃金) **
従業員の賃金は、以下のとおりとする。

1) 従業員の賃金は、職能制とする。2) 基本給は、金350,000円とする。3) 諸手当として以下のものを支給する。1. 通勤手当月額40,000円まで/計算方法: 距離に応じて支給 2. 職務手当月額100,000円まで/計算方法: 職務遂行能力に応じて支給 4) 所定時間外労働等に対する割増賃金の計算方法は、以下のとおりとする。1. 所定時間外かつ法定時間内の労働にかかる部分 100% 2. 法定時間外 1か月60時間以下の労働にかかる部分 125% 3. 125% 4. 125% 5. 150% 6. 150% 7. 150% 8. 150% 9. 150% 10. 150% 11. 150% 12. 150% 13. 150% 14. 150% 15. 150% 16. 150% 17. 150% 18. 150% 19. 150% 20. 150% 21. 150% 22. 150% 23. 150% 24. 150% 25. 150% 26. 150% 27. 150% 28. 150% 29. 150% 30. 150% 31. 150% 32. 150% 33. 150% 34. 150% 35. 150% 36. 150% 37. 150% 38. 150% 39. 150% 40. 150% 41. 150% 42. 150% 43. 150% 44. 150% 45. 150% 46. 150% 47. 150% 48. 150% 49. 150% 50. 150% 51. 150% 52. 150% 53. 150% 54. 150% 55. 150% 56. 150% 57. 150% 58. 150% 59. 150% 60. 150% 61. 150% 62. 150% 63. 150% 64. 150% 65. 150% 66. 150% 67. 150% 68. 150% 69. 150% 70. 150% 71. 150% 72. 150% 73. 150% 74. 150% 75. 150% 76. 150% 77. 150% 78. 150% 79. 150% 80. 150% 81. 150% 82. 150% 83. 150% 84. 150% 85. 150% 86. 150% 87. 150% 88. 150% 89. 150% 90. 150% 91. 150% 92. 150% 93. 150% 94. 150% 95. 150% 96. 150% 97. 150% 98. 150% 99. 150% 100. 150%

Prompt 1: Inference Prompt for ReqRev

・委託者の立場から、以下の指示に従って契約書の内容を確認・修正してください。
- 以下の内容について、適切な表現で追加又は修正してください。
- 「成果物が、第三者の権利を侵害しない」旨を、受託者が保証する規定を、第12条(納入物の知的財産権等)と第13条(知的財産権の侵害)の間に追加
- 第7条(資料等の提供)に「資料の複製を禁止する旨」を追加
- 第8条(再委託)を「委託者の事前の書面による承諾を得た場合に限り、再委託可能とする」旨に修正
- 第10条(契約不適合責任)を「委託者が指定した方法により履行の追完を行う」旨、「委託者が、履行の追完請求を行うことなく、委託料の減額を請求することができる」旨、「契約不適合責任を追及できる期間を委託者が契約不適合を知った時から1年以内」に修正

・条項の追加・削除を行う場合は、条番号のずれや他条項での引用の整合性も必ず修正してください。

Prompt 2: Inference Prompt for RiskRev

- ・委託者の立場から、以下の指示に従って契約書の内容を確認・修正してください。
 - ・以下の内容について、契約書内に該当する文言がない場合は、適切な表現を追加してください。
 - ・成果物が第三者の権利を侵害しない旨
 - ・資料の複製を禁止する旨
 - ・以下の内容について、契約書内に該当するテーマや項目が含まれている場合は、当該表現を委託側に有利に修正してください。削除することが有利になる場合は、削除も可能とします。
 - ・再委託に関する条項
 - ・契約不適合責任に関する内容
 - ・連帯保証人に関する内容
 - ・人材紹介手数料に関する内容
- ・条項の追加・削除を行う場合は、条番号のずれや他条項での引用の整合性も必ず修正してください。

Contract 3: An example pre-revised contract for ReqRev and RiskRev

“業務委託契約書”
委託者〇〇（以下「甲」という。）及び受託者（以下「乙」という。）は、契約要綱記載の業務の委託に関して、次のとおり、業務委託契約（以下「本契約」という。）を締結する。

“<契約要綱>”

本委託業務の表示	
納入物	
納期・検査完了期日	納期:〇年 月 日検査完了期日:納入後 日以内
納入場所	
業務委託料	金 〇 円 (消費税抜金額〇円 消費税額〇円)
業務委託料の支払時期	第9条に定める【納品/検査】が完了した日から 日以内
支払方法	【全額現金払(乙の指定する銀行口座への口座振込による。なお、支払期日が金融機関の休業日に当たった場合、【前/翌】営業日に支払う。また、振込手数料は甲の負担とする。】)
特約事項	

第1条 (業務の委託)

1. 甲は、契約要綱記載の業務（以下「本委託業務」という。）を乙に委託し、乙はこれを受託する。
2. 乙は、本委託業務を、善良なる管理者の注意義務をもって遂行し、本委託業務に関連する法令を遵守し、本契約にて定められた業務の遂行について、事業主として財政上及び法律上を含む全ての責任を負う。

第2条 (本委託業務の詳細)

本委託業務の詳細については、甲乙別途協議のうえ定めるものとし、必要に応じて手順書等を作成する。

第3条 (業務委託料及びその支払方法)

1. 甲は乙に対し、本委託業務の対価として、契約要綱記載の業務委託料並びにこれに対する消費税及び地方消費税（以下、併せて「本業務委託料」という。）を支払う。
2. 乙は、第9条に定める検査が完了した場合、甲に対し本業務委託料にかかる請求書を送付するものとし、甲は、本業務委託料を契約要綱記載の期日までに、契約要綱記載の方法により支払う。

第4条 (納期)

本委託業務にかかる納期は、契約要綱に定めるとおりとする。

第5条 (責任者)

1. 甲及び乙は、本契約締結後速やかに、本契約における各自の責任者をそれぞれ選任し、互いに書面により、相手方に通知する。
2. 甲及び乙は、事前に書面により相手方に通知することにより、責任者を変更することができる。
3. 甲及び乙の責任者は、本委託業務遂行に必要な意思決定、指示、同意等を行う権限及び責任を有する。本委託業務に関する要請、指示、依頼その他の連絡、確認等は原則として責任者を通じて行われなければならない。

第6条 (業務従事者)

1. 乙は、労働法規その他関係法令に基づき、本委託業務に従事する乙の従業員（以下「業務従事者」という。）に対し雇用主としての一切の義務を負うものとし、業務従事者に対する本委託業務遂行に関する指示、労務管理、安全衛生管理等に関する一切の指揮命令を行う。
2. 乙は、本委託業務遂行上、業務従事者が甲の事務所等に立ち入る場合、甲の防犯、秩序維持等に関する諸規則を当該業務従事者に遵守させなければならない。

第7条 (資料等の提供)

1. 甲は乙に対し、本委託業務遂行に必要な資料等を提供する。乙は甲から提供された本委託業務に関する資料等を善良なる管理者の注意をもって管理、保管するものとし、本委託業務以外の用途に使用してはならない。
2. 本委託業務遂行上、甲の事務所等で乙が作業を実施する必要がある場合、甲は当該作業実施場所（当該作業実施場所における必要な機器、設備等作業環境を含む。）を、甲乙協議の上、乙に提供するものとする。

3. 甲が前項により乙に提供する資料等又は作業実施場所に関し、内容等の誤り又は甲の提供遅延があった場合、これにより生じた乙の本委託業務の履行遅滞、納入物の契約不適合等の結果については、乙はその責を負うものとする。
4. 甲から提供を受けた資料等が本委託業務遂行上不要となったときは、乙は遅滞なく資料等につき甲の指示に従い返還等の処置を行うものとする。

第8条 (再委託)

1. 乙は、乙の責任において、本委託業務の一部を第三者に再委託することができる。ただし、乙は、甲が要請した場合、再委託先の名称及び住所等を甲に報告しなければならない。
2. 甲が前項に定める再委託先が不適切であると合理的な理由により判断した場合、甲は、乙に、書面によりその理由を通知し、当該第三者に対する再委託の中止を請求することができる。
3. 乙は、本契約に基づいて甲が甲に対して負担するのと同様の義務を、再委託先に負わせなければならない。また、本委託業務に関する再委託先の行為について、自らの行為と同様の責任を負うものとする。ただし、乙の指定した再委託先の行為については、乙に故意又は重大過失がある場合を除き、責任を負わない。

第9条 (納入及び検収)

1. 乙は、甲に対し、契約要綱記載の納期までに、契約要綱記載の納入物を納入する。乙が納入に際し、甲に対して必要な協力を要請した場合、甲は、すみやかにこれに応じなければならない。
2. 甲は、契約要綱記載の検査完了期日までに、甲乙が合意した内容の検査を行い、納入物が当該検査に合格した場合、乙に対し検査合格証を交付する。
3. 甲は、納入物が前項の検査に合格しない場合、乙に対し不合格となった具体的な理由を明示した書面を交付して修正又は返戻を求め、乙は、協議の上定めた期限内に納入物を無償で修正又は返戻したうえで甲に再度納入し、検査を受けなければならない。
4. 検査完了期日までに前2項に定める検査合格証又は不合格の理由を明示した書面が乙に対し交付されない場合、甲が検査遅延の理由について書面で合理的な理由を明示したときを除き、納入物は、本案所定の検査に合格したものとみなす。
5. 本案所定の検査に合格したことをもって、納入物の検収完了とし、納入物の引渡しが完了したものとみなす。

第10条 (契約不適合責任)

1. 納入物に本契約の内容との不適合があった場合、甲は、乙に対し、当該納入物の無償での修繕、代替品の納入又は不足分の納入等の方法による履行の追完を請求することができる。ただし、乙は、甲に不相当な負担を課するものでないときは、甲が請求した方法及び異なる方法による履行の追完をすることができる。
2. 甲が、前項により相当の期間を定めて履行の追完の催告をし、その期間内に履行の追完が完了しないときは、甲は、その不適合の程度に応じて業務委託料の減額を請求することができる。
3. 乙が本契約の内容との不適合のある納入物を甲に引き渡した場合において、甲が引渡し時から【1】年以内にその旨を乙に通知しないときは、甲は、その不適合を理由として、履行の追完の請求、業務委託料の減額の請求、損害賠償の請求及び本契約の解除をすることができる。
4. 甲の責めに帰すべき事由により契約不適合が生じたときは、甲は、履行の追完、業務委託料の減額又は返還、損害賠償の請求及び契約の解除をすることができない。

第11条 (納入物の所有権)

1. 納入物の所有権は、第9条に定める検収が完了したときに、乙から甲へ移転する。
2. 納入物の滅失、毀損等の危険負担は、納入前については乙が、納入後については甲がそれぞれ負担する。

第12条 (納入物の知的財産権等)

1. 納入物に関する著作権（著作権法第27条及び第28条に規定する権利を含む。）は、当該納入物にかかる本業務委託料の支払いが完了した時点で、甲に帰属する。ただし、乙又は第三者が従前から保有していた著作権は、乙又は当該第三者に留保されるものとする。
2. 乙は、納入物について著作権人格権を行使しないものとする。
3. 本委託業務遂行の過程で生じた発明その他の知的財産又はノウハウ等（以下、併せて「発明等」という。）に係る特許権その他の知的財産権（特許その他の知的財産権を受ける権利を含む）、ノウハウ等に関する権利（以下、特許権その他の知的財産権、ノウハウ等に関する権利を総称して「特許権等」という。）は、第1項に基づき甲に帰属する著作権を除き、当該発明等を行った者が属する当事者に帰属する。
4. 乙は、前項に基づき特許権等を保有する場合、甲に対し、甲が納入物を使用するのに必要な範囲において、当該特許権等の通常実施権を許諾する。なお、当該特許権の対価は、本業務委託料に含まれる。

