# ロングテイルな分布の入力を扱う機械学習システムに対するテスト設計手法の提案

第３８年度 研究コース５「人工知能とソフトウェア品質」
○ 松尾正裕（パナソニック ITS 株式会社）
後藤 優斗（アクセンチュア株式会社）

# 背景と課題

# 映像の振り返り



## AI商社からの提案

| モデルの名前 | 学習に使用したデータ | 読み取り精度 | 順位 |
|---|---|---|---|
| A社が作った万能型 | 秘伝のデータセットにつき非公開 | 0.861 | 2 |
| 日本の老舗ソフトウェアベンダーB社モデル | 2245文字すべてを学習 | 0.598 | 4 |
| イケイケ外資系C社モデル | 2245文字のうち、名字でよく使用されている文字の95%である875文字 | 0.645 | 3 |
| スタートアップのD社モデル | 2245文字のうち、名字でよく使用されている文字の80%である325文字 | **0.960** | **1** |

果たして、D社のモデルを活用していいのだろうか？

**後藤銀行のシステム担当者**

# 背景と課題–出現頻度調査



## 名字の調査

- 全国の名字における上位40,000件のデータを取得し、文字の出現頻度を集計

| 名字 |
|---|
| 中田 |
| 森田 |
| : |
| 田中 |
| 鈴木 |

出現頻度を集計

| ID | 文字 | 出現頻度 |
|---|---|---|
| 1 | 田 | 2230 |
| 2 | 森 | 1576 |
| : | : | : |
| 2244 | 駕 | 1 |
| 2245 | 粧 | 1 |

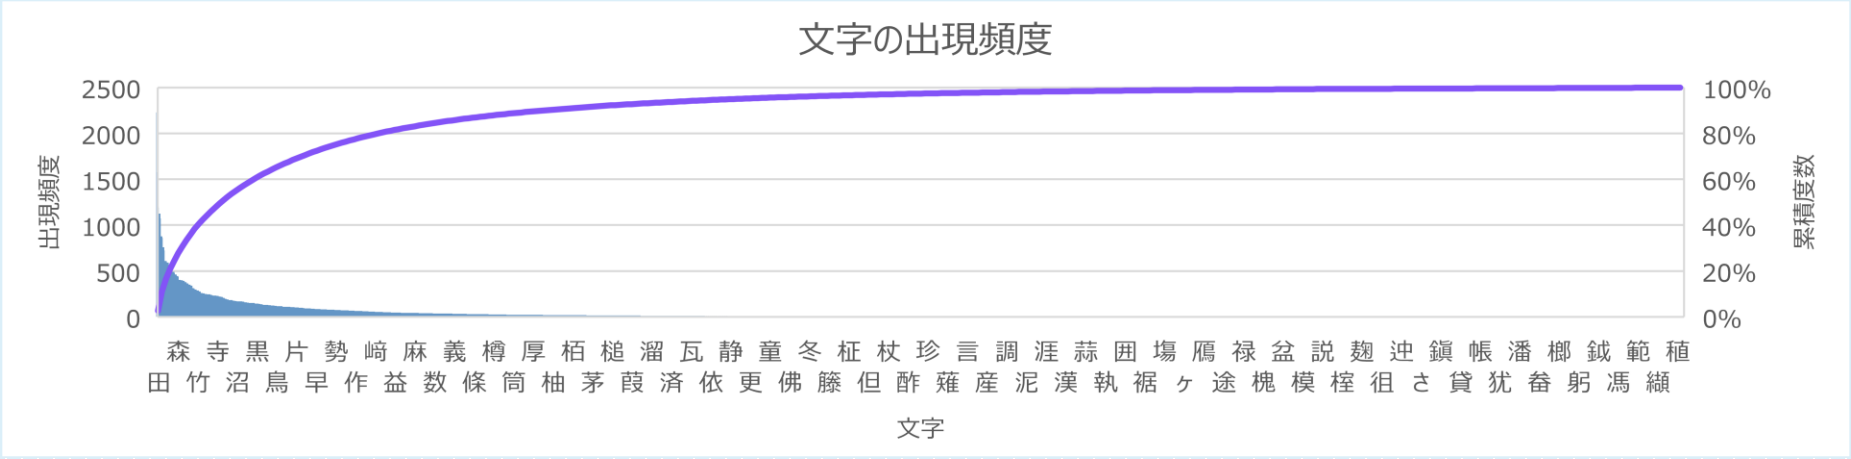


**出現頻度に偏りがあって、ロングテイルな分布になっていることが分かった**

# 背景と課題-AI-OCRの精度について



## 精度の定義

- 読み取り精度：
  テスト対象の文字を1 文字ずつ評価して、正しく読み取れた文字の割合
  AI商社の営業が示した読み取り精度＝使用頻度80%までの文字の読み取り精度

- 利用時精度：
  すべての文字を対象として、正しく読みとれた文字に対して出現頻度で重みづけを行い、計算した割合

読み取り精度 $p_t$ 、利用時精度 $P$ は以下のように記述することができる

$$p_t = \frac{1}{n_t} \sum_{i \in \mathrm{char}_t} r_i$$

$$P = \frac{1}{N} \sum_{i} r_i \times f(i)$$

$n_t$：評価対象の文字数

$\mathrm{char}_t$：評価対象の文字の集合

$r_i$：文字 $i$ の読み取り結果

（正しく読み取れたら $r_i = 1$, それ以外は $r_i = 0$）

$N$：全文字数

$f(i)$：文字 $i$ の使用頻度

# 背景と課題-読み取り精度とリスク回避性



## AI商社から提案された4つのモデルに対して、提示された読み取り精度と追加で評価を実施した

■ AI商社から提示された読み取り精度と利用時精度の比較

| モデル | 読み取り精度（80%） | 利用時精度 | 差 |
|---|---|---|---|
| A | 0.861 | 0.859 | +0.002 |
| B | 0.598 | 0.624 | -0.026 |
| C | 0.645 | 0.652 | -0.007 |
| D | 0.960 | 0.752 | **+0.208** |

**読み取り精度と利用時精度に大きい差が生じることがある**

■ 名字で使われる全2245文字を評価した結果

| モデル | 読み取り精度（100%） | リスク |
|---|---|---|
| A | 0.587 | 中 |
| B | 0.486 | 中 |
| C | 0.221 | **大** |
| D | 0.138 | **大** |

**読み取れない文字が多い＝リスク高**

**テスト設計に、読み取り精度とリスク回避性の考慮が必要・・・課題①**

# 背景と課題-AI-OCRのテストデータについて



**評価対象の文字数が多いと、テストデータの作成にかかるコストが膨大になる**

テストデータの数 ＝ 文字数 × フォントの数 × 文字の大きさ × 外乱 × …

日本語の場合
60,000字

- 漢字の出現頻度調査
  多数の文字は、ほとんど使われない文字である
- テストへの影響
  漢字の使用頻度が利用時精度へ影響する
- データ作成
  AI-OCRのテストデータは任意の文字・装飾・外乱等のデータに対して作成可能である

