

気象データを統合的に用いたクラウドソーシングに基づく 頭痛発生傾向の検知

飯田 静空[†] 若宮 翔子[†] 清水 伸幸^{††} 藤田 澄男^{††} 荒牧 英治[†]

[†] 奈良先端科学技術大学院大学 〒630-0192 奈良県生駒市高山町 8916-5

^{††} LINE ヤフー株式会社 〒102-8282 東京都千代田区紀尾井町 1-3

E-mail: [†]{iida.shizuku.iq0,wakamiya,aramaki}@is.naist.jp, ^{††}{nobushim,sufujita}@lycorp.co.jp

あらまし 気象の影響を受けて体に痛みが生じる現象は天気痛と呼ばれており、最も多い症状は頭痛である。日本で天気痛の潜在患者は1000万人以上存在するため、頭痛が発生しやすいタイミングを事前に把握することは、効果的な先制医療に繋がる。一方で、気象データから頭痛発生傾向を検知するアプリケーションは、主に気圧の特微量のみに依存しており、多様な気象データを用いる点で改善の余地が残されている。さらに、気象と頭痛発生との関係性を示す研究結果には相反が見られるため、気象の変化による頭痛発生の病態メカニズムは未だ不明な点が多い。本研究では、クラウドソーシングの回答に基づいた頭痛発生の指標である「頭痛率」を定義し、気圧、気温、湿度などの気象データを統合的に用いて頭痛発生傾向を検知する。実験の結果、気象データを統合的に用いることで頭痛発生傾向の検知性能を改善できること、気象状況が1日単位で大きく変化する時期は、気象データを用いた頭痛発生傾向の検知性能が向上することが分かった。

キーワード 医療・ヘルスケア、気象、機械学習、クラウドソーシング、ソーシャルセンシング、ソーシャルセンサ

1 はじめに

近年、頭痛は世界的な健康課題として大きく注目されている。2019年の世界における頭痛の推定症例数は、15億例以上に上り、1990年から10%以上の増加が確認されている [8]。日本では、頭痛の潜在患者は約4000万人存在すると推定されており [13]、この事実は、全人口の約3人に1人が頭痛を患っていることを表す。頭痛は緊急性が高い社会問題となっており [15]、それを解決するために、複雑化した頭痛発生のメカニズムの早期解明が求められている。特に、気象の影響を受けて体に痛みが生じる現象は天気痛と呼ばれており、最も多い症状は頭痛である [19]。日本の天気痛の潜在患者は、1000万人以上存在することが示唆されており [5]、気象と頭痛発生の関係性に対する理解は、頭痛治療の革新的な進歩に繋がる。

気象要因の頭痛には、心理的要素が関係することが示唆されており [14]、頭痛発生のタイミングを自身で把握することで自己効力感を高める予防治療も近年注目されている [1, 12]。そのため、気象データから頭痛発生のタイミングを検知し、頭痛がいつ起こりやすいかを自身で把握するためのアプリケーションがいくつか存在する。例えば、株式会社ベルシステム24が提供している頭痛一¹がある。このシステムは6時間毎に、気圧低下量の年間平均値を算出し、頭痛が発生しやすい時間帯をユーザに事前通知する。他には、株式会社ウェザーニューズが提供している天気痛予報²がある。これは気圧下降、微気圧変

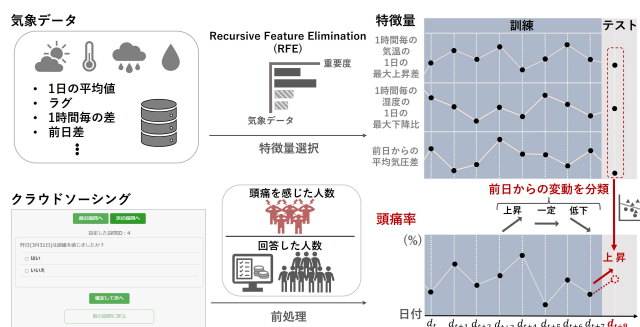


図1 本研究の概要

動、大気潮汐の3要因を基に、3時間おきの頭痛の警戒情報を4段階の指標で発信している [14]。このように、頭痛発生傾向を検知するアプリケーションでは、気象データが用いられている。しかし、これらは主に気圧の特微量のみに依存しており、多様な気象データを用いる点で改善の余地が残されている。主に気圧が用いられる理由は、気圧を感知するセンサーが内耳に存在し、頭痛が発生しやすい人ほど内耳が敏感であるという報告 [2]があるためと考えられる。一方で、気温や湿度も頭痛発生に関係すること [11, 17] が示唆されており、これらを利用することで頭痛発生傾向の検知性能を改善することが期待される。

本研究では、気象データを統合的に用いて頭痛発生傾向を検知する。図1に、本研究の概要を示す。具体的には、頭痛発生の指標としてクラウドソーシングを通して得られた回答から

1: 株式会社ベルシステム24 頭痛一

<https://zutool.jp/>

2: 株式会社ウェザーニューズ 天気痛予報

<https://weathernews.jp/s/pain/>

「頭痛率」を定義し、この指標の前日からの変動を「上昇」、「一定」、「低下」の3クラスに分類する。このとき、気圧、気温、湿度のデータを統合的に用いることで、頭痛発生傾向の検知性能を改善できるか調査する。

2 先行研究

天気痛に関する最初の研究として、Hollanderらは、気圧低下と湿度上昇の組み合わせが痛みを増強させることを示した [4]。この研究以降、特殊な人工環境装置が必要であることが原因で、十分な基礎研究が行われていない [14]。そのため、基礎研究の実験的エビデンスはないが、気象と頭痛発生の関係性を調査した研究が多く存在する。しかし、これらの研究結果には相反が見られるため、気象の変化による頭痛発生の病態メカニズムは未だ不明な点が多い。例えば、Liらの報告では、暖かい時期において相対湿度が高いほど頭痛発生が多い関係性がみられた [7]が、Yilmazらの報告では、相対湿度と救急外来を受診した1日の頭痛患者数の間に負の相関がみられた [18]。本研究では、クラウドソーシングを用いて毎日300人を対象に頭痛発生のデータを収集し、気象と頭痛発生の関係性を分析する。これまで、頭痛発生の調査にクラウドソーシングを用いた研究は少なく、新たなソースに基づく分析は、相反する知見を統一するための新たな観点を提供すると考えている。

