

11. マシンラーニングを応用した地震断層の摩擦モデル

オム テフン

1. はじめに

断層物理の研究では、地震の物理学を理解する上で摩擦が重要な役割を果たしていることが考えられている。地震は、既存の断層やプレートの境界面から発生する摩擦不安定性と見なされている。さらに、摩擦の振る舞いは、断層面間の物理的パラメータによって制御される。したがって、摩擦と物理パラメータ間の関係を理解することは、地震物理学を包括的に理解するために不可欠である。先行研究では、温度、滑り速度、滑り変位、材料特性など、摩擦の振る舞いに寄与するいくつかの重要な物理パラメータが特定されている (Byerlee, 1978; Beeler et al, 2008)。これらのパラメータの組み合わせを含む数値モデルを通じて探求されてきました。しかし、摩擦の振る舞いは多くの物理パラメータとそれらの滑り時間に伴う時間的進化との複雑な相互作用を示すため、従来の摩擦モデルよりも詳細に関係を表現することは難しい状況である。

この研究では、岩石摩擦実験から取ったデータを使用して摩擦モデルを構築するために、リカレントニューラルネットワーク (RNN) を採用した。RNNは、シーケンシャルデータ内の時間的依存関係を捉える能力のため、時系列分析に特に適している。研究で構築されたモデルは、様々な滑り時間間隔 (データシーケンスの長さ) を通じて、断層表面の5つの物理パラメータ (滑り速度、軸方向の変位、温度、温度の変化率、軸方向の変位の変化率) に基づいて特定の時点での摩擦を定義する。摩擦に直接影響を与える正常応力やせん断応力などのパラメータは除外された。導出されたモデルを分析し、摩擦を定義するための最適な時間間隔 (最適なシーケンス長) を探求し、変化する正常応力条件下で各物理パラメータが摩擦を決定する重要性を評価する。

2. 方法

2.1 RNNs

リカレントニューラルネットワーク (RNN) は、時系列データのモデリングに適したディープラーニングのニューラルネットワークの一種である (Sundermeyer et al, 2012)。従来のニューラルネットワークが各入力を独立して処理するのに対し、RNNは状態またはメモリを維持し、入力 of シーケンスを扱うことができる。RNNの基本原理は、シーケンスの一ステップから次のステップへ情報を渡すループを使用することにある。これにより、RNNは前の入力のメモリを維持し、そのメモリを使用してモデルを作成することができる。しかし、一般のRNNは消失または爆発するグラジエントの問題があるため、この研究では、情報の流れを選択的に制御してトレーニング中にネットワークを通して伝播する際に勾配が小さすぎたり大きすぎたりするのをコントロールできるGRUを利用した。

摩擦と5つのパラメーター (滑り速度、軸方向変位、温度、温度の変化率、軸方向変位の変化率) との関係を定義するモデルを構築するために、時間窓ベースのアプローチを適用した。このアプローチでは、出力特徴は与えられた時間の摩擦値であり、入力特徴は出力特徴で設定された摩擦値の時間までの特定の時間間隔 (データシーケンスの長さ) にわたる5つのパラメーターの値で構成されます。50秒 (s)、100s、150s、200s、250s、300s、350s、400s、450s、500sの10の異なる時間間隔ごとに個々のモデルを構築した。これらの間隔はそれぞれ、50、100、150、200、250、300、350、400、450、および500のデータシーケンスの長さのデータセットに対応した。それぞれの時間間隔 (データシーケンスの長さ) ごとに、20回のトレーニングイテレーションを実施し、各

イテレーションは100トレーニングエポックで構成された。2つの異なる正常応力条件のデータを含めることができるように、各時間間隔（データシーケンスの長さ）の時間窓を設定した。入力データは、時間間隔が増加するにつれてサイズが拡大する多次元マトリックスで構成されている。機械学習モデルは、2つの1次元畳み込み（Conv1D）層に続いて4つのGRU層、そしてDense層が順に構築されました。Conv1D層は、各時間間隔（データシーケンスの長さ）の入力データ内の局所的な特徴やパターンを学習するために追加された。