**文字数を削減することでテストデータを効率よく作成することが必要・・・課題②**

# 課題解決に向けたアプローチ

# 課題解決に向けたアプローチ-提案手法



## 提案手法は、「出現頻度を考慮し、テストに使用する文字を取捨選択するテスト手法」

**特徴**
ロングテイルなデータセットに対して、閾値ｔを決めて「メジャー文字」「マイナー文字」の2つのサブグループに分割する
テストデータは、「メジャー文字」は全ての文字を用いて、「マイナー文字」の一部を削除することで作成する
※ｔの範囲は、0≦ｔ≦100

**考え方**
- 出現頻度の高い文字（メジャー文字）は、利用時精度への影響が大きいので、全て文字をテストに使用する
- 出現頻度の低い文字（マイナー文字）は、利用時精度への影響が小さいので、テストに使用する文字を削減する

### 提案手法の手順

1. ロングテイルなデータセットを用意する
2. 累積度数の閾値ｔを決める
3. 出現頻度上位t%をメジャー文字、出現頻度下位100-t%をマイナー文字としての2つのサブグループに分割する
4. メジャー文字：マイナー文字＝t：100-tになるようにマイナー文字を削除する

# 課題解決に向けたアプローチ-提案手法のフロー1/2



## 閾値 t を用いて、メジャー文字とマイナー文字を2つのサブグループに分割する

1. ロングテイルなデータセットを用意する
2. 累積度数の閾値 t を決める
3. 出現頻度上位t%をメジャー文字、出現頻度下位100-t%をマイナー文字としての2つのサブグループに分割する
4. メジャー文字：マイナー文字＝t：100-t になるようにマイナー文字を削除する

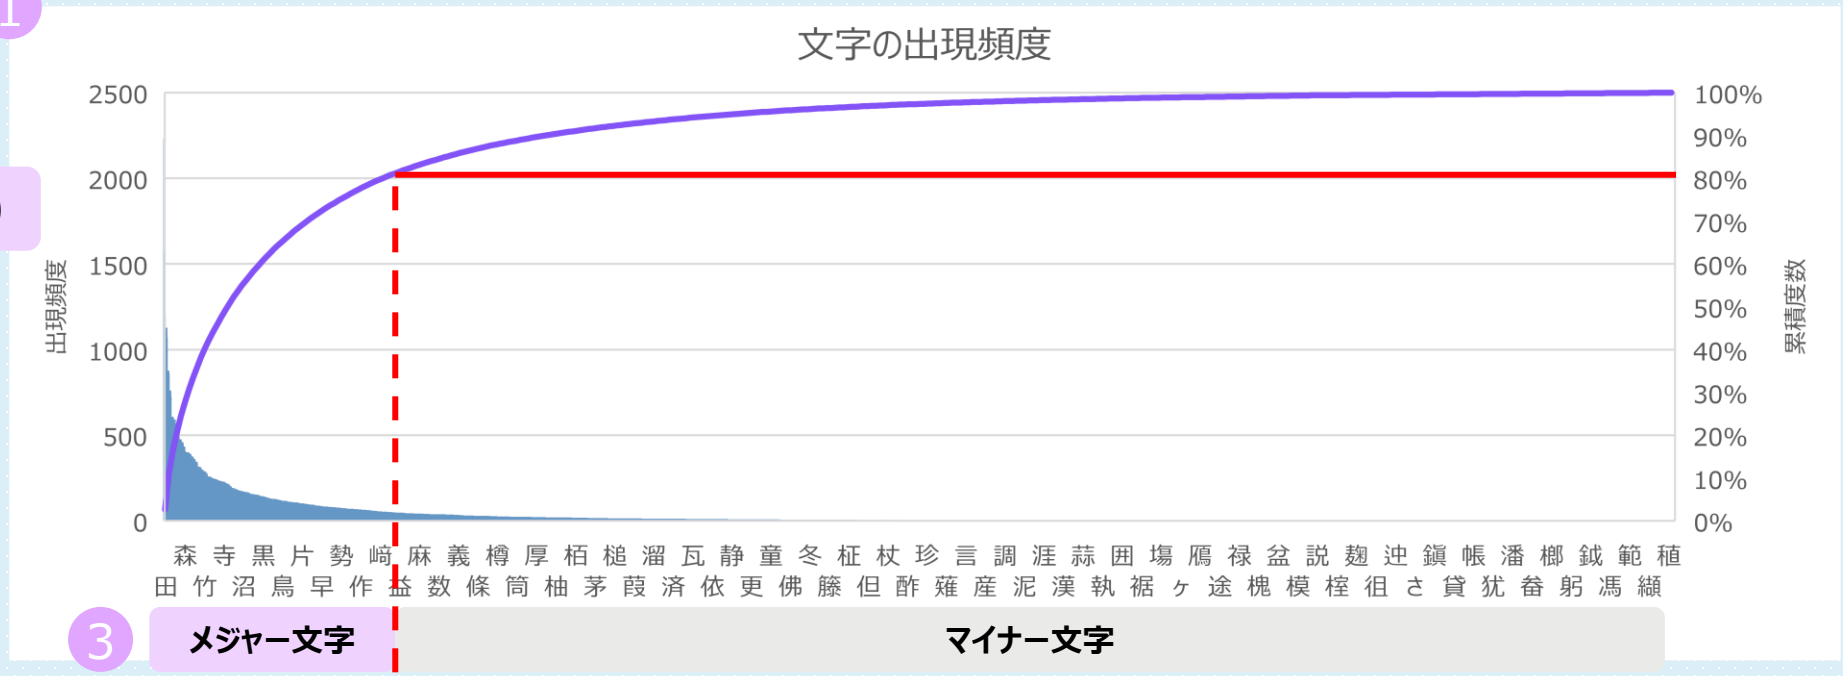

# 課題解決に向けたアプローチ-提案手法のフロー2/2



## マイナーな文字をランダムに削減して、テストデータにおけるメジャー文字の数の比を閾値 t と一致させる

1. ロングテイルなデータセットを用意する
2. 累積度数の閾値 t を決める
3. 出現頻度上位t%をメジャー文字、出現頻度下位100-t%をマイナー文字としての2つのサブグループに分割する
4. メジャー文字：マイナー文字＝t：100-t になるようにマイナー文字を削除する