頭痛がいつ発生するかを把握する重要性とは裏腹に、気象データを用いて頭痛発生傾向を検知する可能性について調査した研究は、我々の知る限りほとんどない。勝木らは、頭痛一発のユーザが記録した頭痛回数のデータを用いて、気象データから頭痛回数に回帰する統計モデルと深層学習ベースのモデルを構築した [6]。この研究は、気象データを用いて頭痛発生傾向を検知する可能性について評価した唯一の研究であるが、気象データの多様な組み合わせに応じた性能の違いを評価していない。さらに、結果のエラー分析に関する言及がないため、どのような場合に気象データが頭痛発生傾向を検知可能か詳細は不明である。本研究では、気圧、気温、湿度の特徴量の様々な組み合わせの利用とエラー分析を通して、気象データを用いた頭痛発生傾向の検知可能性を詳細に分析する。

3 データセット

3.1 頭痛率

本研究では、気象データを用いて頭痛発生傾向を検知し、気象と頭痛発生の関係性について分析する。そのために、人々の報告に基づく「頭痛率」指標を導入する。我々は、この指標を、「ある地域で1日における頭痛を感じた人の割合 (%)」と定義する。

Yahoo!クラウドソーシング³を利用し、2022年7月2日から2023年10月1日まで457日連続で、人々の頭痛についてのアンケートを行った。対象地域は「東京都」、1回あたりの

タスク数は300件、1タスクあたりの謝礼は5円と設定した。質問した項目は以下の3項目である。

- お住まいの市区町村を教えてください。
(回答) 東京都の62市区町村から選択式
- 昨日(昨日の日付)は主に都内のどこにいましたか？
(回答) 東京都の62市区町村と「都内にはいなかった」からなる選択式
- 昨日(昨日の日付)は頭痛を感じましたか？
(回答) 「はい」か「いいえ」の選択式

1日単位で収集したデータに対し、「昨日は主に都内のどこにいましたか？」という質問で「都内にはいなかった」と回答したユーザをそれぞれ除外した。その後、「昨日(昨日の日付)は「頭痛」を感じましたか？」という質問に「はい」と答えたユーザの割合を算出した。最終的に、2022年7月1日から2023年9月30日における東京都の日々の頭痛に関するデータセットを作成した。1日あたりに除外されたユーザ数の平均は5.3、中央値5.0であった。2022年7月1日から2023年9月30日の頭痛率の記述統計量は、平均値10.8、標準偏差2.1、最大値17.9、中央値10.5、最小値5.8であった。

3.2 気象データ

気象庁が提供している過去の気象データ検索⁴を用いて気象データを集めた。頭痛率のデータは東京都在住者を対象としたため、東京都の「東京」地点のデータを取得した。気象データの特徴量に過去のデータも考慮するため、2022年6月24日から2023年9月30日の期間で取得した。図2に収集した頭痛率、平均気温、平均湿度、平均現地気圧の日別推移を示す。

4 頭痛発生傾向の検知

本研究の目的は、気圧のみを用いるよりも気象データを統合的に用いた方が、頭痛発生傾向を高性能に検知できるかを検証することである。そのために、頭痛率の前日からの変動傾向を分類する問題に取り組む。

4.1 問題設定

この実験では、1日の頭痛率の前日比を「上昇」、「一定」、「低下」のいずれかに分類する3クラス分類問題に取り組む。これは、前日の頭痛率との相対的な関係の検知に、気象データが寄与するか調査することを意味しており、本研究の目的を検証するアプローチとして妥当であると考えられる。

頭痛率の日毎のデータに対し前日比をとる前処理を行い、事前に決めた基準をもとにラベルを付与した。図3は、頭痛率の前日比のヒストグラムを表し、表1は頭痛率の前日比の分類基準とそのデータ数の内訳を表す。分類モデルを構築するために、データセットは2022年7月1日から12月31日を学習用、2023年1月1日から3月31日を検証用、2023年4月1日から9月30日をテスト用に分割した。学習データの偏りをでき