第13条 (知的財産権の侵害)

1. 甲は、乙による本委託業務の履行に起因して第三者から知的財産権の侵害の申立てを受けたときは、速やかに乙に対して申立ての事実及び内容を通知する。
2. 前項の場合において、乙は、甲が第三者との交渉又は訴訟の遂行に関し、乙に実質的な参加の機会及び決定の権限を与え、必要な援助を行ったときは、甲が支払うべきとされた損害賠償額を負担する。ただし、当該知的財産権の侵害が専ら甲の責めに帰すべき事由により生じた場合には、乙は賠償する義務を負わない。
3. 乙は、本委託業務の履行に起因する第三者の知的財産権の侵害に関し、本案の定めに従った責任を負い、それ以外に一切責任を負わない。

第14条 (秘密保持)

1. 甲及び乙は、本契約の存在及び内容並びに本契約に関連して知った相手方に関する情報（以下「秘密情報」という。）を、相手方の書面による事前の承諾なく第三者に対して開示、提供又は漏洩してはならない。ただし、次のいずれかに該当することを証明できる情報については、秘密情報から除くものとする。
(1) 提供又は開示を受けた際、既に自己が保有していた情報
(2) 提供又は開示を受けた際、既に公知となっている情報
(3) 提供又は開示を受けた後、自己の責めにやらずに公知となった情報
(4) 正当な権限を有する第三者から秘密保持義務を負わずに適法に取得した情報

(5) 秘密情報によることなく独自に開発又は取得した情報
(6) 法令の規定又は権限ある官公庁からの開示の要求に基づき開示しなければならない情報

2. 甲及び乙は、秘密情報を本契約の目的以外に使用してはならない。

3. 甲及び乙は、秘密情報を、本契約の遂行のために知る必要がある自己の役員及び従業員（以下「役員等」という。）並びに弁護士等の法令上守秘義務を負う専門家に限り開示等することができる。この場合、本条に基づき秘密情報の受領者が負担する義務と同等の義務を、開示等を受けた当該役員等に退職後も含め課さなければならない。

4. 本契約が終了した場合、甲及び乙は、相手方の指示に従って、秘密情報を返還し、又は、破棄するものとする。なお、相手方は受領者に対し、秘密情報等の返還又は破棄を証明する文書の提出を求めることができる。

第15条（個人情報）

1. 乙は、本委託業務遂行に際して甲より取扱いを委託された個人情報（個人情報の保護に関する法律に定める個人情報をいう。以下同じ。）を適切に管理し、他に開示、漏洩、又は公開してはならない。

2. 乙は、個人情報を、本契約の目的の範囲内でのみ使用しなければならない。

3. 個人情報が必要と認められたときは、乙は遅滞なく甲の指示に従い返還等の処置を行うものとする。

第16条（報告等）

1. 甲が、本委託業務の遂行状況又は秘密情報若しくは個人情報の管理状況について乙に報告を求めたときは、乙は、これを速やかに甲に報告しなければならない。

2. 本委託業務に関する問題が発生し、若しくはそのおそれがある場合又は乙に本契約違反があると合理的理由により認められる場合には、甲は、乙に検査の日 日前までに書面で通知することにより、乙の営業時間中、乙の事業所に立ち入り、本契約の履行状況を調査することができる。

第17条（損害賠償）

甲又は乙は、自己の責めに帰すべき事由により本契約に違反して相手方に損害を与えた場合、その損害を賠償する義務を負う。

第18条（遅延損害金）

甲及び乙は、本契約に基づく債務の支払を遅滞したときは、相手方に対し、当該債務の支払期日の翌日から支払済みまで年【14.6】%（年365日の日割計算）の割合による遅延損害金を支払わなければならない。

第19条（解除等）

1. 甲又は乙が本契約のいずれかの条項に違反し、相手方からその是正を要求する通知を受領した後 日以内にその違反を是正しない場合は、相手方は、違反者にその旨を通知することにより、本契約を直ちに解除することができる。

2. 甲は、乙が以下の各号に定める事由のいずれかに該当した場合には、何らの催告なくして、直ちに本契約を解除することができる。

(1) 重大な過失又は背信行為があった場合
(2) 手形若しくは小切手の不渡りが生じたとき、電子交換所の取引停止処分を受けたとき、又は支払停止の状態に陥ったとき。
(3) 第三者より差押え、仮差押え、仮処分、強制執行などをを受けたとき、又は公租公課の滞納処分を受けたとき。
(4) 破産手続、特別清算、民事再生手続又は会社更生手続開始の申立てがあったとき。
(5) 債務整理の通知がなされたとき
(6) その他財務状態が著しく悪化し、又は悪化のおそれがあるとき。
(7) その他前各号に準ずるような本契約を継続し難い重大な事由が発生した場合

第20条（契約終了時の措置）

本契約が事由の如何を問わず本委託業務の履行完了前に終了した場合、甲は、乙に対し、既に履行された本委託業務の内容に応じた本業務委託料を支払わなければならない。なお、本条の規定は、第17条並びに民法641条及び642条の規定を排除するものではない。

第21条（反社会的勢力の排除）

1. 甲及び乙は、自社、自社の株主・役員その他自社を実質的に所有し、若しくは支配するものが、現在、暴力団、暴力団員でなくなった時から5年を経過しない者、暴力団準構成員、暴力団関係企業、総会屋等、社会運動等標ぼうゴロ又は特殊知能暴力集団等、その他これらに準ずる者（以下、これらを「暴力団員等」という。）に該当しないこと、及び各号のいずれにも該当しないことを表明し、かつ将来にわたっても該当しないことを確約する。