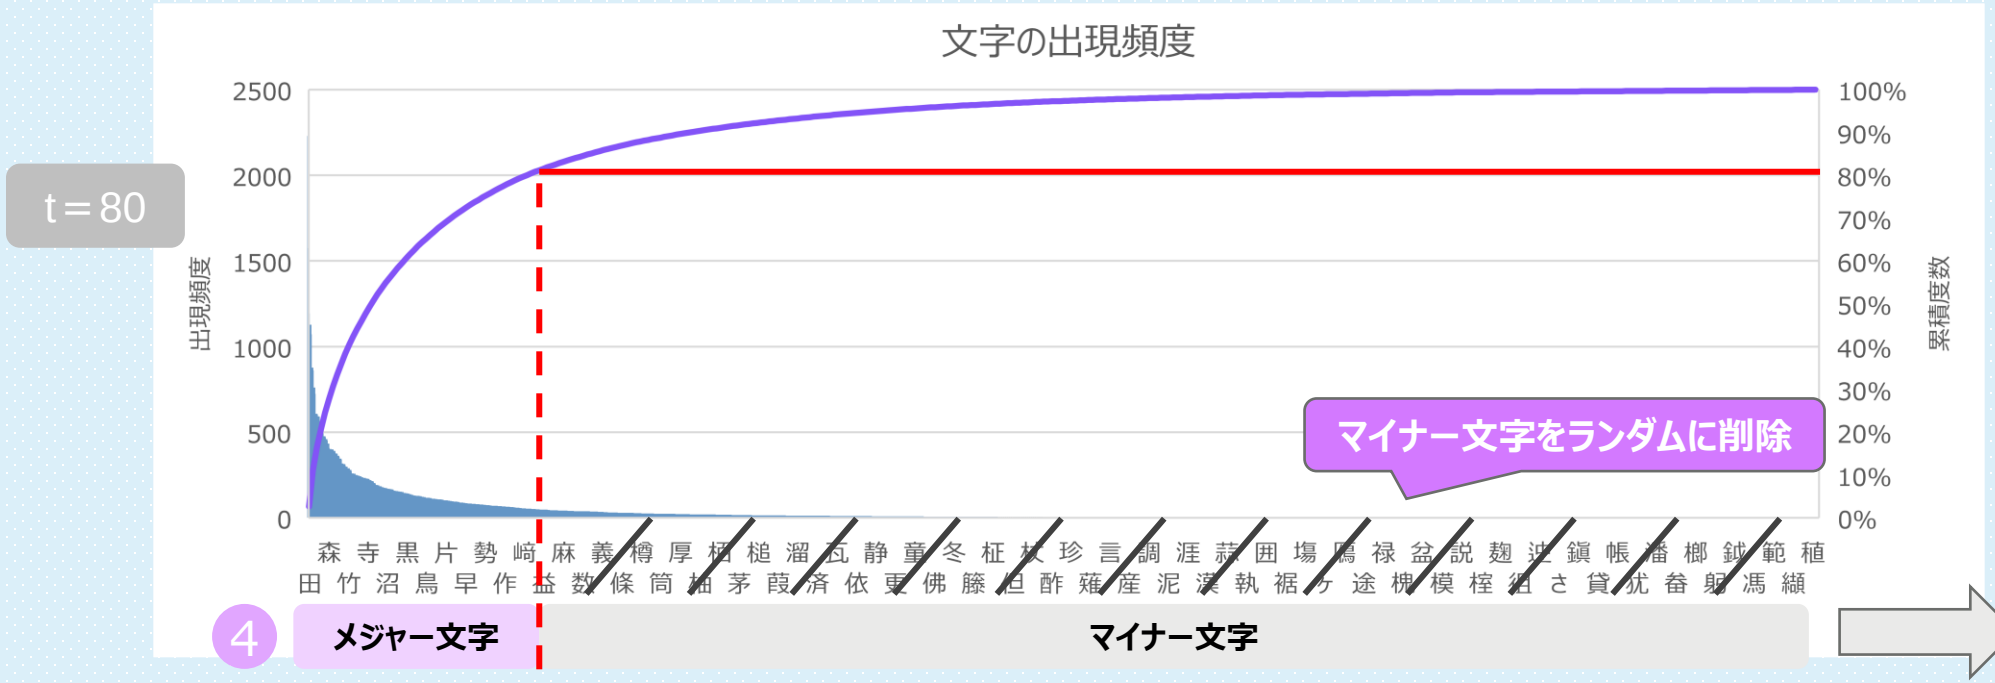


テストデータで使用する文字

| メジャー文字 | マイナー文字 |
| --- | --- |
| 80% | 20% |

# 実験

# 実験-提案手法の有効性の確認



- **提案手法の有効性を確認するために、下記2点を検証する**

**検証①：モデル間の読み取り精度について**

1. 提案手法で評価したモデルの読み取り精度の順位を確認する
   利用時精度とリスク回避性が最も優れているモデルが1位になることを確認する
2. 読み取り精度とリスク回避性を総合的に評価していること

**検証②：文字の削減量について**

1. 全体の文字に対する削除したマイナー文字が占める割合を確認する

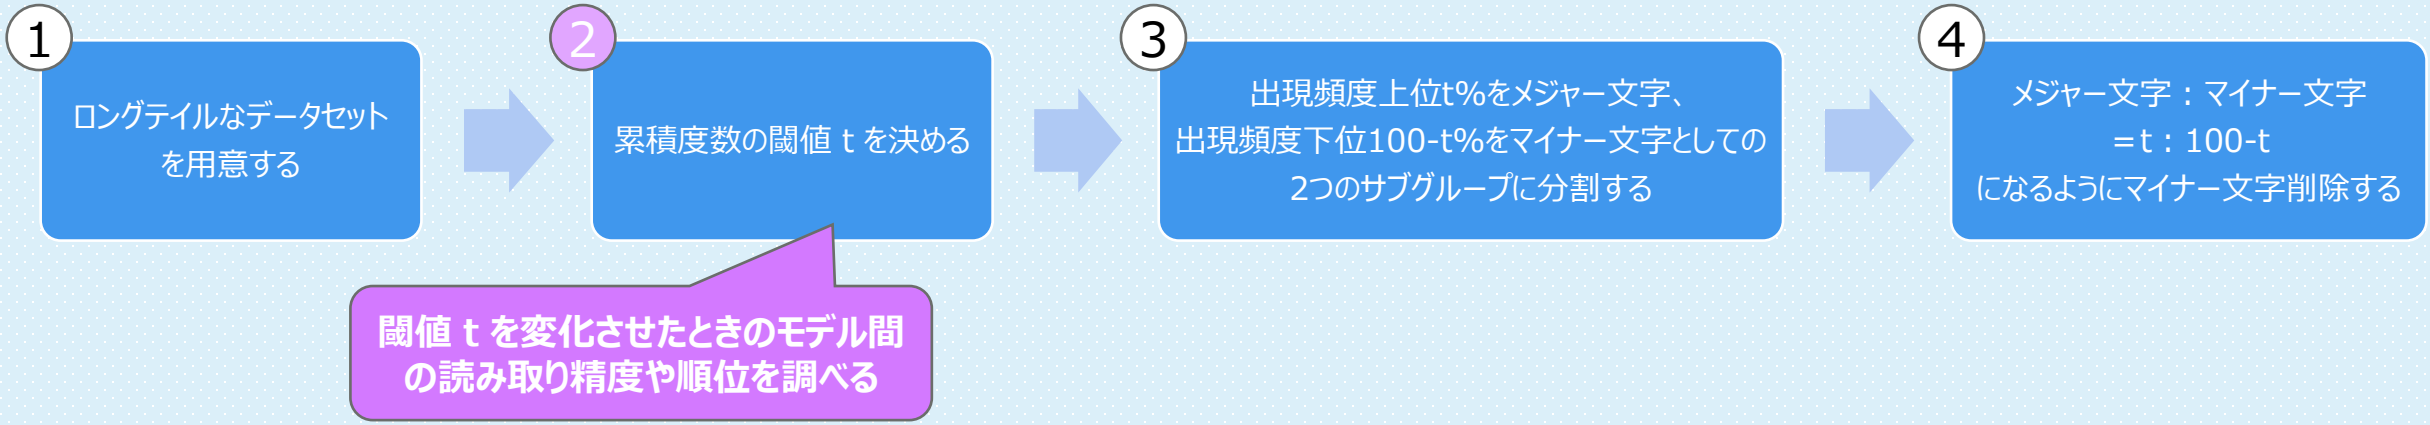

# 実験前準備-閾値tの有効範囲について



## ■ 実験の前準備

### ■ 閾値 t とテストデータ数の確認

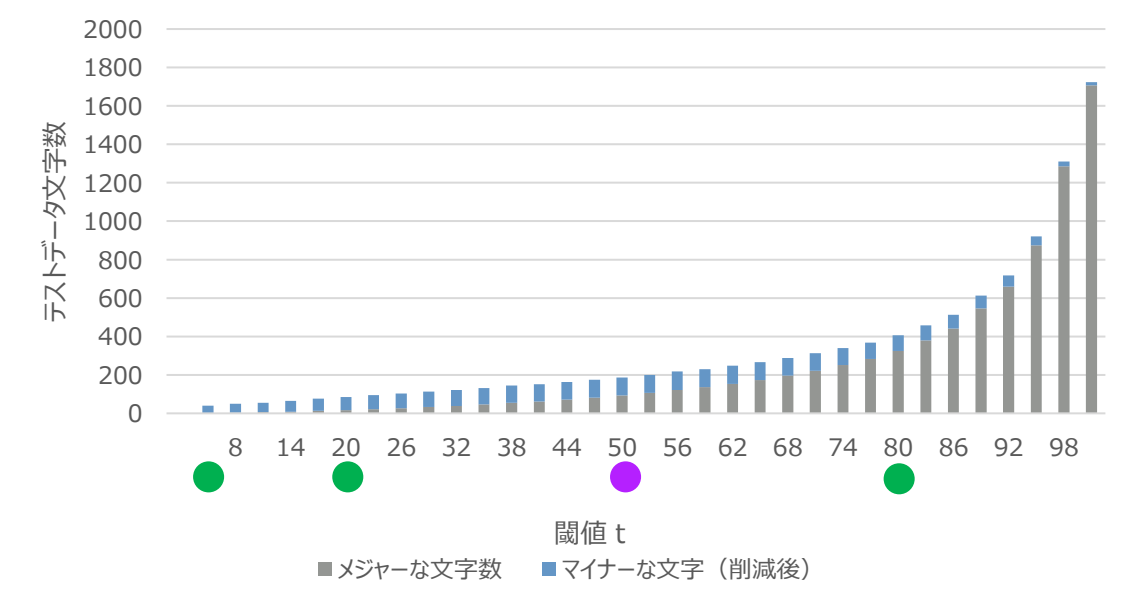


| 閾値 t | メジャー文字 | | マイナー文字（削除後） |
|---|---|---|---|
| 0 | 0 | < | 0 |
| 20 | 17 | < | 68 |
| 50 | 93 | = | 93 |
| 80 | 325 | > | 81 |
| 100 | 2245 | > | 0 |

**閾値 t について**

- 閾値50を境に、メジャー文字＞マイナー文字となる
- 全てのモデルが学習している文字が含まれている範囲が80%までである

**評価が有効である範囲を「50 ≦ t ≦ 80」として確認していく**

# 実験-検証①モデル間の読み取り精度について



**提案手法における閾値tの有効範囲(50-80)において、読み取り精度が高いモデルAとDを比較した結果、読み取り精度がモデルA＞モデルDであることが分かった**

## 各モデルの読み取り精度

| モデル | 読み取り精度 (t=80) |
|---|---|
| A | 0.796 |
| B | 0.571 |
| C | 0.545 |
| D | 0.764 |

## 閾値 t に対する読み取り精度

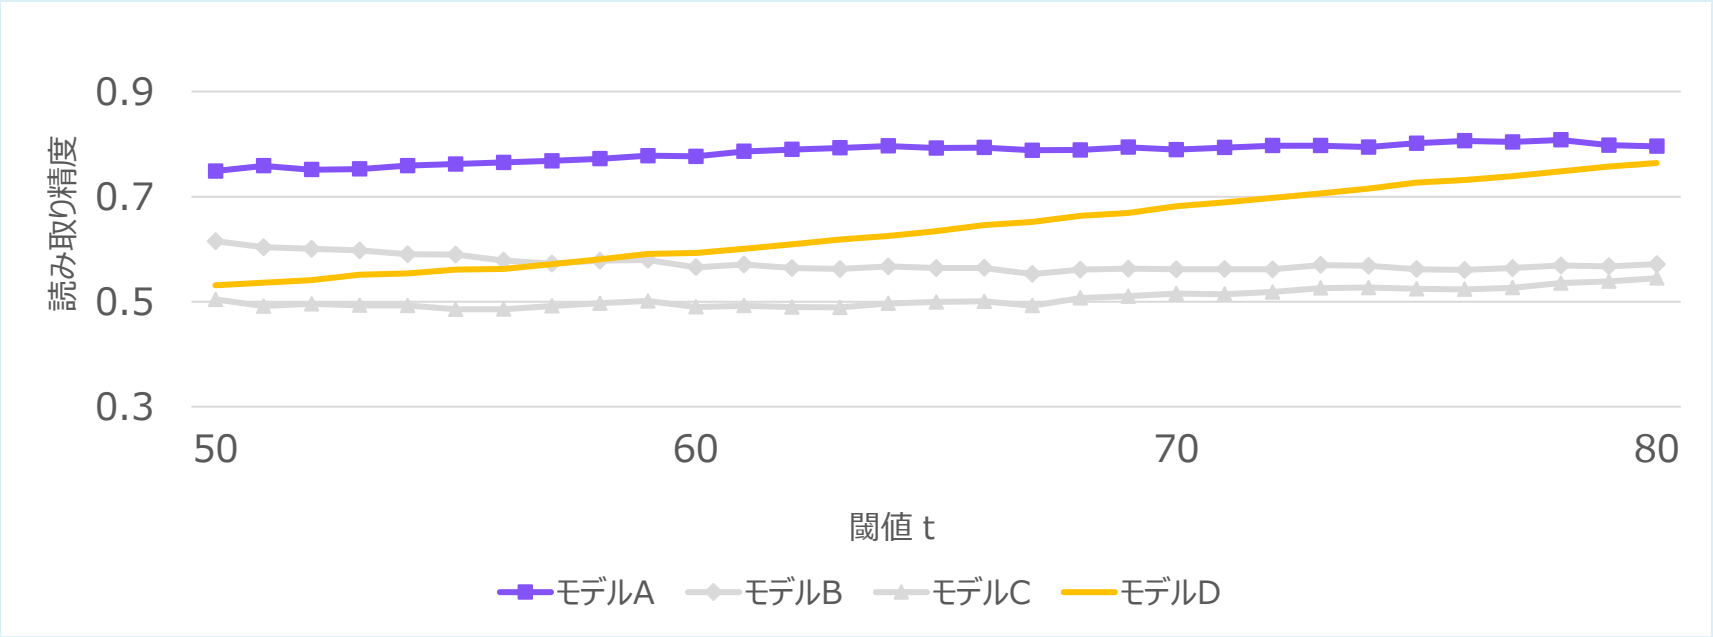

# 実験-検証①モデル間の読み取り精度について



## モデルAとモデルDにおける利用時精度とリスク回避性の比較

## 利用時精度、リスク回避性ともモデルAのほうが高い

### 各モデルの読み取り精度

| モデル | 読み取り精度 (t=80) |
|---|---|
| A | 0.796 大 |
| B | 0.571 |
| C | 0.545 |
| D | 0.764 小 |

### 利用時精度とリスク回避性

| モデル | 利用時精度 | 読み取り精度 (t=100) |
|---|---|---|
| A | 0.859 大 | 0.587 大 |
| B | 0.624 | 0.486 |
| C | 0.652 | 0.221 |
| D | 0.752 小 | 0.138 小 |

**検証①-1「利用時精度とリスク回避性が最も優れているモデルが1位になることを確認する」への結果**

✓ モデルAが最も良いモデルといえているので「利用時精度とリスク回避性が最も高いモデル」を「最も読み取り精度が高いモデル」として評価することができた

# 実験-検証①モデル間の読み取り精度について



**提案手法における閾値tの有効範囲(50-80)において、読み取り精度が低いモデルBとCを比較した結果、読み取り精度がモデルB＞モデルCであることが分かった**

## 各モデルの読み取り精度

| モデル | 読み取り精度 (t=80) |
|---|---|
| A | 0.796 |
| **B** | **0.571** |
| **C** | **0.545** |
| D | 0.764 |

## 閾値 t に対する読み取り精度

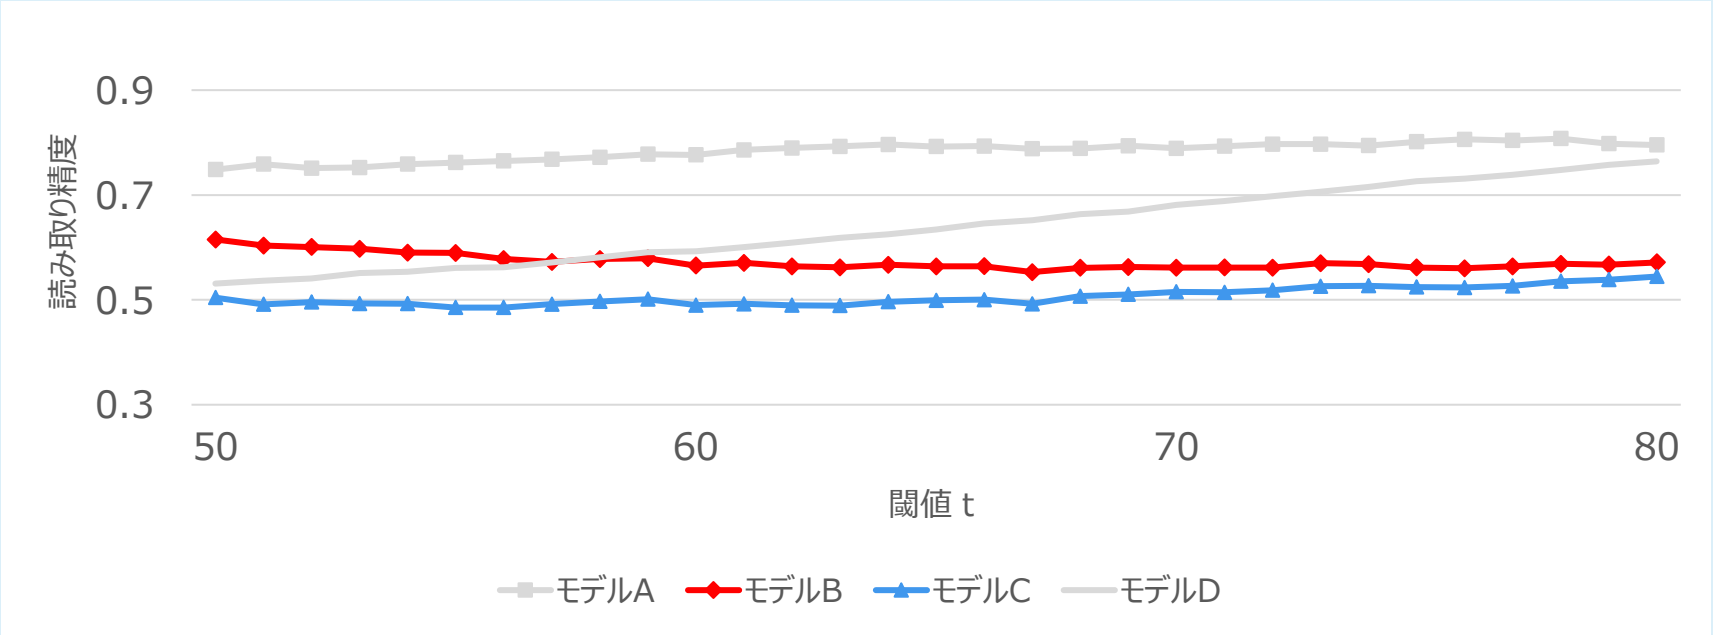

# 実験-検証①モデル間の読み取り精度について



**モデルBとモデルCにおける利用時精度とリスク回避性の比較**

**利用時精度はモデルCのほうが少し高いが、リスク回避性はモデルBのほうが圧倒的に高い**

**各モデルの読み取り精度**

| モデル | 読み取り精度 (t=80) |
|---|---|
| A | 0.796 |
| B | 0.571 大 |
| C | 0.545 小 |
| D | 0.764 |

**利用時精度とリスク回避性**

| モデル | 利用時精度 | 読み取り精度 (t=100) |
|---|---|---|
| A | 0.859 | 0.587 |
| B | 0.624 小 | 0.486 大 |
| C | 0.652 大 | 0.221 小 |
| D | 0.752 | 0.138 |

**検証①－2「読み取り精度とリスク回避性を総合的に評価していること」**

✓ モデルBとモデルCに対して、提案手法を用いることでリスク回避性を考慮することができた

# 実験-検証②文字の削減量について



## ■ 提案手法を用いた実験の結果

### ◆ テストデータの削減量

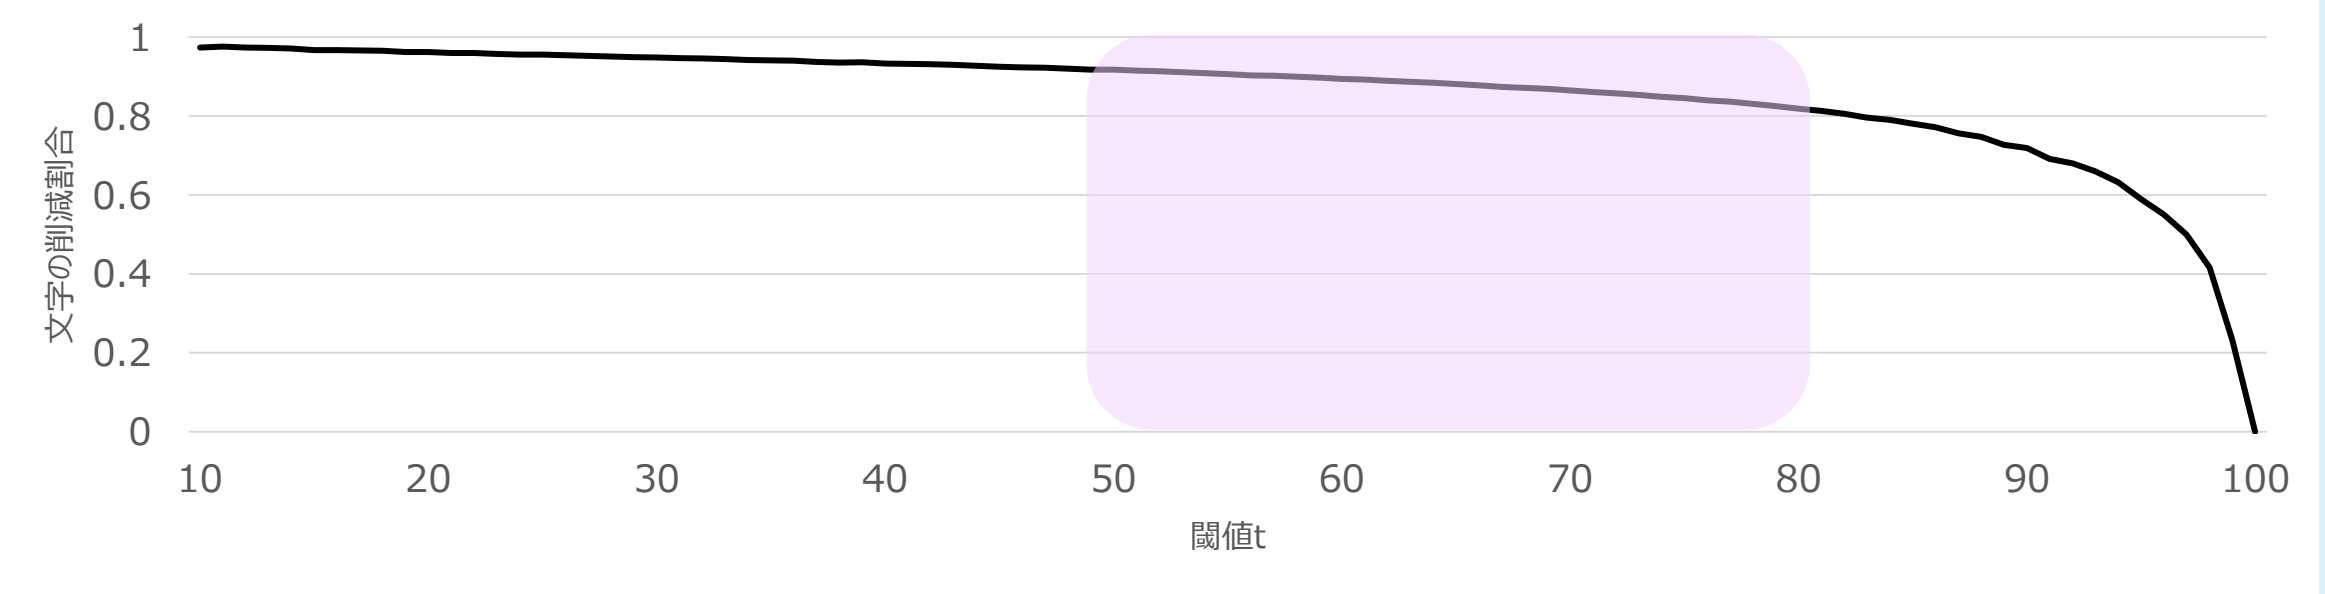


有効範囲である50%～80%の範囲では8割以上の文字削減を確認

**検証②－1「全体の文字に対する削除したマイナーな文字が占める割合を確認する」**

✓ 提案手法を用いるとテストデータの大幅削減が可能である

# 考察

# 考察



## ■ 考察１ 提案手法の利点

### ◆ 考察1-1 メジャー文字のみを評価することに対する考察

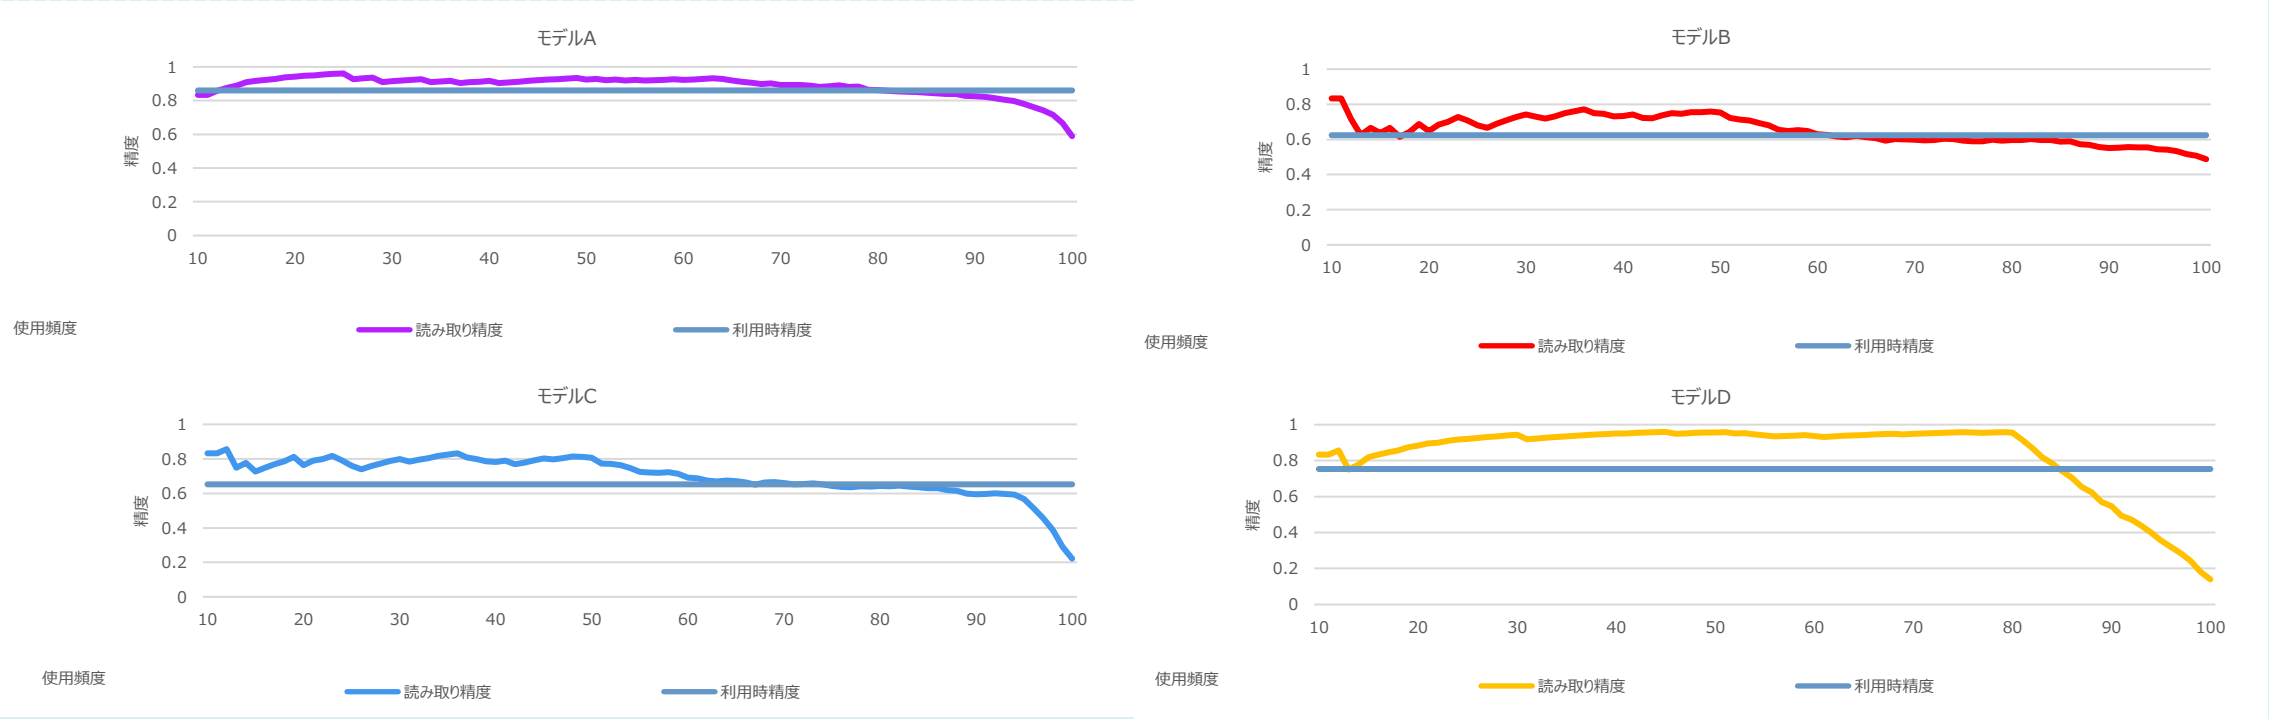


モデルA、B、Cは60%から80%の範囲で利用時精度と読み取り精度の値が近い
一方，全体の14%の文字しか学習していないモデルDは大きな乖離が見られた

**メジャー文字のみに特化させて学習させたモデルでは、読めないことに対する精度低下が無視できないほど大きい**

# 考察



## ■ 考察１ 提案手法の利点

### ◆ 考察1-2 マイナーを付加することによる効果

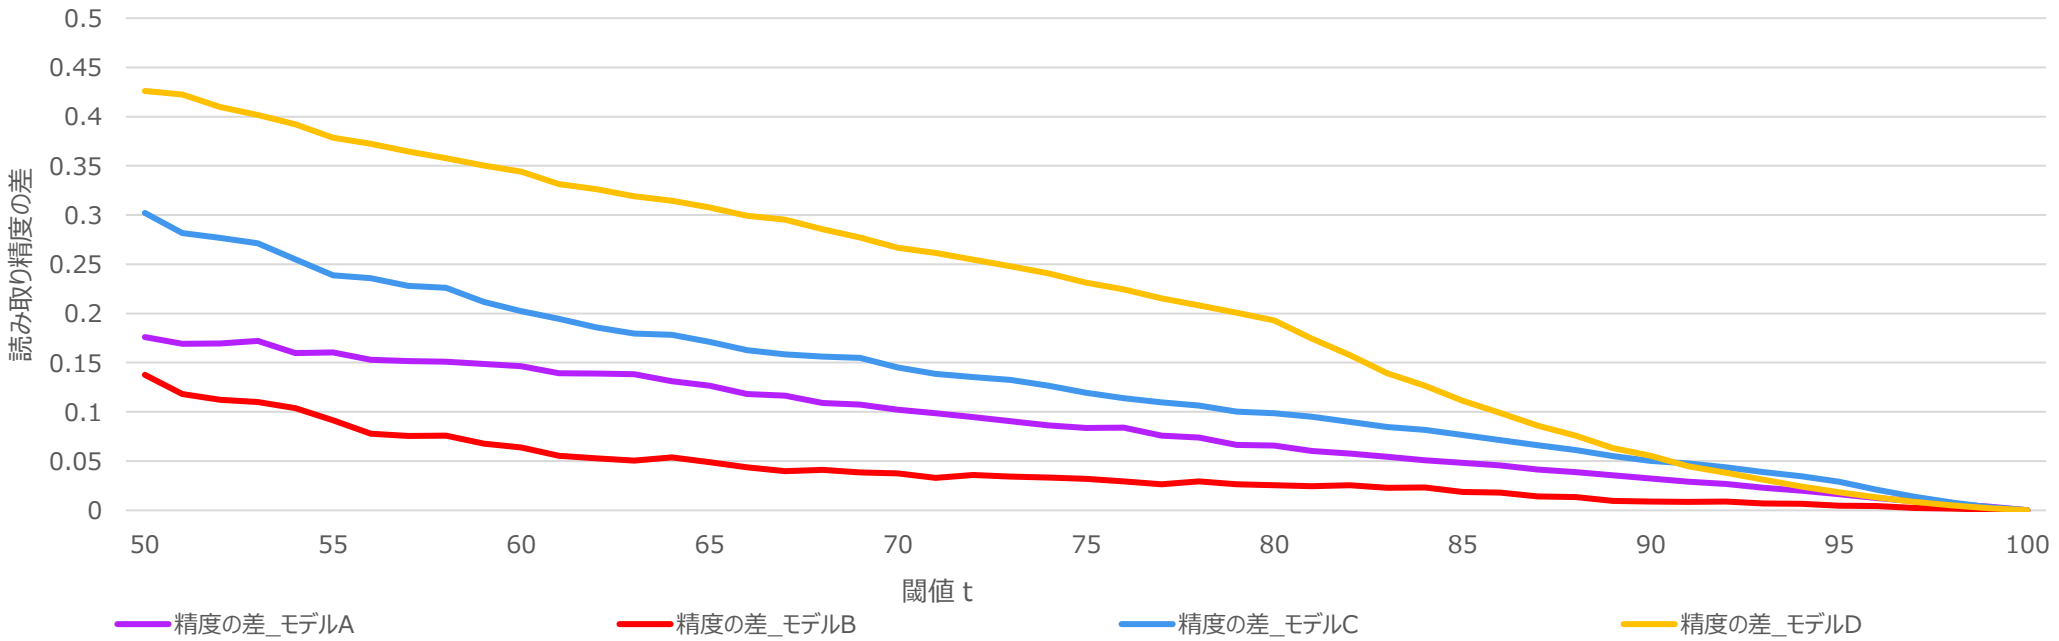


マイナー文字を付加することで、学習の機会が少ない文字を評価に使うことができ、
評価にリスクの観点を含める役割を担っている

**読めない文字を付与することで、評価にリスクの観点を付与できている**

# 考察



## ■ 考察2 提案手法におけるランダム評価の安定性/信頼性

### ◆ 考察2-1 モデル間順位の安定性

ランダムに100回のテストデータ生成を実施したときの、各テストデータにおけるモデルの順位の平均（閾値80まで）

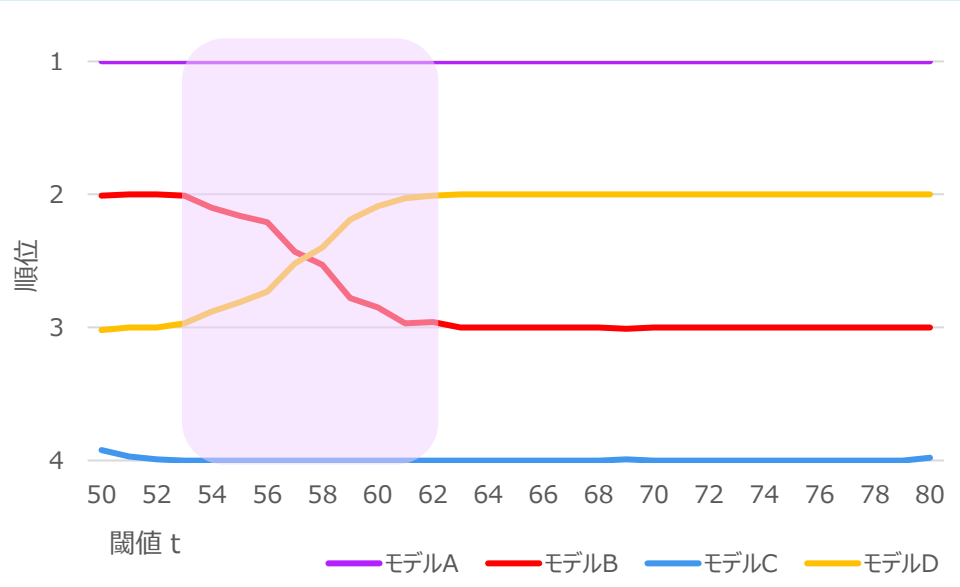


- 順位が安定しているほど、平均値と最頻値は一致する
  平均値が最頻値からずれるほど正しく評価されない確率が上がる
- **ほとんどの範囲で順位は安定している**
  **⇒ランダム評価1回で十分であるといえる**
- 2つのモデルがほぼ同率・近い精度の場合は、
  順位が入れ替わるので評価は安定しない（閾値57付近）
- 安定しない点は事前にわからないため、複数の閾値で評価するとよい

**提案手法は1回テストデータの作成で十分に評価可能**
**複数の閾値で評価することで、より正確な評価が可能になる**

# 今後の展望

# 今後の展望



## 今後の展望１：AI-OCR 以外の機械学習システムに対する提案手法の適用

インプットとなるデータがロングテイルな分布になっていることは、AI-OCR 以外にも広くみられる以下について検証する必要がある

- AI-OCR 以外の分野で用いられる機械学習システムに対する有効性

例
- 総合ECサイトリコメンドシステム
  →「商品」と「売上」
- SEO対策
  →「言葉」と「アクセス数」

など

## 今後の展望２：テスト対象の文字における制約の解除

今回は文字以外の要素を排除したが、実際のAI-OCR では、「フォント」や「文字の大きさ」「紙質」「外乱」などが読み取り精度に影響する
手書き文字についても、丁寧さや癖字などが読み取り精度に影響するため、これらの条件も含めて、提案手法による評価が有効であるかを検証する

例
- 活字文字への外乱


- 手書き文字

D社モデルの性能は悪かったのだ
A社モデルが一番良かったのだ

ご清聴ありがとうなのだ！