3: Yahoo!クラウドソーシング
<https://crowdsourcing.yahoo.co.jp/>

4: 気象庁 過去の気象データ検索
<https://www.data.jma.go.jp/obd/stats/etrn/index.php>

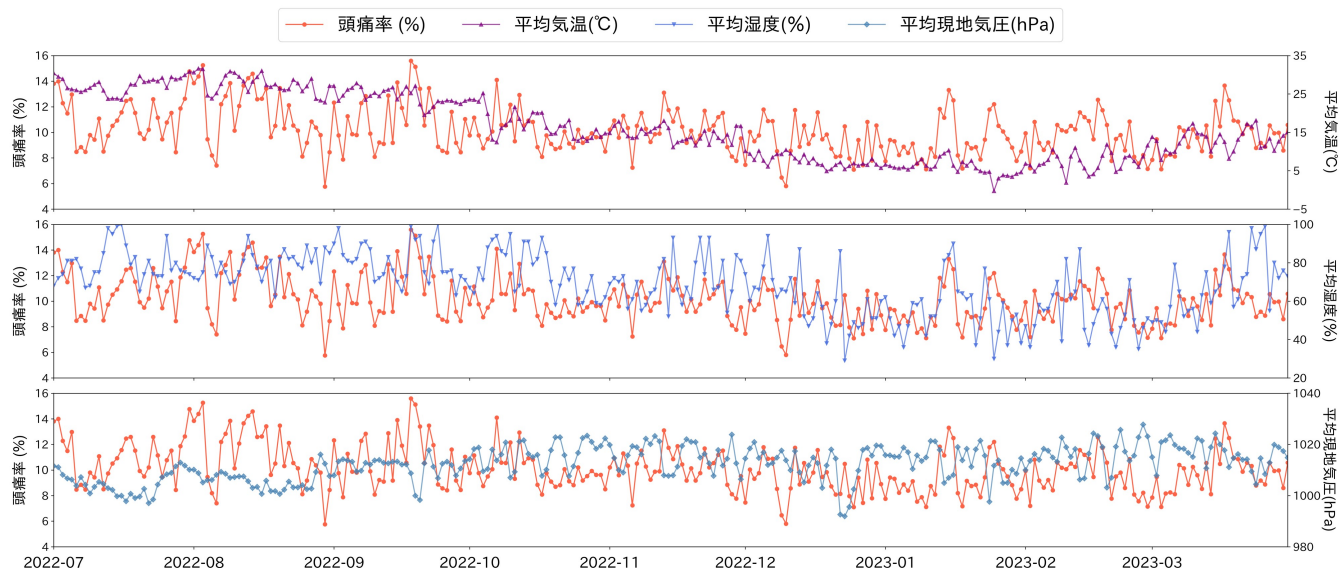


図2 2022年7月1日から2023年3月31日における頭痛率，平均気温，平均湿度，平均現地気圧の daily 推移。




図3 頭痛率の前日比のヒストグラム

表1 頭痛率の前日比の分類基準とラベル数の内訳

頭痛率の前日比	ラベル	学習	検証	テスト
$1.1 < x$	上昇	50	23	52
$0.9 \leq x \leq 1.1$	一定	75	44	83
$x < 0.9$	低下	59	23	48

る限り少なくするために，ラベルの基準は，頭痛率の前日比 x が $1.1 < x$ を「上昇」， $0.9 \leq x \leq 1.1$ を「一定」， $x < 0.9$ を「低下」と設定した。

4.2 説明変数

本研究では，様々な気象データの組み合わせで構築した分類モデルの性能を比較する．説明変数には，分類モデルに必ず用いる固定変数と任意で用いる可変変数の2種類を用いた．さらに，可変変数は気温と湿度から成る気象特徴量と気圧特徴量の2種類を用いた。

4.2.1 固定変数

固定変数はラベルのダミー変数のラグであり，以下の6種類

を用いた．これらを用いた理由は，過去の自己回帰的な特徴量は，頭痛率の前日からの変動傾向の分類に寄与すると考えられるためである．特に，分類対象日の直近の特徴量は分類への寄与が大きいと仮定し，ラグ1からラグ3までを対象とした．

- 上昇ラグ1 (1日前が「上昇」の場合は1，それ以外は0)
- 上昇ラグ2 (2日前が「上昇」の場合は1，それ以外は0)
- 上昇ラグ3 (3日前が「上昇」の場合は1，それ以外は0)
- 低下ラグ1 (1日前が「低下」の場合は1，それ以外は0)
- 低下ラグ2 (2日前が「低下」の場合は1，それ以外は0)
- 低下ラグ3 (3日前が「低下」の場合は1，それ以外は0)

4.2.2 可変変数

気象特徴量には，以下の16種類を用いた．気温と湿度は過去の情報や1日単位，前日からの変化などを特徴量の候補として挙げた。

- 1日の平均気温
- 1日の平均気温ラグ1 (1日前の1日の平均気温)
- 1日の平均気温ラグ2 (2日前の1日の平均気温)
- 前日からの平均気温差
- 1時間毎の気温の1日の最大値と最小値の差
- 1時間毎の気温の1日の最大下降差
- 1時間毎の気温の1日の最大上昇差
- 1日の平均湿度
- 1日の平均湿度ラグ1 (1日前の1日の平均湿度)
- 1日の平均湿度ラグ2 (2日前の1日の平均湿度)
- 前日からの平均湿度比
- 1時間毎の湿度の1日の最大値と最小値の比
- 1時間毎の湿度の1日の最大下降比
- 1時間毎の湿度の1日の最大上昇比

気圧特徴量には，以下の9種類を用いた．先行研究では，頭痛発生傾向の検知に大気潮汐 [14] や直近1週間の気圧パター

ン [6] が寄与することが示唆されている。そのため、大気潮汐と長期パターンを、気象特徴量の粒度に追加した。

- 1日の平均気圧
- 1日の平均気圧ラグ1（1日前の1日の平均気圧）
- 1日の平均気圧ラグ2（2日前の1日の平均気圧）
- 前日からの平均気圧差
- 1時間毎の気圧の1日の最大値と最小値の差
- 1時間毎の気圧の1日の最大下降差
- 1時間毎の気圧の1日の最大上昇差
- 1日の9時と15時の気圧差（大気潮汐）
- 直近1週間の平均気圧の平均値に対する1日の平均気圧差（長期パターン）

4.3 実験設定

ベースラインには、学習データの多数派のラベルのみを分類結果とする Majority baseline を用いた。分類モデルにはロジスティック回帰 (LR), 決定木 (DT), Support Vector Machine (SVM) を用いた。実装には、Python の scikit-learn のライブラリを用いた。LR は多項ロジスティック回帰で構築し、solver には lbfgs, 正則化には L2 正則化を指定した。DT の構築にはジニ不純度を用い、葉ノードに必要な最小サンプル数の min_samples_leaf を指定した。SVM は One-vs-Rest で構築し、カーネルには RBF, 正則化には L2 正則化を指定した。さらに、不均衡データに対処するために、全てのモデルでクラス重み付けを指定した。これは以下の式に従って、分類の重みを各クラスのデータ数の分布に応じた割合で調整する方法である。

$$\text{classweight} = \frac{n_{\text{samples}}}{n_{\text{classes}} \cdot n_{\text{samples}_{\text{class}}}} \quad (1)$$

ここで、 n_{samples} はデータの総数、 n_{classes} はクラスの総数、 $n_{\text{samples}_{\text{class}}}$ は各クラスのデータの総数を表す。

4.2 節で挙げた全ての説明変数の組み合わせを比較することが理想的である。しかし、変数の数の増加とともに組み合わせの数は指数的に増加するため、現実的な時間内でモデルを比較することは不可能となる。そのため、モデルに用いる説明変数を効率的に削減するために、Recursive Feature Elimination (RFE) を用いた。これは、初期の特徴量の集合に対してモデルを学習し、推定された重要度を基に特徴量を再帰的に削除する手法である。可変変数の候補が 15 種類以上のモデルを比較する場合に、RFE を用いて候補を 14 種類にまで削除した。その後、候補の可変変数の全ての組み合わせを比較した。RFE の各イテレーションで削除する可変変数は 1 とし、全てのモデルでクラス重み付けを指定した。LR は L2 正則化パラメータ $C = 1.0$, DT は min_samples_leaf = 1 を指定した。SVM は RBF カーネルを用いた場合に、重要度を算出することができないため、線形 SVM で L2 正則化パラメータ $C = 1.0$ を指定した。

モデルの学習と評価には、Walk-Forward Validation を用いた。図 4 に、Walk-Forward Validation のイメージを示す。これは、1 時点毎に検証・テストに用いたデータを学習データに加えていき、次の時点のデータを検証・テストデータに用いる方法である。例えば、図 4 の Set₁ では、 d_{t+2} までを学習




図 4 Walk-Forward Validation のイメージ

データに用い、 d_{t+3} 時点のラベルのみを分類する。次の Set₂ では、 d_{t+3} までを学習データに用い、 d_{t+4} 時点のみのラベルを分類する。今回は 1 セットあたり学習データの 1 時点先のみを分類していき、最終的に全セットの分類結果を総合して評価した。評価指標には、Accuracy と Macro-F1 を用いた。ハイパーパラメータの探索にはグリッドサーチを行い、検証用データの Macro-F1 の値が最も大きいパラメータを採用した。ハイパーパラメータの候補値は、LR で L2 正則化パラメータ C を {0.1 から 2.0 の範囲で 0.1 刻みの値}, DT で min_samples_leaf を {1 から 30 の範囲で 1 刻みの値}, SVM で L2 正則化パラメータ C を {0.1, 1, 10, 100}, RBF カーネルのパラメータ γ を {1, 5, 10} とした。最終的なテストデータを用いた評価には、2022 年 7 月 1 日から 2023 年 3 月 31 日までを学習データに用い、Walk-Forward Validation で評価した。

4.4 結果

表 2 に、頭痛率の前日比のラベル分類結果を示す。 $*label$ は固定変数のみで構築したモデル、 $*weather$ は気象特徴量のみで構築したモデル、 $*pressure$ は気圧特徴量のみで構築したモデル、 $*all$ は全ての特徴量で構築したモデルを表している。各モデルで考慮する説明変数の全組み合わせ中、最も Macro-F1 の大きいモデルの性能を示している。まず、Majority baseline を除く全てのモデルにおいて、Accuracy と Macro-F1 の間に大きな差が見られないため、モデルが不均衡データの分類に対処できていることが分かる。次に、3 つのモデルで、 $*label$, $*weather$ もしくは $*pressure$, $*all$ の順に Accuracy と Macro-F1 が大きいことが分かる。全ての $*label$ は Majority baseline 以下の分類性能だが、気象特徴量もしくは気圧特徴量を用いることで Majority baseline よりも分類性能が向上している。さらに、LR, DT, SVM の順に全体的な分類性能が良いことが分かる。特に、SVM と DT の分類性能に比べて、LR は格段に性能が良くなっている。各モデルにおいて、 $*all$ のモデルは最も分類性能が良く、 $*all$ の中で LR_{all} は Accuracy 0.53, Macro-F1 0.53 で最も性能が良い結果となった。気象特徴量が気圧特徴量を用いたモデルは、Majority baseline よりも分類性能は改善されたが、最高性能のモデルでも約 5 割を正確に分類可能である結果にとどまった。LR_{all} の可変変数の組み合わせは、1 時間毎の気温の 1 日の最大上昇差、1 時間毎の湿度の 1 日の最大下降比、前日からの平均気圧差、1 時間毎の気圧の 1 日の最大下降

表 2 頭痛率の前日比のラベル分類結果. テストデータの評価を示す. 各モデルが考慮する説明変数の全組み合わせ中, 最も Macro-F1 の大きいモデルの性能を示す.

モデル	Accuracy	Macro-F1
Majority baseline	0.45	0.21
LR _{label}	0.46	0.45
LR _{weather}	0.51	0.51
LR _{pressure}	0.51	0.52
LR _{all}	0.53	0.53
DT _{label}	0.38	0.38
DT _{weather}	0.50	0.50
DT _{pressure}	0.48	0.48
DT _{all}	0.51	0.51
SVM _{label}	0.36	0.34
SVM _{weather}	0.46	0.45
SVM _{pressure}	0.48	0.46
SVM _{all}	0.49	0.46

差, 大気潮汐, 長期パターンの 6 種類であり, ハイパーパラメータの値は $C = 0.3$ であった. 1 時間毎の気圧の 1 日の最大下降差, 大気潮汐, 長期パターンの気圧特徴量が重要であった本研究の結果は, 先行研究の結果 [6, 14] と一致した.

5 考 察

頭痛率の前日比ラベルの分類結果から, 気象データを用いた頭痛発生傾向の検知可能性や気象と頭痛発生の関係性について分析する.

5.1 エラー分析

図 5 に, テストデータの正解ラベル (□) と LR_{all} の分類ラベル (◇) の推移を示す. 上図は 2023 年 4 月 1 日から 6 月 30 日, 下図は 2023 年 7 月 1 日から 9 月 30 日の推移を表している. これらの総合期間 (4 月から 9 月) の LR_{all} の Accuracy は 0.53, Macro-F1 は 0.53 であったが, 時期で分けた場合, 上図の方が下図よりも正しく分類できた日が多いことが分かる. 実際, 上図の期間 (4 月から 6 月) の Accuracy は 0.60, Macro-F1 は 0.61 であるのに対し, 下図の期間 (7 月から 9 月) の Accuracy は 0.46, Macro-F1 は 0.46 であった. これらの結果は, 春先から梅雨の時期にかけて, 気象データを用いることで頭痛発生傾向の検知が比較的可能になることを示している.

さらに, 4 月から 6 月と 7 月から 9 月の期間を, 細かな時系列の粒度で比較する. まず, 4 月から 6 月の方が 7 月から 9 月よりも連続で正解している箇所が多い. 例えば, 4 月から 6 月では最長で 8 日間 (5 月 19 日から 5 月 26 日) 連続で正解することができている. 次いで, 連続 5 日間 (4 月 6 日から 4 月 10 日, 5 月 28 日から 6 月 1 日), 連続 4 日間 (4 月 1 日から 4 月 4 日, 4 月 24 日から 4 月 27 日, 5 月 4 日から 5 月 7 日, 6 月 3 から 6 月 6 日) と続き, 複数の該当箇所が見られる. 一方で, 7 月から 9 月では最長で 5 日間 (8 月 3 日から 8 月 7 日) の正解にとどまっている. 次に, 正解と真逆の分類をした箇所に注

目する. 正解と真逆の分類とは, ある日付の正解ラベルが「上昇」, 「低下」であるのに対し, 分類結果が「低下」, 「上昇」であった場合を指す. 4 月から 6 月では 6 箇所 (4 月 29 日, 5 月 8 日, 5 月 30 日, 6 月 7 日, 6 月 9 日, 6 月 16 日, 6 月 21 日) 確認されたのに対し, 7 月から 9 月では 8 箇所 (7 月 2 日, 7 月 6 日, 7 月 25 日, 8 月 19 日, 8 月 23 日, 9 月 7 日, 9 月 10 日, 9 月 23 日) 確認された.

これらの結果は, 4 月から 6 月と 7 月から 9 月の期間で, 頭痛発生傾向を検知する能力に違いがあることを示している. 4 月から 6 月と 7 月から 9 月の期間の気象状況の違いを理解するために, 各期間における平均気温と平均現地気圧の前日差, 平均湿度と頭痛率の前日比の箱ひげ図を, 図 6 に示す. 7 月から 9 月に比べると, 4 月から 6 月ほどの前日差, 前日比も中央値がほぼ同じで, 四分位範囲が大きい傾向にあることが分かる. これは, 4 月から 6 月の期間は, 気象状況が前日から大きく変化する日が多いことを表している. 気象と頭痛発生の時間的な関係性を調査した研究によれば, 寒冷前線が頻繁にやってくる時期に気象と頭痛発生に関係性が見られたこと [17] が報告されている. 気象と頭痛発生の関係性は未だ分かっていないことが多いが, 急激な気象状況の変化に伴うストレスや物理的的刺激が, 自律神経の乱れに繋がりがやすいため, 頭痛発生を引き起こしやすいと考えられている [10]. この考えに基づくと, 気象状況が 1 日単位で大きく変化するような時期では, 気象の変化は頭痛発生に大きく影響を与えるようになるため, 気象データを用いた頭痛発生傾向の検知が比較的可能になるのかもしれない.

5.2 気象と頭痛発生

5.1 節のエラー分析は, 気象と頭痛発生の関係性が時期によって複雑に変化する可能性を示唆している. そこで, 3ヶ月毎の気象データと頭痛率の相関係数を用いた関係性から, 頭痛発生傾向の検知に, 気象データを統合的に用いることが効果的な状況について分析する. 表 3 に, LR_{all} の各説明変数と頭痛率の各期間の相関係数を示す. 相関係数には, 母集団の分布を仮定しないスピアマンの順位相関係数を用い, 有意水準は 0.05 とした. 全期間は 2022 年 7 月 1 日から 2023 年 9 月 30 日, summer22 は 2022 年 7 月 1 日から 2022 年 9 月 30 日, fall22 は 2022 年 10 月 1 日から 2022 年 12 月 31 日, winter23 は 2023 年 1 月 1 日から 2023 年 3 月 31 日, spring23 は 2023 年 4 月 1 日から 2023 年 6 月 30 日, summer23 は 2023 年 7 月 1 日から 2023 年 9 月 30 日を表している.

全期間で各説明変数に有意な相関を確認できるが, サンプル数 ($n=457$) の影響であることを考慮し, 期間毎の相関について考察する. 期間毎の傾向として, winter23 と spring23 では有意な相関が多く確認される. これは, 気象が 1 日単位で大きく変化する時期は, 気象と頭痛発生が関係する 5.1 節の考察を裏付けている. winter23 と spring23 で, 1 時間毎の気温の 1 日の最大上昇差は -0.27 と -0.26 の有意な負の相関が確認された. これは, 1 月から 6 月の 1 時間単位で気温上昇が大きい日に, 頭痛発生が減少する可能性を示唆している. この条件に該当する日の特徴を理解するために, 天気との関係性を調べる.




図5 テストデータの正解ラベル(□)と LR_{all} の分類ラベル(◇)の推移. 上図が2023年4月1日から6月30日, 下図が2023年7月1日から9月30日の結果を表している.

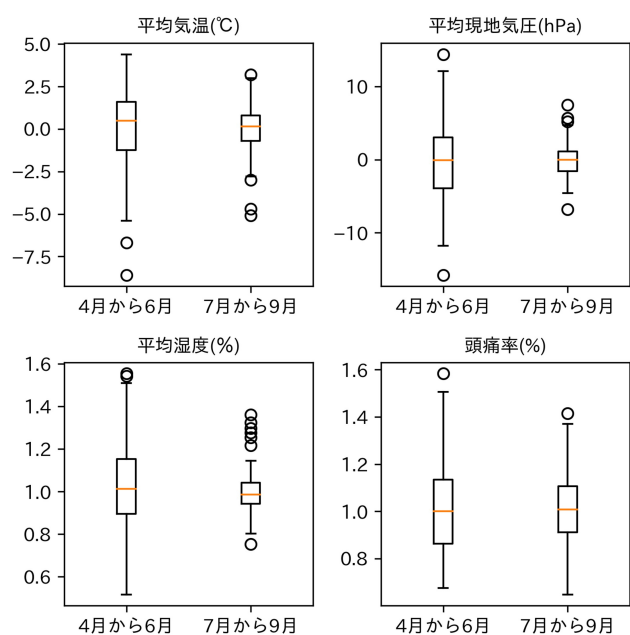


図6 平均気温と平均現地気圧の前日差と平均湿度と頭痛率の前日比の箱ひげ図

気象庁の過去の気象データ検索から天気概況(昼:06時~18時)のデータを取得し, 1時間毎の気温の1日の最大上昇差の中央値以上に該当する日数のうち, 天気概況に‘晴’, ‘曇’, ‘雨’のそれぞれの文字を含む日数の割合を比較した. ‘晴’, ‘曇’, ‘雨’の割合は, それぞれ86%, 63%, 12%であり, 1時間毎の気温の1日の最大上昇差が大きい日には, 晴れの日が多く見られることが分かる. つまり, 1時間単位の気温上昇が大きい晴れの日には, 頭痛発生が減少する傾向がある. spring23で, 1時間毎の湿度の1日の最大下降比は, 0.26の有意な正の相関が確認された. 気温と同様に, 1時間毎の湿度の1日の最大下降比でも天気の割合を比較した. ‘晴’, ‘曇’, ‘雨’の割合は, 47%, 78%, 39%であり, 1時間毎の湿度の1日の最大下降比が大きい日には, 曇りや雨の日が多く見られる. 1時間毎の湿度の1日の最

大下降比の大きさは, 1時間後の湿度変化の小ささを意味している. この結果は, 1時間単位の湿度変化が小さい曇りや雨の日に, 頭痛発生が増加する傾向であることを示している.

これらの1時間毎の特徴量に関する結果をまとめると, 1日の天気は頭痛発生に関係する可能性がある. この知見は, 悪天候で頭痛発生が確認された多くの文献で主張されている[11, 17]. 気象特徴量は, 気圧特徴量だけでは十分に捉えられない天気の特徴を表現している可能性がある. 一般的に, 低気圧時は悪天候が多いため, 天気を表す点で気圧特徴量は有効であるが, それだけで天気を説明することは難しい. 例えば, 晴れの日には地表が太陽光で温められることで上昇気流が生じ, 一時的に気圧が下がる場合がある. 一方で, このような状況では短時間の気温上昇が期待され, 気象特徴量が天気の情報に補完する可能性が考えられる. 気象の変化と天気の関係性は非常に複雑であるため, 気象特徴量がどの情報を具体的に補完するかは今後調査されるべきである.

LR_{all} の各説明変数は, ある基準からの差や比を表す特徴量であるため, 1年を通したトレンドに関する情報は排除されている. 一方で, 1日の気象の平均値がある閾値以上の場合には, 頭痛が起りやすい可能性があるため, 各気象データの1日の平均値に関しても同様に分析する. 表3の下段に, 平均気温, 平均湿度, 平均気圧の各期間における相関係数を示す. winter23とspring23で各特徴量の相関が強まる傾向に関しては, 5.1節の考察と同様である. 一方で, 1年を通して高い気温が観測されることが多いsummer22とsummer23において, 平均気温と頭痛発生間に有意な正の相関が見られる. さらに, summer23の1時間毎の気圧の1日の最大下降差を除き, これらの期間で頭痛発生と有意な相関が見られる可変変数は確認できない. この結果は, 高い気温が記録される時期の1日の気温は, 頭痛発生に大きく寄与する可能性を示唆している. 頭痛発生と暑さに焦点を絞った研究は極めて少ないが, 山口らは夏季夜間の小児の頭痛患者数が, 平均気温と有意な正の関係が見られたことを報告している[16]. 頭痛と気温の詳細な病態メカニズムは不明

表 3 LR_{all} の各説明変数における 3ヶ月毎のスピアマンの順位相関係数と p 値. 全期間は 2022 年 7 月 1 日から 2023 年 9 月 30 日, summer22 は 2022 年 7 月 1 日から 2022 年 9 月 30 日, fall22 は 2022 年 10 月 1 日から 2022 年 12 月 31 日, winter23 は 2023 年 1 月 1 日から 2023 年 3 月 31 日, spring23 は 2023 年 4 月 1 日から 2023 年 6 月 30 日, summer23 は 2023 年 7 月 1 日から 2023 年 9 月 30 日を表す. 括弧内は p 値を表し, 太字は $p \leq 0.05$ の値を表す.

	全期間 <i>n</i> = 457	summer22 <i>n</i> = 92	fall22 <i>n</i> = 92	winter23 <i>n</i> = 90	spring23 <i>n</i> = 91	summer23 <i>n</i> = 92
1 時間毎の気温の 1 日の最大上昇差	-0.09 (0.05)	0.14 (0.17)	-0.15 (0.14)	-0.27 (0.01)	-0.26 (0.01)	-0.07 (0.49)
1 時間毎の湿度の 1 日の最大下降比	0.23 (0.00)	-0.09 (0.40)	0.15 (0.15)	0.14 (0.20)	0.26 (0.01)	0.16 (0.14)
1 時間毎の気圧の 1 日の最大下降差	0.22 (0.00)	-0.07 (0.49)	-0.02 (0.85)	0.00 (0.98)	-0.12 (0.27)	0.21 (0.04)
前日からの平均気圧差	-0.15 (0.01)	-0.08 (0.42)	-0.16 (0.14)	-0.15 (0.14)	-0.21 (0.04)	-0.05 (0.64)
大気潮汐	-0.12 (0.01)	-0.09 (0.38)	-0.03 (0.77)	0.03 (0.78)	-0.12 (0.24)	0.04 (0.70)
長期パターン	-0.16 (0.00)	-0.16 (0.12)	-0.15 (0.17)	-0.29 (0.01)	-0.24 (0.02)	-0.04 (0.68)
平均気温	0.56 (0.00)	0.38 (0.00)	0.18 (0.09)	0.11 (0.28)	0.23 (0.03)	0.41 (0.00)
平均湿度	0.37 (0.00)	0.01 (0.95)	0.22 (0.04)	0.31 (0.00)	0.42 (0.00)	-0.06 (0.57)
平均気圧	-0.37 (0.00)	-0.10 (0.32)	-0.02 (0.85)	-0.23 (0.02)	-0.37 (0.00)	-0.06 (0.59)

とされているが, 夏季の時期に頭痛発生の要因が変化している可能性は考えられる. 5.1 節で見られた LR_{all} の分類性能の低下に対し, この知見は性能改善の可能性を示唆している.

5.3 限界

気象データを統合的に用いて頭痛発生傾向を検知するモデルから, 両者の関係性を分析した本研究のアプローチには, いくつかの限界がある. 1 つ目は, 今回用いた説明変数の最適な組み合わせは, 別に存在する可能性がある. 本研究では, RFE を用いてモデルが考慮する説明変数の数を最長 14 個に制限し, 14 個の全組み合わせを調査した. RFE はモデルを構築した際の重要度が小さい変数を削除する方法であるため, 実際の分類に有効な特徴量を削除してしまう可能性がある. 候補として挙げた可変変数の探索範囲を拡大できれば, 分類性能はさらに向上する可能性がある. しかし, 現実的な時間内で全ての組み合わせを比較することは不可能であるため, RFE よりも最適な変数選択の方法を模索する必要がある.

2 つ目は, 分析対象の集団内にバイアスが存在することである. 本研究では, クラウドソーシングを用いて東京都在住者を対象とした上で, 気象と頭痛発生の関係性を調査した. クラウドソーシングの手法上, 回答者が特定の集団に偏ってしまう選択バイアスや, 昨日のことを尋ねた時間感覚的な歪みに関する記憶バイアスなどが存在する. これらのバイアスを排除することはできないため, 今回の知見が現実の集団に対しても適用できるか別アプローチからの検証を行うべきである.

3 つ目は, 頭痛率のデータに気象以外の要因がどの程度含まれていたかは不明なことである. 頭痛には, 気象以外にストレス, 疲れ, 騒音など様々な要因や, 片頭痛や緊張型頭痛などの様々な種類が存在することが分かっている. 本研究では, クラウドソーシングの質問で気象条件に言及せずに, 昨日頭痛があったかどうかのシンプルな質問をした. そのため, 気象以外の要因による頭痛や, メカニズムが異なる様々な頭痛のノイズ

が混入している可能性がある. 従って, 気象が影響する頭痛を対象を絞ることができれば, 気象と頭痛発生に関するより有益な知見を提供することに繋がると考えられる.

4 つ目は, アプリケーションを実現できる頭痛発生傾向の検知性能を, 現状達成できていないことである. 表 2 を見ると, Majority baseline と比較して気象データを用いたことで分類性能は改善したが, 最高で約 5 割の分類性能にとどまっている. 現状の分類問題に機械学習を用いる意味はあるが, アプリケーションの性能まで昇華させることは現時点では難しい. 最終的に, 気象状況から頭痛発生傾向を把握できるアプリケーションの構築を目指しているが, 最低でも 8 割の分類性能を達成したいと考えている. 解決策として, 気象の影響を強く受ける特定の属性集団を対象とすることや, 気象と頭痛発生の関係性をより表現できるモデルを検討することなどが考えられる. 一方で, 気象データを用いて頭痛発生傾向を検知することが, 如何なる場合でも難しい可能性も考えられるため, 多様なアプローチの観点から今後も研究されるべきである.

6 おわりに

本研究では, 気象状況から頭痛発生傾向を把握するアプリケーションの構築を目標とし, 気象データを統合的に用いて頭痛発生傾向を検知する可能性を調査した. そのために, クラウドソーシングで得られた回答から頭痛発生を表す「頭痛率」指標を導入し, 頭痛率が前日から上昇したかを分類する 3 クラス分類を行った. 気象データの様々な組み合わせを比較した実験結果から, 気圧, 気温, 湿度の特徴量を統合的に用いたロジスティック回帰が最も高い分類性能を示した. さらに, 構築した分類モデルの分析を通して, 1 日単位の気象変化が大きい時期では, 比較的高性能な分類が実現できることを示し, 気温や湿度の気象データを用いて頭痛発生傾向を検知する重要性を示した.

今後の発展としては, 大きく 3 点考えられる. 1 点目は, 限

定された属性の集団でどの程度気象データを用いた頭痛発生傾向の検知が可能かを調査することである。例えば、女性の方が男性よりも偏頭痛が多いことが報告されており [13], 性別の違いによって気象が頭痛発生に与える影響に違いが生じる可能性がある。本研究では、クラウドソーシングにおける東京都在住者の集団のみを対象としたため、様々な集団での頭痛発生に関する調査は、興味深い知見を提供すると考えている。

2点目は、頭痛発生との関係性がより強く、収集が比較的容易なデータを検知に利用することである。5.3節でも言及した通り、今回の頭痛発生傾向の検知性能は約5割である。気象データの収集は容易ではあるが、今回の結果から気象データを用いるだけでは頭痛発生傾向を十分に検知することは困難である。解決方法としては、頭痛発生とより関係性の強いデータを検知に用いることである。例えば、「頭痛」、「頭痛薬」、「天気」などのweb検索クエリの検索回数は頭痛発生と相関があるかもしれない [3,9]。さらに、人間の暑さを定量化した暑さ指数は、気象データよりも頭痛発生の生体情報として有用かもしれない。これらのデータが頭痛発生とどう関係するかを調査することは、頭痛発生を将来的に抑制するための重要な研究になる。

3点目は、過去の気象データから頭痛発生傾向をどの程度検知できるか調査することである。本研究では、主に同時点のデータから頭痛発生傾向を検知するアプローチを採用したが、数日前に入手可能なデータから検知できた方がより有用なアプリケーションを実現できる。今回の結果は、時間軸で最も近い気象データを用いた場合でも、約5割の検知性能にとどまった。頭痛発生傾向を検知するアプローチについて様々な観点から研究することは、頭痛発生を抑制するためのアプリケーションの実現に近づく。

謝 辞

本研究は、LINE ヤフー株式会社共同研究費の支援を受けたものである。

文 献

- [1] Christopher J Elcik, Christopher M Fuhrmann, Scott C Sheridan, Kathleen Sherman-Morris, and Andrew E Mercer. Perceptions of weather-based pain forecasts and their effect on daily activities. *International Journal of Biometeorology*, pp. 1–15, 2023.
- [2] Megumi Funakubo, Jun Sato, Takashi Honda, and Kazue Mizumura. The inner ear is involved in the aggravation of nociceptive behavior induced by lowering barometric pressure of nerve injured rats. *European Journal of Pain*, Vol. 14, No. 1, pp. 32–39, 2010.
- [3] Kurubaran Ganasegeran, Alan Swee HockCh'ng, Zariah Abdul Aziz, Irene Looi. Population's health information-seeking behaviors and geographic variations of stroke in malaysia: An ecological correlation and time series study. *Scientific reports*, Vol. 10, No. 1, p. 11353, 2020.
- [4] Joseph L Hollander and Sarantos J Yeostros. The effect of simultaneous variations of humidity and barometric pressure on arthritis. *Bulletin of the American Meteorological Society*, Vol. 44, No. 8, pp. 489–494, 1963.
- [5] Shinsuke Inoue, Fumio Kobayashi, Makoto Nishihara, Young-Chang P. Arai, Tatsunori Ikemoto, Takashi Kawai, Masayuki Inoue, Tomomi Hasegawa, and Takahiro Ushida. Chronic pain in the Japanese community—prevalence, characteristics and impact on quality of life. *PLOS ONE*, Vol. 10, No. 6, pp. 1–14, 2015.
- [6] Masahito Katsuki, Muneto Tatsumoto, Kazuhito Kimoto, Takashige Iiyama, Masato Tajima, Tsuyoshi Munakata, Taihei Miyamoto, and Tomokazu Shimazu. Investigating the effects of weather on headache occurrence using a smartphone application and artificial intelligence: a retrospective observational cross-sectional study. *Headache: The Journal of Head and Face Pain*, Vol. 63, No. 5, pp. 585–600, 2023.
- [7] Wenyuan Li, Suzanne M. Bertisch, Elizabeth Mostofsky, Catherine Buettner, and Murray A. Mittleman. Weather, ambient air pollution, and risk of migraine headache onset among patients with migraine. *Environment International*, Vol. 132, p. 105100, 2019.
- [8] Xin-yu Li, Cheng-hao Yang, Jia-jie Lv, Hui Liu, Lu-yu Zhang, Min-yi Yin, Zhi-lin Guo, and Ru-hong Zhang. Global, regional, and national epidemiology of migraine and tension-type headache in youths and young adults aged 15–39 years from 1990 to 2019: findings from the global burden of disease study 2019. *The Journal of Headache and Pain*, Vol. 24, No. 1, p. 126, 2023.
- [9] Marcelo D Mendonça, André Caetano, and Miguel Viana-Baptista. “Dr Google” will see you now—time trends in online searches on headache. *Cephalalgia*, Vol. 38, No. 2, pp. 407–408, 2018.
- [10] Karl Messlinger, Megumi Funakubo, Jun Sato, and Kazue Mizumura. Increases in neuronal activity in rat spinal trigeminal nucleus following changes in barometric pressure—relevance for weather-associated headaches? *Headache: The Journal of Head and Face Pain*, Vol. 50, No. 9, pp. 1449–1463, 2010.
- [11] Kayoko Ozeki, Tatsuya Noda, Mieko Nakamura, and Toshiyuki Ojima. Weather and headache onset: a large-scale study of headache medicine purchases. *International journal of biometeorology*, Vol. 59, pp. 447–451, 2015.
- [12] Bianca Raffaelli, Jasper Mecklenburg, Lucas Hendrik Overeem, Simon Scholler, Markus A Dahlem, Tobias Kurth, Ana Sofia Oliveira Gonçalves, Uwe Reuter, and Lars Neeb. Determining the evolution of headache among regular users of a daily electronic diary via a smartphone app: observational study. *JMIR mHealth and uHealth*, Vol. 9, No. 7, p. e26401, 2021.
- [13] F Sakai and H Igarashi. Prevalence of migraine in Japan: a nationwide survey. *Cephalalgia*, Vol. 17, No. 1, pp. 15–22, 1997.
- [14] J Sato, R Ueyama, K Morita, T Furuya, Y Otsuka, S Hatakeyama, et al. The epidemiological and clinical features of weather-related pain (tenkitsu) and development of prediction information service for the onset of pain. *Pain Res*, Vol. 36, No. 2, pp. 75–80, 2021.
- [15] Toshihiko Shimizu, Fumihiko Sakai, Hitoshi Miyake, Tomofumi Sone, Mitsuhiro Sato, Satoshi Tanabe, Yasuhiro Azuma, and David W Dodick. Disability, quality of life, productivity impairment and employer costs of migraine in the workplace. *The journal of headache and pain*, Vol. 22, No. 1, pp. 1–11, 2021.
- [16] Hiroshi Yamaguchi, Kandai Nozu, Shinya Ishiko, Hiroaki Nagase, Takeshi Ninchoji, Hiroki Takeda, Ai Unzaki, Kazuto Ishibashi, Ichiro Morioka, Kazumoto Iijima, et al. Multivariate analysis of the impact of weather and air pollution on emergency department visits for night-time headaches among children: retrospective, clinical observational study. *BMJ open*, Vol. 11, No. 4, p. e046520, 2021.
- [17] Albert C Yang, Jong-Ling Fuh, Norden E Huang, Ben-Chang Shia, Chung-Kang Peng, and Shuu-Jiun Wang. Tem-

poral associations between weather and headache: analysis by empirical mode decomposition. *PLOS ONE*, Vol. 6, No. 1, p. e14612, 2011.

- [18] Mustafa Yilmaz, Mehtap Gurger, Metin Atescelik, Mustafa Yildiz, and Sukru Gurbuz. Meteorologic parameters and migraine headache: Ed study. *The American Journal of Emergency Medicine*, Vol. 33, No. 3, pp. 409–413, 2015.
- [19] ウェザーニュース. 【天気痛調査 2020】天気痛持ちは全体の 6 割? 天気痛女子は約 8 割にも, July 2020. <https://weathernews.jp/s/topics/202007/070165/>.