(1) 暴力団員等が経営を支配していると認められる関係を有すること
(2) 暴力団員等が経営に実質的に関与していると認められる関係を有すること
(3) 自己、自社若しくは第三者の不正の利益を図る目的又は第三者に損害を加える目的をもってする等、不当に暴力団員等を利用していると認められる関係を有すること
(4) 暴力団員等に対して資金等を提供し、又は便宜を供与する等の関与をしていると認められる関係を有すること
(5) 役員又は経営に実質的に関与している者が暴力団員等と社会的に非難されるべき関係を有すること

2. 甲及び乙は、暴力団員等と取引関係を有してはならず、事後的に、暴力団員等との取引関係が判明した場合には、これを相当期間内に解消できるよう必要な措置を講じる。

3. 甲及び乙は、相手方が本条の表明又は確約に違反した場合、何らの通知又は催告をすることなく直ちに本契約の全部又は一部について、履行を停止し、又は解除することができる。この場合において、表明又は確約に違反した当事者は、相手方の履行停止又は解除によって被った損害の賠償を請求することができる。

4. 甲及び乙は、相手方が本条の表明又は確約に違反した場合、これによって被った一切の損害の賠償を請求することができる。

第22条（本契約上の地位譲渡等の禁止）

甲及び乙は、相手方の書面による事前の承諾がない限り、本契約上の権利及び義務並びに本契約上の地位を第三者へ譲渡し、又は担保に供してはならない。

第23条（存続条項）

本契約が終了した場合でも、第10条から第15条、第17条、第18条、第20条、第21条3項から4項、及び、本条から第26条は有効に存続する。ただし、第14条については、本契約の終了後【2】年間に限り、その効力を有する。

第24条（準拠法）

本契約は、日本法を準拠法とする。

第25条（合意管轄）

本契約に関する一切の紛争については、法令に専属管轄の定めがある場合を除き、被告の住所地を管轄する地方裁判所又は簡易裁判所を第一審の専属的合意管轄裁判所とする。

第26条（協議）

甲及び乙は、本契約に定めがない場合及び本契約の条項の解釈について疑義が生じた場合は、民法その他の法令及び慣行に従い、誠意をもって協議し、解決するものとする。本契約の成立を証するため本書2通を作成し、各自記名押印のうえ、各1通を保有する。

○年○月○日

委託者（甲）
受託者（乙）

Contract 4: An example post-revised contract for ReqRev and RiskRev

“業務委託契約書”
委託者○○（以下「甲」という。）及び受託者（以下「乙」という。）は、契約要綱記載の業務の委託に関して、次のとおり、業務委託契約（以下「本契約」という。）を締結する。

“<契約要綱>”

本委託業務の表示
納入物
納期・検査完了期日
納入場所
業務委託料
業務委託料の支払時期
支払方法
特約事項

第1条（業務の委託）

1. 甲は、契約要綱記載の業務（以下「本委託業務」という。）を乙に委託し、乙はこれを受託する。

2. 乙は、本委託業務を、善良なる管理者の注意義務をもって遂行し、本委託業務に関連する法令を遵守し、本契約にて定められた業務の遂行について、事業主として財政上及び法律上を含む全ての責任を負う。

第2条（本委託業務の詳細）

本委託業務の詳細については、甲乙別途協議のうえ定めるものとし、必要に応じて手順書等を作成する。

第3条（業務委託料及びその支払方法）

1. 甲は乙に対し、本委託業務の対価として、契約要綱記載の業務委託料並びにこれに対する消費税及び地方消費税（以下、併せて「本業務委託料」という。）を支払う。

2. 乙は、第9条に定める検査が完了した場合、甲に対し本業務委託料にかかる請求書を支付するものとし、甲は、本業務委託料を契約要綱記載の期日までに、契約要綱記載の方法により支払う。

第4条（納期）

本委託業務にかかる納期は、契約要綱に定めたとおりとする。

第5条（責任者）

1. 甲及び乙は、本契約締結後速やかに、本契約における各自の責任者をそれぞれ選任し、互いに書面により、相手方に通知する。

2. 甲及び乙は、事前に書面により相手方に通知することにより、責任者を変更することができる。

3. 甲及び乙の責任者は、本委託業務遂行に必要な意思決定、指示、同意等を行う権限及び責任を有する。本委託業務に関する要請、指示、依頼その他の連絡、確認等は原則として責任者を通じて行わなければならない。

第6条（業務従事者）

1. 乙は、労働法規その他関係法令に基づき、本委託業務に従事する乙の従業員（以下「業務従事者」という。）に対し雇用主としての一切の義務を負うものとし、業務従事者に対する本委託業務遂行に関する指示、労務管理、安全衛生管理等に関する一切の指揮命令を行う。

2. 乙は、本委託業務遂行上、業務従事者が甲の事務所等に立ち入る場合、甲の防犯、秩序維持等に関する諸規則を当該業務従事者に遵守させなければならない。

第7条（資料等の提供）

1. 甲は乙に対し、本委託業務遂行に必要な資料等を提供する。乙は甲から提供された本委託業務に関する資料等を善良なる管理者の注意をもって管理、保管するものとし、本委託業務以外の用途に使用してはならない。

2. 本委託業務遂行上、甲の事務所等で乙が作業を実施する必要がある場合、甲は当該作業実施場所（当該作業実施場所における必要な機器、設備等作業環境を含む。）を、甲乙協議の上、乙に提供するものとする。

3. 甲が前各項より乙に提供する資料等又は作業実施場所に関し、内容等の誤り又は甲の提供遅延があった場合、これにより生じた乙の本委託業務の履行遅滞、納入物の契約不適合等の結果については、乙はその責を免れる。

4. 甲から提供を受けた資料等が本委託業務遂行上不要となったときは、乙は遅滞なく資料等につき甲の指示に従い返還等の処置を行うものとする。

第8条（再委託）

1. 乙は、乙の責任において、本委託業務の一部を第三者に再委託することができる。ただし、乙は、甲が要請した場合、再委託先の名称及び住所等を甲に報告しなければならない。
2. 甲が前項に定める再委託先が不適切であると合理的な理由により判断した場合、甲は、乙に、書面によりその理由を通知し、当該第三者に対する再委託の中止を請求することができる。
3. 乙は、本契約に基づいて乙が甲に対して負担するのと同様の義務を、再委託先に負わせなければならない。また、本委託業務に関する再委託先の行為について、自らの行為と同様の責任を負うものとする。ただし、甲が指定した再委託先の行為については、乙に故意又は重大な過失がある場合を除き、責任を負わない。

第9条 (納入及び検収)

1. 乙は、甲に対し、契約要約記載の納期までに、契約要約記載の納入物を納入する。乙が納入に際し、甲に対して必要な協力を要請した場合、甲は、すみやかにこれに応じなければならない。
2. 甲は、契約要約記載の検査完了期日までに、甲乙が合意した内容の検査を行い、納入物が当該検査に合格した場合、乙に対し検査合格証を交付する。
3. 甲は、納入物が前項の検査に合格しない場合、乙に対し不合格となった具体的な理由を明示した書面を交付して修正又は追完を求めることができる。乙は、協議の上定めた期限内に納入物を無償で修正又は追完したうえで甲に再度納入し、検査を受けなければならない。
4. 検査完了期日までに前2項に定める検査合格証又は不合格の理由を明示した書面が乙に対し交付されない場合、甲が検査遅延の理由について書面で合理的な理由を明示したときを除き、納入物は、本条所定の検査に合格したものとみなす。
5. 本条所定の検査に合格したことをもって、納入物の検収完了とし、納入物の引渡しが完了したものとみなす。

第10条 (契約不適合責任)

1. 納入物に本契約の内容との不適合があった場合、甲は、乙に対し、当該納入物の無償での修補、代替品の納入又は不足分の納入等の方法による履行の追完を請求することができる。ただし、乙は、甲に不相当な負担を課するものでないときは、甲が請求した方法と異なる方法による履行の追完をすることができる。
2. 甲が、前項により相当の期間を定めて履行の追完の催告をし、その期間内に履行の追完がないときは、甲は、その不適合の程度に応じて業務委託料の減額を請求することができる。
3. 乙が本契約の内容との不適合のある納入物を甲に引き渡した場合において、甲が引渡した時から【1】年以内にその旨を乙に通知しないときは、甲は、その不適合を理由として、履行の追完の請求、業務委託料の減額の請求、損害賠償の請求及び本契約の解除をすることができる。
4. 甲の責めに帰すべき事由により契約不適合が生じたときは、甲は、履行の追完、業務委託料の減額又は返還、損害賠償の請求及び契約の解除をすることができる。

第11条 (納入物の所有権)

1. 納入物の所有権は、第9条に定める検収が完了したときに、乙から甲へ移転する。
2. 納入物の滅失、毀損等の危険負担は、納入前については乙が、納入後については甲がそれぞれ負担する。

第12条 (納入物の知的財産権等)

1. 納入物に関する著作権 (著作権法第27条及び第28条に規定する権利を含む) は、当該納入物にかかる本業務委託料の支払いが完了した時点で、甲に帰属する。ただし、乙又は第三者が従前から保有していた著作権は、乙又は当該第三者に留保されるものとする。

2. 乙は、納入物について著作権者人格権を行使しないものとする。
3. 本委託業務遂行の過程で生じた発明その他の知的財産又はノウハウ等 (以下、併せて「発明等」という。) に係る特許権その他の知的財産権 (特許その他の知的財産権を受ける権利を含む。)、ノウハウ等に関する権利 (以下、特許権その他の知的財産権、ノウハウ等に関する権利を総称して「特許権等」という。) は、第1項に基づき甲に帰属する著作権を除き、当該発明等を行った者が属する当事者に帰属する。
4. 乙は、前項に基づき特許権等を保有する場合、甲に対し、甲が納入物を使用するのに必要な範囲において、当該特許権等の通常実施権を許諾する。なお、当該許諾の対価は、本業務委託料に含まれる。

第13条 (知的財産権の侵害)

1. 甲は、乙による本委託業務の履行に起因して第三者から知的財産権の侵害の申立てを受けたときは、速やかに乙に対して申立ての事実及び内容を通知する。
2. 前項の場合において、乙は、甲が第三者との交渉又は訴訟の遂行に関し、乙に実質的な参加の機会及び決定の権限を与え、必要な援助を行ったときは、甲が支払うべきとされた損害賠償額を負担する。ただし、当該知的財産権の侵害が専ら甲の責に帰すべき事由により生じた場合には、乙は賠償する義務を負わない。
3. 乙は、本委託業務の履行に起因する第三者の知的財産権の侵害に関し、本条の定めに従った責任のみを負い、それ以外に一切責任を負わない。

第14条 (秘密保持)

1. 甲及び乙は、本契約の存在及び内容並びに本契約に関連して知った相手方に関する情報 (以下「秘密情報」という) を、相手方の書面による事前の承諾なく第三者に対して開示、提供又は漏洩してはならない。ただし、次のいずれかに該当することを証明できる情報については、秘密情報から除くものとする。

- (1) 提供又は開示を受けた際、既に自己が保有していた情報
- (2) 提供又は開示を受けた際、既に公知となっている情報
- (3) 提供又は開示を受けた後、自己の責めに伴って公知となった情報
- (4) 正当な権限を有する第三者から秘密保持義務を負わずに適法に取得した情報
- (5) 秘密情報によることなく独自に開発又は取得した情報
- (6) 法令の規定又は権限ある官公庁からの開示の要求に基づき開示しなければならない情報

2. 甲及び乙は、秘密情報を本契約の目的以外に使用してはならない。
3. 甲及び乙は、秘密情報を、本契約の遂行のために知る必要のある自己の役員及び従業員 (以下「役員等」という) 並びに弁護士等の法令上守秘義務を負う専門家に限り開示することができる。この場合、本条に基づき秘密情報の受領者が負担する義務と同等の義務を、開示を受けた当該役員等に退職後も含め課さなければならない。
4. 本契約が終了した場合、甲及び乙は、相手方の指示に従って、秘密情報を返還し、又は、破壊するものとする。なお、相手方は受領者に対し、秘密情報等の返還又は破壊を証明する文書の提出を求めることができる。

第15条 (個人情報)

1. 乙は、本委託業務遂行に際して甲より取扱いを委託された個人情報 (個人情報の保護に関する法律に定める個人情報をいう。以下同じ) を適切に管理し、他に開示、漏洩、又は公開してはならない。

2. 乙は、個人情報、本契約の目的の範囲内のみ使用しなければならない。
3. 個人情報が本委託業務遂行上不要となったときは、乙は遅滞なく甲の指示に従い返還等の処置を行うものとする。

第16条 (報告等)

1. 甲が、本委託業務の遂行状況又は秘密情報若しくは個人情報の管理状況について乙に報告を求めたときは、乙は、これを速やかに甲に報告しなければならない。
2. 本委託業務に関する問題が発生し、若しくはそのおそれがある場合又は乙に本契約違反があると合理的理由により認められる場合には、甲は、乙に検査日の 日前までに書面で通知することにより、乙の営業時間中、乙の事業所に立ち入り、本契約の履行状況を検査することができる。

第17条 (損害賠償)

- 甲及び乙は、自己の責めに帰すべき事由により本契約に違反して相手方に損害を与えた場合、その損害を賠償する義務を負う。

第18条 (遅延損害金)

- 甲及び乙は、本契約に基づき債務の支払を遅滞したときは、相手方に対し、当該債務の支払期日の翌日から支払済みまで【14.6】% (年 365 日の日割計算) の割合による遅延損害金を支払わなければならない。

第19条 (解除等)

1. 甲又は乙が本契約のいずれかの条項に違反し、相手方からその是正を要求する通知を受領した後 日以内にその違反を是正しない場合は、相手方は、違反者にその旨を通知することにより、本契約を直ちに解除することができる。

2. 甲は、乙が以下の各号に定める事由のいずれかに該当した場合には、何らの催告なくして、直ちに本契約を解除することができる。

- (1) 重大な過失又は背信行為があった場合
- (2) 手形若しくは小切手の不渡りが生じたとき、電子交換所の取引停止処分を受けたとき、又は支払停止の状態に陥ったとき
- (3) 第三者より差押入、仮差押入、仮処分、強制執行などを受けたとき、又は公租公課の滞納処分を受けたとき
- (4) 破産手続、特別清算、民事再生手続又は会社更生手続開始の申立てがあったとき
- (5) 債務整理の通知がなされたとき
- (6) その他財務状態が著しく悪化し、又は悪化のおそれがあるとき
- (7) その他前各号に準ずるような本契約を継続し難い重大な事由が発生した場合

第20条 (契約終了時の措置)

- 本契約が事由の如何を問わず本委託業務の履行完了前に終了した場合、甲は、乙に対し、既に履行された本委託業務の内容に応じた本業務委託料を支払わなければならない。なお、本条の規定は、第17条並びに民法641条及び642条の規定を排除するものではない。

第21条 (反社会的勢力の排除)

1. 甲及び乙は、自社、自社の株主・役員その他自社を実質的に所有し、若しくは支配するものが、現在、暴力団、暴力団員、暴力団員でなくなった時から5年を経過しない者、暴力団準構成員、暴力団関係企業、総会屋等、社会運動等構成員、若しくは特殊技能暴力集団等、その他これらに準ずる者 (以下、これらを「暴力団員等」という) に該当しないこと、及び次の各号のいずれにも該当しないことを表明し、かつ将来にわたっても該当しないことを確約する。

- (1) 暴力団員等が経営に実質的に関与していると認められる関係を有すること
- (2) 暴力団員等が経営に実質的に関与している目的又は第三者に損害を加える目的をもってする等、不当に暴力団員等を利用していると認められる関係を有すること
- (3) 自己、自社若しくは第三者の不正の利益を図る目的又は第三者に損害を加える目的をもってする等、不当に暴力団員等を利用していると認められる関係を有すること
- (4) 暴力団員等に対して資金等を提供し、又は便宜を供与する等の関与をしていると認められる関係を有すること
- (5) 役員又は経営に実質的に関与している者が暴力団員等と社会的に非難されるべき関係を有すること

2. 甲及び乙は、暴力団員等と取引関係を有してはならず、事後的に、暴力団員等との取引関係が判明した場合には、これを相当期間内に解消できるよう必要な措置を講じる。
3. 甲及び乙は、相手方が本条の表明又は確約に違反した場合、何らの通知又は催告をすることなく直ちに本契約の全部又は一部について、履行を停止し、又は解除することができる。この場合において、表明又は確約に違反した当事者は、相手方の履行停止又は解除によって被った損害の賠償を請求することはできない。
4. 甲及び乙は、相手方が本条の表明又は確約に違反した場合、これによって被った一切の損害の賠償を請求することができる。

第22条 (本契約上の地位譲渡等の禁止)

- 甲及び乙は、相手方の書面による事前の承諾がない限り、本契約上の権利及び義務並びに本契約上の地位を第三者へ譲渡し、又は担保に供してはならない。

第23条 (存続条項)

- 本契約が終了した場合でも、第10条から第15条、第17条、第18条、第20条、第21条3項から4項、及び、本条から第26条は有効に存続する。ただし、第14条については、本契約の終了後【2】年間に限り、その効力を有する。

第24条 (準拠法)

- 本契約は、日本法を準拠法とする。

第25条 (合意管轄)

- 本契約に関する一切の紛争については、法令に専属管轄の定めがある場合を除き、被告の住所地を管轄する地方裁判所又は簡易裁判所を第一審の専属的合意管轄裁判所とする。

第26条 (協議)

- 甲及び乙は、本契約に定めがない場合及び本契約の条項の解釈について疑義が生じた場合は、民法その他の法令及び慣行に従い、誠意をもって協議し、解決するものとする。

- 本契約の成立を証するため本書2通を作成し、各自記名押印のうえ、各1通を保有する。

○年○月○日

委託者 (甲)

受託者 (乙)

Prompt 3: Inference Prompt for AmendExp

User prompt

あなたは法律の専門家です。古い法令・新しい法令が与えられます。まず本質的な変更点のみを列挙し（表記揺れ・語尾・軽微な用語統一・条ずれ等は無視）、続いて各変更が契約書へ与える影響を、根拠となる法令の条番号付きで列挙してください。

【入力】

古い法令: {old_statute}

新しい法令: {new_statute}

【作業規則】

- 実務影響が見込まれる ** 本質的変更 ** のみ抽出
- 表記の揺れ、句読点、順序入替、同義語置換など ** 軽微な変化は全て無視 **
- 政府の参考資料が存在する場合は ** そこに明記の変更点を優先 ** し、該当しない細部は出力しない
- 契約書への影響には、具体的な修正対象（条・項・別紙の種類など）と ** 根拠条番号（新旧） ** を併記
- 変更点や影響がない場合は「(該当なし)」と明示

【出力仕様】

- 出力は次のタグ内 ** のみ ** に記載
- タグ内は ** 以下のコードブロック形式 ** を厳密に守る

<OUTPUT>

法令の変更点

- 変更点 1

- 変更点 2

契約書への影響

- 変更点 1

- 変更点 2

</OUTPUT>

Prompt 4: Inference Prompt for StatRev

User prompt

あなたは経験豊富な法務専門家です。古い法令に基づく契約書を新しい法令に適合させてください。

【入力】

古い法令:

{old_statute}

新しい法令:

{new_statute}

修正対象の契約書:

{contract}

【作業規則】

- 契約書の構造と形式は可能な限り維持
- 変更が必要な条文のみ修正（無関係な条文は出力しない）
- 条番号・見出しは元の表記を踏襲

【出力仕様】

- 冒頭は ** 「修正後の契約書:」 ** の文字列から開始
- その直後に改行し、** 差分がある条文のみ ** を本文として出力
- 出力は次のタグで囲む。タグ外には一切出力しない

<OUTPUT>

修正後の契約書:

(ここに修正後の条文のみ)

</OUTPUT>

Prompt 5: Inference Prompt for ReqRev

System prompt

あなたは最高水準の法務専門家です。
契約書の修正において以下の品質基準を満たしてください：

【必須要件】

- 指示された全ての修正を漏れなく実行
- 条項番号の整合性を完璧に維持
- 引用条項番号の適切な更新
- 法的に正確で明確な表現の使用

【品質基準】

- 契約書の構造と論理性を保持
- 専門的で統一された文体
- 曖昧さのない明確な条文

最高品質の修正結果を提供してください。

User prompt

以下の契約書に対して、指定された修正を行ってください。

契約書:

{contract_text}

修正指示:

{instruction}

修正された契約書全体を出力してください。

Prompt 6: Inference Prompt for RiskRev

System prompt

あなたは最高水準の法務専門家です。
契約書の修正において以下の品質基準を満たしてください：

【必須要件】

- 指定された契約リスクを解消するための修正を漏れなく実行
- 条項番号の整合性を完璧に維持
- 引用条項番号の適切な更新

- 法的に正確で明確な表現の使用

【品質基準】

- 契約書の構造と論理性を保持
- 専門的で統一された文体
- 曖昧さのない明確な条文

最高品質の修正結果を提供してください。

User prompt

以下の契約書に対して、指定されたリスク対策の観点から修正を行ってください。

契約書:

{contract_text}

修正指示:

{instruction}

修正された契約書全体を出力してください。

Prompt 7: Evaluation Prompt for AmendExp

User prompt

あなたは法律専門家による法令改正説明の評価を行う専門家です。以下の内容について評価してください。

【評価対象】

元のプロンプト: {original_prompt}

LLM の回答: {llm_response}

【正解データ】

{ground_truth}

【評価基準】

下記の評価尺度に基づいて以下の観点から評価し、具体的な理由を述べてください：

1. ** 改正の概要 - 主要な変更点の網羅性 ** (0-2 点)
 - 0: 主要な変更点が網羅されておらず、重要な変更が多数漏れている
 - 1: 主要な変更点の一部は網羅されているが、不足がある
 - 2: 主要な変更点を十分に網羅しており、全体像を把握できる
2. ** 改正の概要 - 変更点の説明精度 ** (0-2 点)
 - 0: 変更点の説明に重大な誤りや不正確さがある
 - 1: 概ね正確だが、一部に不十分な説明や曖昧な表現がある
 - 2: 変更点の説明が正確で、法令解釈や表現も適切である
3. ** 改正の概要 - 不要内容の排除 ** (0-2 点)
 - 0: 不要な内容や本質的でない変更が多く含まれている
 - 1: 一部に不要な内容が含まれるが、全体として許容範囲
 - 2: 不要な内容は含まれず、簡潔で要点に絞られている
4. ** 契約書への影響 - 影響事項の網羅性 ** (0-2 点)
 - 0: 契約書に影響する主要な事項を把握できていない
 - 1: 一部の影響事項を把握しているが、不足がある
 - 2: 影響事項を十分に網羅し、実務的な影響も特定できている
5. ** 契約書への影響 - 影響説明の正確性 ** (0-2 点)
 - 0: 影響説明に重大な誤りや不正確さがある
 - 1: 概ね正確だが、一部に不足や不明確な点がある
 - 2: 影響について正確に説明され、根拠や実務対応も明確である
6. ** 契約書への影響 - 不要内容の排除 ** (0-2 点)
 - 0: 契約書に関係のない不要内容が多く含まれている
 - 1: 一部に不要な内容が含まれるが、全体として許容範囲
 - 2: 不要な内容を含まず、実務に直結した要点に絞られている

Prompt 8: Evaluation Prompt for StatRev

User prompt

あなたは法改正による契約書修正の評価を行う専門家です。以下の内容について評価してください。

【評価対象】

元のプロンプト: {original_prompt}

LLM の回答: {llm_response}

【正解データ】

{ground_truth}

【評価基準】

下記の評価尺度に基づいて以下の観点から評価し、具体的な理由を述べてください：

1. ** 修正内容の新法令準拠性 ** (0-2 点)
 - 0: 新法令に全く準拠していない/誤解を招く修正をしている
 - 1: 新法令の一部は反映されているが、不十分または誤りがある
 - 2: 新法令に完全に準拠し、解釈や反映も適切である
2. ** 契約書構造 (条番号など) が整合している ** (0-1 点)
 - 0: 契約書構造の整合性が失われている
 - 1: 契約書構造は整合している
3. ** 不要な修正がされていないか ** (0-1 点)
 - 0: 不要な修正がされている
 - 1: 不要な修正がされていない
4. ** 専門用語の正確性 ** (0-2 点)
 - 0: 実務上重大な誤りのある専門用語の使用をしている
 - 1: 実務上問題はないが、不自然または誤解を招く専門用語がある
 - 2: 専門用語が正確かつ自然に使用されている
5. ** 契約書言い回しの適切性 ** (0-2 点)
 - 0: 契約書的な言い回しが全く適切でなく、口語的・不明確である
 - 1: 契約書的な言い回しが一部適切でない、または曖昧な表現がある
 - 2: 契約書的な言い回しが適切で、明確かつ簡潔である

Prompt 9: Evaluation Prompt for ReqRev

User prompt

あなたは契約書修正の評価を行う法務専門家です。以下の内容について評価してください。

【評価対象】

元の契約書: {original_prompt}

修正指示: {instruction}

LLM による修正後契約書: {llm_response}

【正解データ】

{ground_truth}

【評価基準】

下記の評価尺度に基づいて以下の観点から評価し、具体的な理由を述べてください：

1. ** 指示通りの修正がされているか ** (0-2 点)
 - 0: 要件が全く満たされていない
 - 1: 要件が一部満たされているが、一部満たされていない
 - 2: 要件が全て満たされている

- 2. ** 契約書構造（条番号など）が整合している ** (0-1 点)
 - '0': 契約書構造の整合性が失われている
 - '1': 契約書構造は整合している
- 3. ** 指示されていない不要な修正がされていないか ** (0-1 点)
 - '0': 指示されていない不要な修正がされている
 - '1': 指示されていない不要な修正がされていない。条番号や項番号、引用条項に関する書式の変更は許容される。修正指示を拡大解釈して修正している場合も許容される。
- 4. ** 専門用語が正しく使用されているか ** (0-2 点)
 - '0': 実務上問題になる誤った専門用語の使い方をしている
 - '1': 実務上問題はないが、専門用語が適切に使用されていない
 - '2': 専門用語に関して違和感なく自然な表現が用いられている。曖昧な表現や広範な表現については許容される。
- 5. ** 契約書的な言い回しが適切に使用されているか ** (0-2 点)
 - '0': 契約書的な言い回しが全く適切でない
 - '1': 契約書的な言い回しが一部適切でない
 - '2': 契約書的な言い回しが全て適切に用いられている

Prompt 10: Evaluation Prompt for RiskRev

User prompt

あなたは契約書修正の評価を行う法務専門家です。以下の内容について評価してください。

【評価対象】

元の契約書: {original_prompt}

修正指示: {instruction}

LLM による修正後契約書: {llm_response}

【正解データ】

{ground_truth}

【評価基準】

下記の評価尺度に基づいて以下の観点から評価し、具体的な理由を述べてください：

- 1. ** 指示通りの修正がされているか ** (0-2 点)
 - '0': リスクが全く解消されていない
 - '1': リスクが一部解消されているが、一部解消されていない
 - '2': リスクが全て解消されている
- 2. ** 契約書構造（条番号など）が整合している ** (0-1 点)
 - '0': 契約書構造の整合性が失われている
 - '1': 契約書構造は整合している
- 3. ** 不要な修正がされていないか ** (0-1 点)
 - '0': 不要な修正がされている
 - '1': 不要な修正がされていない
- 4. ** 専門用語が正しく使用されているか ** (0-2 点)
 - '0': 実務上問題になる誤った専門用語の使い方をしている
 - '1': 実務上問題はないが、専門用語が適切に使用されていない
 - '2': 専門用語に関して違和感なく自然な表現が用いられている
- 5. ** 契約書的な言い回しが適切に使用されているか ** (0-2 点)
 - '0': 契約書的な言い回しが全く適切でない
 - '1': 契約書的な言い回しが一部適切でない
 - '2': 契約書的な言い回しが全て適切に用いられている