

ソーシャルメディアを用いた 一般用医薬品のファーマコビジランス

西山智弘¹ 矢田竣太郎¹ 若宮翔子¹ 堀里子² 荒牧英治¹

¹ 奈良先端科学技術大学院大学 ² 慶應義塾大学

¹{nishiyama.tomohiro.ns5,s-yada,wakamiya,aramaki}@is.naist.jp

²hori-st@pha.keio.ac.jp

概要

近年、OTC 医薬品の誤用・乱用が増加しており、社会問題となっているが、自由に購入できる OTC 医薬品の乱用状況を把握することは難しい。そこで、我々はユーザが日常を投稿することが盛んに行われるソーシャルメディアを用いることで、OTC 医薬品の誤用乱用を把握できると考え、OTC 医薬品の使用状況に関してラベル付けを行ったコーパスを構築した。用いたコーパスに含まれる医薬品名をマスクしたテキストを用いて学習させたモデルで分類精度を確認したところ、医薬品名が含まれるものと同程度の精度で分類できることがわかった。

1 はじめに

近年、高齢化による医療費の増大が社会問題となっている。この解決策の一つとして、薬局で購入することのできる over-the-counter 医薬品（以降、OTC 医薬品とする）が推奨されている。しかし、これらの医薬品は手軽に手に入られることから同時にその乱用が増加している。こうした乱用事例は特に若い世代に多く、OTC 医薬品のインターネット売上の普及で消費者がより簡便に OTC 医薬品を購入できるようになった影響等が考えられる [1]。2021 年 12 月には薬物乱用に関するソーシャルメディア上のコミュニティを通じて知り合ったグループで OTC 医薬品の乱用による死亡事故も起きており、これらの医薬品が不適切に扱われることは社会上の問題である [2]。

そのような状況下ではあるが、OTC 医薬品の乱用の現状などを把握する手法は乏しく、その方法としてはアンケートや医療機関への受診などに限られる [3]。こうした手法では、情報の収集に時間やコストがかかり、非効率であるだけでなく、依存症な



図 1 医薬品誤用乱用関連のツイートの抽出

どの問題が発生した後でしか、その事象を捉えることができないため、より簡便に迅速に OTC 医薬品の使用状況を捉える手法が求められている。

特に医薬品の乱用を含めた誤用などの医薬品の使用状況を迅速に取得することができれば、当局自身が医療政策、製薬会社が乱用問題への対策をより効果的に打ち出せる可能性がある。これらを可能とする情報リソースとしてソーシャルメディアが挙げられる。中でも、Twitter は日本国内では LINE、YouTube について多くのユーザを有しており [4]、匿名発信による手軽さから、ユーザが日常を投稿することが盛んに行われており、ユーザ自身による医薬品使用状況に関する投稿も多い。著者らはこの情報を医薬品安全性監視といったレギュラトリーサイエンスに役立てると考えており、既に誤用乱用などを含めた服薬コンプライアンスに関するコーパスの構築に取り組んでいる [5]。しかし、OTC 医薬品に向けたテキストの分類体系は存在していない。

そこで、本研究では OTC 医薬品のための誤用乱

用に関するテキスト分類体系を提案し、その自動分類を実施する。

2 関連研究

ソーシャルメディアを用いて、医薬品の使用状況を捉える研究は盛んに行われており、患者の薬物乱用や服薬コンプライアンスを検出する試みがなされている [6–14]。Abdellaoui らは、エシタロプラムとアリピプラゾールという 2 つの薬物について、トピックモデルを用いたツイート分類を行った [13]。Weinssenbacher らは、コンプライアンス違反を検出するために医薬品投与に関する変更イベントを分類する方法を提案した [6]。また、著者らはこれまで服薬コンプライアンス違反に関するテキストの自動分類の精度を検証している [5]。しかしながら、この研究での服薬コンプライアンス違反の分類精度は 59.7 と低く、改善の余地があると考えられた。この研究において、服薬コンプライアンスの中でも、細かい分類が分類精度の向上に寄与することが示唆されたことから、本研究ではラベルに大分類と細分類を設けることで、精度向上を試みた。

3 データセット

我々は“MediA OTC section”という OTC 用の医薬品コーパスを構築した。本コーパスは「ブロン」、「パブロン」、「ウット」、「イブ」、「ナロン」、「レスタミン」、「ルル」、「トニン」、「コンタック」、「ドリエル」、「ベンザブロック」、「アネトン」、「エスタロンモカ」からなる 14 種類の医薬品クエリで取得されたツイートについて、誤用乱用に関するラベルが付与された全 22036 件のデータである。14 種類のクエリは薬剤師資格保有者によって、2020 年の全国の精神科医療施設における薬物関連精神疾患の実態調査に登場する OTC 医薬品の商品名を含むものを全て選択した [15]。

3.1 前処理

2021 年 1 月 1 日から 2021 年 12 月 31 日の期間で twitterAPI を用いて、14 種類の医薬品クエリで収集したツイートに対して、前処理を行なった。「イブ」、「ルル」、「ナロン」の 3 クエリについては、「クリスマス」、「ルルル」、「ナロンちゃん」などの明らかに医薬品に関連しないツイートを多く含んでいたため、これらのクエリについては、上述のようなワードを含むツイートを除外した。

残ったツイートデータに対して、URL、ハッシュタグ、RT の除去処理や重複ツイートの除去を行なった後、テキスト本文が 10 文以上のツイートを各クエリ 1500 件ずつランダムサンプリングした。ただし、ノイズが多く医薬品関連ツイートの割合が少ない「イブ」、「ルル」については 10000 件ずつ行った。このデータセットに対し、各医薬品の医薬品関連ツイートが 500 件に達するまでアノテーションを実施した。

3.2 アノテーション

アノテータはツイートが医薬品に関して書かれたものかどうかを判断する。第 2 段階として、アノテータは医薬品に関して書かれたツイートについて使用 (Use)、誤用乱用 (Misuse)、言及 (Mention) を判断する。最終段階として、誤用乱用 (Misuse) と判断されたツイートについて、細分類を判断する。細分類は、投与量間違い (dosage error)、過少服用 (underuse)、過剰服用 (overuse)、用法に反する (against usage)、精神的効果 (psychotropic effect)、ダイエット (weight loss)、自殺企図 (suicide attempt)、鎮静効果 (sedation)、依存 (addiction)、不適切管理 (stock)、誤認識 (misunderstand)、その他誤用乱用 (other) の 12 種類である。これらの分類は、Bigeard らのソーシャルメディアテキストの解析を参考に作成した [8]。彼らの解析例をもとに、我々は OTC 用のマルチラベルの分類体系を構築した。

また、アノテータは各クエリについて、医薬品関連ツイートが 500 件に達するまでラベル付けを行った。最終的にラベル付けされたのは、全 20036 件のツイートである。

本データセットは二人のアノテータによって行われた。各医薬品クエリについて、アノテータがそれぞれ 100 件ずつ、合計で 1400 件のツイートに関してラベル付けを行い、アノテータ一致度を計算した。各ラベルのカップ係数の平均は 0.891 であり、相当程度一貫しているとみなせる。

4 提案手法

分類モデルには Bidirectional Encoder Representations from Transformers (BERT) [16] を用いた。日本語コーパスで事前学習したモデル¹⁾を採用し、データセットを用いてファインチューニングを行なっ

1) <https://huggingface.co/cl-tohoku/bert-base-japanese-whole-word-masking>




図2 医薬品分類モデルにおける Original と Masked の F1 スコア

た．学習条件として最適化手法は AdamW, 学習率は 1.0×10^{-5} , バッチサイズは 512 であり, バリデーションロスが最小の時点におけるモデルを利用した．

本研究では3種類のモデルを作成した．ツイートが医薬品に関するものかどうかを分類するモデル(医薬品分類モデル), 医薬品に関わるツイートを使用 (Use), 誤用乱用 (Misuse), 言及 (Mention) のいずれかに分類するモデル(誤用乱用大分類モデル), 誤用乱用に関わるツイートが誤用乱用のうち, どの細分類と判断されるかを分類するモデル(誤用乱用細分類モデル)である．

また, 医薬品名がテキスト分類に影響をもたらすことが予想されたため, それぞれのモデルに対して, 訓練データとして該当クエリの医薬品名をマスクしないテキスト (Original) とマスクしたテキスト (Masked) を適用したモデルで結果を検討した．

5 結果

データセットを9 (訓練データ) : 1 (評価データ) の割合で分割し, 3つのモデルによるツイートの分類精度を評価した．

医薬品分類モデルの Original と Masked の分類結果の F1 スコアを比較した結果を図2に示す．全体を見ると, ほとんどの医薬品で Masked の方が F1 スコアが下がっていることがわかる．その中でもイブとルルについては, それぞれ 0.138 と 0.209 と大きな低下を示した．

図3は誤用乱用大分類モデルの Original と Masked の分類結果の F1 スコアの差である．Use に関しては医薬品名をマスクしても F1 スコアに差はほとんどでなかった．一方で, Misuse や Mention では Masked の方が F1 スコアが上がっていることがわかる．誤

用乱用大分類モデルの Masked の Original の医薬品ごとの F1 スコアについては, appendix に示した．

図4は誤用乱用細分類モデルの Original と Masked の分類結果の F1 スコアの差である．医薬品名をマスクしても, “overuse” や “against usage” では F1 スコアには大きく差はなかった．

6 考察

図2において, イブとルルの Masked の F1 スコアの大幅な低下には, データの不均衡性が寄与していると考えられる．イブやルルは医薬品関連ツイート以外のツイートも多く含まれ, イブやルルが含まれると医薬品関連でないとツイートが判断されやすくなっていると考えられる．ルルやイブでは医薬品名がマスクされたツイートでは Recall が上昇する代わりに Precision が低下していることから, 上述の影響が寄与していることが推測される．例えば, “もうやだルルしかないけど OD しよ”, “ユンケルと, ルルを, ダブルで, 飲んだとこなんよ” といった医薬品関連ツイートが Original では医薬品関連ツイートではないと判断されているが, Masked では医薬品関連ツイートであると判断されている．医薬品名をマスクした方が不必要なツイートを分類してしまう可能性が高くなるが, 誤用や乱用をキャッチしていくという意味では医薬品名をマスクした方が漏れの少ない分類モデルを作成できると考えられる．

図3において, 全体的に Mention が高くなっており, 医薬品名をマスクした方が分類精度が改善している．これは, 医薬品名が分類結果に影響を及ぼしていることが理由と考えられる．例えば, “エスタロンモカ?” や “ルルアタック APEX?” といったような医薬品名だけで, Use と分類される例があった．医薬品名をマスクすることで, 医薬品名自身が分類




図3 誤用乱用大分類モデルにおける Original と Masked の F1 スコアの差




図4 誤用乱用細分類モデルにおける Original と Masked の F1 スコア

に与える影響を減じることができる。

図4において、一部のカテゴリで Original と Masked に大きな差があった。この理由としては、これらのカテゴリはほぼ全てがラベル数が100以下であり、データが不十分であったことが原因であると考えられる。

一方で、ラベル数が500以上と十分に確保できた“overuse”においては、医薬品名の有無にかかわらず、精度良く分類することができることがわかった。既存研究では、コンプライアンス不良を分類した精度は59.7であり、20ポイント程度の改善が確認できた[5]。細分類が精度の向上に寄与していると考えられる。OTC 医薬品において、最も問題となっているのは過剰投与であり、本モデルはこうした発言を精度良く分類することができることが示唆された。

7 おわりに

本研究では、OTC 医薬品の使用状況を自動で分類するための方法について検討した。OTC 医薬品に

関するクエリでツイートを収集し、医薬品について発言されたツイートについて、アノテーションを実施しコーパスを作成した。続いて、作成したコーパスについて、医薬品分類モデル、誤用乱用大分類モデル、誤用乱用細分類モデルの3種類のモデルについて、Original と Masked の結果を比較した。その結果、医薬品名をマスクしたとしても、マスクしていないものと比較して、遜色ない精度で分類できることが示唆された。一方で、ラベル数を確保できない場合には分類精度が低くなるということもわかった。細分類においてはラベル数を確保することが難しいものがあり、少量データや不均衡データでも検出できることが求められる。

本研究は、捕捉が難しい OTC 医薬品に関する使用状況をソーシャルメディアを通じて捉えるという初の試みであり、OTC 医薬品の使用状況を把握するための新規のテキスト分類体系を構築した。情報を効率的に収集することで、当局や製薬企業がその対応を適切に行えるようになるものと期待する。

謝辞

本研究の一部は、JST AIP 日独仏 AI 研究 JP-MJCR20G9, JST CREST JPMJCR22N1, 国立情報学研究所 (NII) CRIS, JSPS 科研費 JP21H03170, AMED の課題番号 JP22mk0101229 の支援を受けたものである。

参考文献

- [1] Reiko Yano Nobuyuki Goto Fumiko Ohtsu Hiroko Niwa, Kouich Tanabe. Association between the Current Situation of Adverse Reactions Caused by Non-prescription Drug Abuse and Patient Backgrounds. **Jpn. J. Drug Inform.**, Vol. 20, pp. 145–155, 2018.
- [2] The Japan Times. Abuse of over-the-counter drugs surges among young people in Japan, 2022. <https://www.japantimes.co.jp/news/2022/01/17/national/drugs-mental-suffering/>.
- [3] Aluri Mourya, Chippy Mary, Chithu James, Josepheena Jose, and R Srinivasan. A Survey on Over The Counter Drug usage in the Community. **Journal of Drug Delivery and Therapeutics**, Vol. 9, No. 2-s, April 2019. Section: Research.
- [4] comnico. 【2023 年 1 月版】人気ソーシャルメディアのユーザー数まとめ, 2023. <https://www.comnico.jp/we-love-social/sns-users>.
- [5] 西山智弘, 矢田竣太郎, 若宮翔子, 堀里子, 荒牧英治. ソーシャルメディアにおける服薬ノンコンプライアンス発言の分類と医薬品構造類似度を用いたコーパス可搬性の検討. 言語処理学会第 28 回年次大会発表論文集, pp. 1956–1960, 2022.
- [6] Davy Weissenbacher, Suyu Ge, Ari Klein, Karen O'Connor, Robert Gross, Sean Hennessy, and Graciela Gonzalez-Hernandez. Active neural networks to detect mentions of changes to medication treatment in social media. **Journal of the American Medical Informatics Association**, Vol. 28, No. 12, pp. 2551–2561, 2021. Publisher: Oxford University Press (OUP).
- [7] Abeed Sarker and Graciela Gonzalez. Portable automatic text classification for adverse drug reaction detection via multi-corpus training. **Journal of Biomedical Informatics**, Vol. 53, pp. 196–207, February 2015.
- [8] Elise Bigeard, Natalia Grabar, and Frantz Thiessard. Detection and Analysis of Drug Misuses. A Study Based on Social Media Messages. **Frontiers in Pharmacology**, Vol. 9, p. 791, July 2018.
- [9] Nhathai Phan, Soon Ae Chun, Manasi Bhole, and James Geller. Enabling Real-Time Drug Abuse Detection in Tweets. In **2017 IEEE 33rd International Conference on Data Engineering (ICDE)**, pp. 1510–1514, San Diego, CA, USA, April 2017. IEEE.
- [10] Antonio A. Ginart, Sanmay Das, Jenine K. Harris, Roger Wong, Hao Yan, Melissa Krauss, and Patricia A. Cavazos-Rehg. Drugs or Dancing? Using Real-Time Machine Learning to Classify Streamed “Dabbing” Homograph Tweets. In **2016 IEEE International Conference on Healthcare Informatics (ICHI)**, pp. 10–13, Chicago, IL, USA, October 2016. IEEE.
- [11] Tim K. Mackey, Janani Kalyanam, Takeo Katsuki, and Gert Lanckriet. Twitter-Based Detection of Illegal Online Sale of Prescription Opioid. **American Journal of Public Health**, Vol. 107, No. 12, pp. 1910–1915, December 2017.
- [12] Michael Chary, Nicholas Genes, Christophe Giraud-Carrier, Carl Hanson, Lewis S. Nelson, and Alex F. Manini. Epidemiology from Tweets: Estimating Misuse of Prescription Opioids in the USA from Social Media. **Journal of Medical Toxicology**, Vol. 13, No. 4, pp. 278–286, December 2017.
- [13] Redhouane Abdellaoui, Pierre Foulquié, Nathalie Texier, Carole Faviez, Anita Burgun, and Stéphane Schüick. Detection of Cases of Noncompliance to Drug Treatment in Patient Forum Posts: Topic Model Approach. **Journal of Medical Internet Research**, Vol. 20, No. 3, p. e85, March 2018.
- [14] Miguel A. Alvarez-Mon, Carolina Donat-Vargas, Javier Santoma-Vilaclara, Laura de Anta, Javier Goena, Rodrigo Sanchez-Bayona, Fernando Mora, Miguel A. Ortega, Guillermo Lahera, Roberto Rodriguez-Jimenez, Javier Quintero, and Melchor Álvarez Mon. Assessment of Antipsychotic Medications on Social Media: Machine Learning Study. **Frontiers in Psychiatry**, Vol. 12, p. 737684, November 2021.
- [15] 松本俊彦, 宇佐美貴士, 船田大輔, 村上真紀, 沖田恭治, 谷淵由布子, 山本泰輔, 山口重樹. 全国の精神科医療施設における薬物関連精神疾患の実態調査. 医薬品・医療機器等レギュラトリーサイエンス政策研究事業, pp. 41–104, 2020.
- [16] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding”. In **Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)**, pp. 4171–4186. Association for Computational Linguistics, 2019.

A 参考情報

図 5, 6 は誤用乱用大分類モデルの Masked の Original の医薬品ごとの F1 スコアである。Use に関してはラベルを医薬品名をマスクしても F1 スコアに差はほとんどでなかった。一方で、Misuse や Mention では Masked の方が F1 スコアが上がっていることがわかる。




図 5 誤用乱用大分類モデルにおける Original の F1 スコア




図 6 誤用乱用大分類モデルにおける Masked の F1 スコア