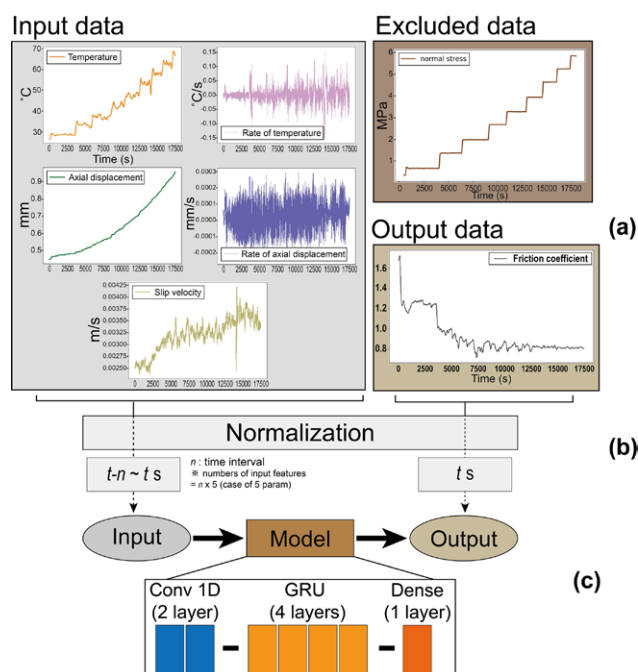


図1 GRUモデルの構造

2.2 グラジエント重要性

ニューラルネットワークモデルの構造が「ブラックボックス」として一般に認識されているにもかかわらず、特定の外部推論技術を用いることで、それらから貴重な情報を抽出し、その内部構造と入力特徴が出力特徴に与える影響の理解を深めることができる。モデルでは、各入力パラメータに対する損失のグラジエントがある。このグラジエントの特徴がモデルの損失の変化にどれだけ敏感であるかを測定する。このようなグラジエントは、特定の入力特徴が結果としての出力にどの程度影響を与えるかについて貴重な洞察を提供する (Guidotti et al., 2018; Fisher et al., 2019)。各入力特徴の影響度を決定するために、入力シーケンスの微分を通じて得られたモデルのグラジエントを分析した。これらのグラジエントは実数として現れ、positiveの場合は直接的な関係を、negativeの場合は入力特徴と出力特徴の間の逆の関係を示す。グラジエントの大きさは、その符号に関係なく、出力が入力特徴の変化に対してどれだけ敏感であるかを定量化し、入力特徴の出力に対する相対的な重要性の指標として機能である。このため、この研究では「重要性」（グラジエントの大きさ）に焦点を当て、グラジエントの符号の影響を解釈から排除するために、これらのグラジエントの絶対値を計算した。

3. 結果

3.1 最適モデル

図2 aは、異なる時間間隔で5つのパラメータを用いて構築されたモデルの最低val_lossのトレンドを箱ひげ図と点プロットで表している。図は、四分位範囲 (IQR) を象徴する長方形の箱として描かれている。最低val_lossデータの下位四分位数 (Q1または25%を表す) から上位四分位数 (Q3または75%を表す) にかけての範

囲を含み、データの中央50%をカバーする。上のヒゲはQ3から、Q3から1.5倍のIQRの範囲内の最大データ値まで伸び、下のヒゲはQ1から、Q1から同じ範囲内の最小データ値まで伸びる。最低val_lossの平均は、すべての時間間隔で0.001106から0.001301の範囲にあり、時間間隔が400秒(s)まで増加するにつれて連続して減少する傾向が示される。50秒から300秒まで、最低val_lossの平均は急速に減少し、400秒で最低の平均値に達するまで徐々に低下した。450秒から500秒の時間間隔の最低val_lossの平均は、400秒の間隔よりもわずかに高かった。同様に、val_lossの最大値、上位四分位数、下位四分位数も平均と同様のパターンを示す。最低val_lossの最小値は250秒までより緩やかな下降を示し、その後より顕著な下降を示す。400秒を超えると、最低val_lossの最小値は500秒まで上昇を示す。注目すべきは、最低val_lossの最小値を持つモデルは、400秒の時間間隔で構築されたモデルにも見られることである。これは、最低val_lossの平均が最小であると観察される間隔と一致している。

モデルの性能は、検証およびテストデータセットの予測摩擦値と真摩擦値を比較することで識別できます(図2b)。50秒の時間間隔で訓練されたモデルによって予測された摩擦は、真摩擦値から大きく逸脱するだけでなく、全体的なトレンドも捉えることができなかった。200秒の時間間隔で訓練されたモデルは、真摩擦値の全範囲を予測することはできなかったが、検証データセットでの真の摩擦の一般的なトレンドをかなりよく捉えた。400秒の時間間隔で訓練されたモデルは、真摩擦値の範囲とトレンドの両方をよく予測した。500秒の時間間隔で訓練されたモデルは、400秒のモデルよりも性能が悪かった。500秒のモデルは、検証およびテストデータセットで400秒のモデルと同じくらい真の摩擦のトレンドを予測したが、真摩擦の範囲を正確に予測することはできなかった。この結果に基づき、摩擦を最もよく特徴づけるモデルを構築するための最適な時間間隔条件は400秒であると考えられる。

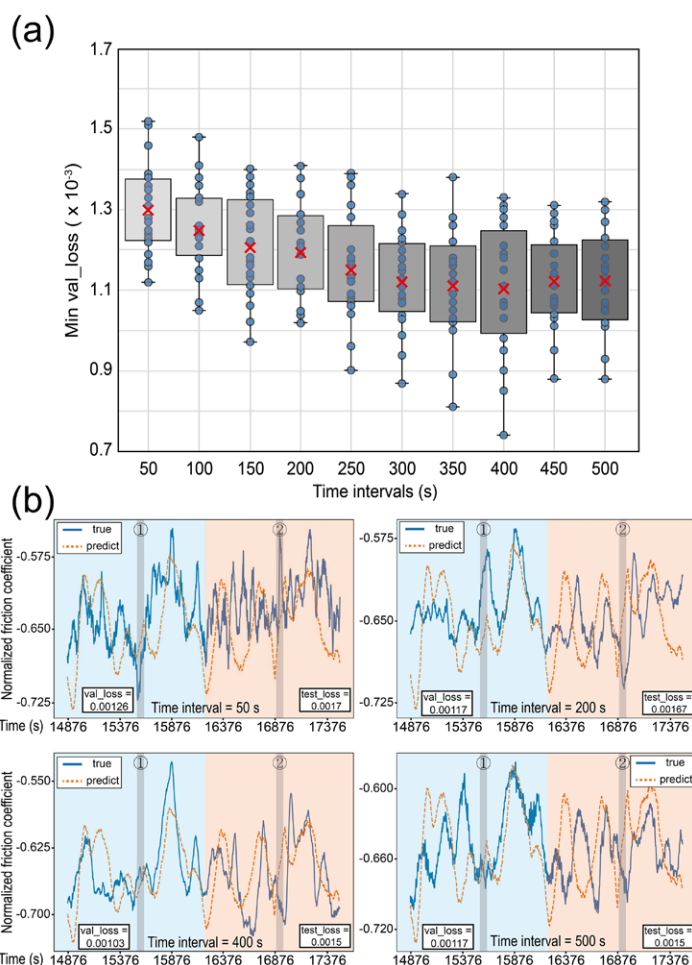


図2 (a) 時間間隔によるモデルのloss、(b) 時間間隔によるモデルの性能

3.2 重要性

図3は、モデルごとに分類されたすべての正常応力範囲にわたる各パラメータの平均相対重要度を示す。すべてのモデルを通じて、各パラメータに割り当てられた平均重要度は差異を示す。特に、各モデルの平均重要度は類似した大きさを示していますが、そのランキングはわずかに異なる（図4）。すべてのモデルを通じて、温度は一貫して最も重要なパラメータとして浮上し、重要度の値は0.2877から0.3374の範囲にある。軸方向変位は、重要度の値が0.1997から0.2773の範囲にわたって、二番目に重要なパラメータとしてランクインしている。例外として、モデル-2ndでは、軸方向変位が三番目に重要なパラメータとして記録され、重要度の値は0.1717である。滑り速度のランキングはより広範囲に変動し、重要度の値が0.1419から0.1908の比較的狭い範囲にもかかわらず、二番目から四番目の重要なパラメータとして変動した。温度の変化率は一般に重要度の第四位としてランクされ、値は0.1361から0.1815の範囲にわたりますが、モデル-9thでは第三位となり、重要度の値は0.1621と記録された。すべてのモデルにおいて、軸方向変位の変化率は一貫して最も影響力のないパラメータとしてランクされ、重要度の値は0.1361から0.1815の範囲内にある。

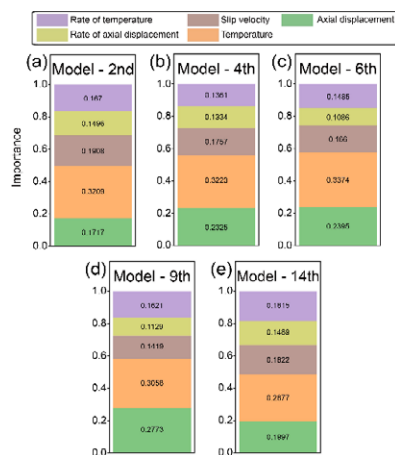


図3 各パラメータの重要性




図4 各モデルの平均重要度

4. まとめ

本研究では、岩石摩擦実験における5つの物理パラメーター（滑り速度、軸方向変位、温度、温度の変化率、軸方向変位の変化率）、時間、および摩擦との関係を調査した。正常応力が増加すると、滑走面での摩擦熱が発生し、温度が上昇した。物理パラメーターと摩擦の関係を調査するために、我々はリカレントニューラルネットワーク（RNN）を使用して断層摩擦を表すモデルを開発した。摩擦を効果的に定義する最適モデルの分析は、摩擦を定義するための最適な時間間隔は400秒であることを示唆した。さらに、物理パラメーターの重要性は、滑り時間と条件が変化するにつれて連続して変化します。正常応力の全範囲にわたる摩擦に対するこれらの物理パラメーターの平均的な重要性の評価では、次のようにランク付けされた：温度、軸方向変位、滑り速度、温度の変化率、軸方向変位の変化率。

参考文献

- Byerlee J (1978) Friction of rocks. Rock friction and earthquake prediction, Springer, eidelberg, p 615-626.
- Beeler NM, Tullis TE, