


AIで読む『小説家になろう』： Transformerによる物語ジャンル の可視化と分類

大阪大学人文学研究科
言語文化専攻助教
黄 晨雯



Transformerの位置付け



線形回帰
ロジックスティック回帰
サポートベクトルマシン
階層クラスタリング
トピックモデル等

ニューラルネットワーク

RNN、LSTM、CNN
Transformer
(2017年に論文『Attention is All You Need』
にて発表されたアーキテクチャ)



Transformerができること

- テキスト生成
- テキスト分類
- 固有表現抽出
- 文章要約
- 質問応答
- 音声処理
- その他

オンライン小説のあらすじを入力文とし、モデルを微調整する。
→ 文体や内容の傾向に基づいたジャンル分類の可能性を探る。



分析対象（メタ情報）

- 『小説家になろう』：<https://yomou.syosetu.com/search.php>

何かの物語のはずだけどタイトルがわかりません

作者：兎乃マロン／小説情報／Nコード：N7317HA

連載中
(全44部分)

(本編43話完結済) 中肉中背、経済的状況普通、知能普通、運動特に可もなく不可もない。特技、どこにいるかわからないよう紛れる事。普通令嬢だけど転生者。タイトルもわからないけど何か感じます、乙女ゲーム、ラノベ、何でしょう？セカンドシーズンですか？私って必要ですか？非日常ぽいので傍観者としてワクワクします。対策って必要？結局美味しいところを持っていきます(番外編追加しました)

ジャンル：異世界（恋愛）

キーワード：R15 異世界転生 乙女ゲーム 悪役令嬢 ほのぼの 女主人公 学園 バッドエンド

ハッピーエンド 普通令嬢 モブ がうがうコン1

最終更新日：2021/07/02 05:41 読了時間：約130分 (64,926文字)

週別ユニークユーザ：1,830人 レビュー数：0件 **PC投稿**

総合ポイント：762 pt

ブックマーク：155件 評価人数：55人 評価ポイント：452 pt

分析対象（メタ情報）

- なろうAPI（デベロッパー向け）

<https://dev.syosetu.com/man/api/>

Pythonスクリプトでスクレイピング

```
title: デビルエンジェルAYA
ncode: N7449HE
userid: 738795
writer: ハ上 みつか
story: 1
    関東某県の山中にある新興都市。
    そこは企業が『JOY使い』という能力者を秘密裏に開発するための施設だった。
    営業は普通の学園都市であるが、夜は制限を解かれた能力者たちが争い合う危険な街へと変貌する。
    何も知らずに高校からこの街で一人暮らしを始めた主人公、星野空人。
    彼は同じ新入生でありながら最強クラスのJOY能力を持ちヒーローに憧れる少女、赤坂綺と出会い一目惚れをする。
    それぞれ特徴のある三つの学園、夜間に勢力争いをする少年能力者グループ、そして街を支配する企業の間。
    さまざまな陰謀渦巻く街で、空人は時に争いに巻き込まれながらも、綺に並び立つ男になるため日夜奮闘していく。
biggenre: 2
genre: 202
gensaku:
keyword: >
    R15 残酷な描写あり 青春
    異能力バトル 学園 現代
    男主入公 群像劇 超能力
general_firstup: 2021-09-07 00:00:00
general_lastup: 2021-09-22 02:00:00
novel_type: 1
end: T
general_all_no: 138
length: 795817
time: 1592
issstop: 0
isr15: 1
isbn: 0
isgl: 0
iszankoku: 1
istensei: 0
istenni: 0
pc_or_jk: 2
global_point: 30
daily_point: 12
weekly_point: 4
monthly_point: 18
quarter_point: 18
yearly_point: 18
fav_novel_cnt: 5
impression_cnt: 1
review_cnt: 0
all_point: 20
all_hyoka_cnt: 2
sasie_cnt: 0
kaiwaritu: 29
novelupdated_at: 2021-09-22 02:00:01
updated_at: 2021-09-22 02:02:04
```

分析対象（メタ情報）

- メタデータコーパス構築

	title	writer	story	Group	Genre	Year	global_point
0	【WEB版】うちの弟子がいつのまにか人類最強になっていて、なんの才能もない師匠の俺が、それを...	アキライズン	「貴方様が剣聖アリス様のお師匠様、大剣聖タクミ様で御座いますね」「え、いや、人違ひじゃないか...」	文芸	コメディー（文芸）	2019	29464
1	水属性の魔法使い	久宝 忠	【好きラノ2021年上期 新作部門第2位！】書籍版第二巻「水属性の魔法使い 第一部 中央諸国...」	ファンタジー	ハイファンタジー（ファンタジー）	2020	256230
2	【三章開始！】創成魔法の再現者～『魔法が使えない』と実家を追放された天才少年、魔女の弟子と...	みわもひ	「貴様は出来損ないだ、二度と我が家の敷居を跨ぐなあ！」魔法が全ての国、とりわけ貴族だけが生ま...	ファンタジー	ハイファンタジー（ファンタジー）	2021	162034
3	【アイテム無消費】だけが売りの俺。ダンジョン最下層へと追放される～だがそこで手に入れたアイテ...	まんじ	「くそっ！くそっ！くそくそくそ！」地面に跪き、怨嗟の声を上げる若者の名は——セドリ。【アイテ...	ファンタジー	ハイファンタジー（ファンタジー）	2021	39846
4	【9月書籍・コミカライズ発売！】植物魔法チートでのんびり領主生活始めます～前世の知識を駆使し...	りょうとかえ	9月書籍第3巻、コミカライズ第2巻発売！ページ下部のバナーから公式サイトへと移動できます。貴...	ファンタジー	ハイファンタジー（ファンタジー）	2019	169186

モデルの訓練（教師あり）

- 教師あり学習

入力文：

非常に良いお店
ですね。

Embedding size

非常	0.01 0.02 … 0.15
に	0.02 0.42 … 0.35
良い	0.11 0.05 … 0.21
お	0.39 0.03 … 0.65
店	0.61 0.49 … 0.84
で	0.47 0.12 … 0.79
す	0.51 0.23 … 0.46
ね	0.43 0.02 … 0.13
。	

Hidden Layer

0.99

Positive

0.01

Negative

モデルの訓練（教師あり）

- 正解ラベル：Genre列のジャンル
- 訓練データ：あらすじ（80%）
- テストデータ：あらすじ（20%）
- 事前学習済モデル：
tohoku-nlp/bert-base-japanese-v3

ジャンル	ラベル
コメディー〔文芸〕	0
ハイファンタジー〔ファンタジー〕	1
ローファンタジー〔ファンタジー〕	2
現実世界〔恋愛〕	3
アクション〔文芸〕	4
異世界〔恋愛〕	5
VRゲーム〔SF〕	6
空想科学〔SF〕	7
ヒューマンドラマ〔文芸〕	8
歴史〔文芸〕	9
宇宙〔SF〕	10
パニック〔SF〕	11
純文学〔文芸〕	12
ノンジャンル〔ノンジャンル〕	13
推理〔文芸〕	14
ホラー〔文芸〕	15

モデルの評価

- テストデータを用いたモデルの評価結果


	指標	スコア
評価損失（誤差）	eval_loss	0.87029701
評価用モデル準備時間	eval_model_preparation_time	0.008
正解率	eval_accuracy	0.77530864
精度と再現率の調和平均	eval_f1	0.74625348
評価にかかった時間	eval_runtime	41.9998
評価サンプル数/秒	eval_samples_per_second	28.929
評価ステップ数/秒	eval_steps_per_second	1.81

混同行列の可視化



- 分類問題における予測結果の評価を行うために使用される行列

True Label: 正解ラベル

Predicted Label: 予測ラベル




あらすじ間の関係性可視化




あらすじ間の関係性可視化

Sentence Embeddings Visualization with PCA



あらすじ間の関係性可視化

Sentence Embeddings Visualization with PCA



ご清聴ありがとうございました。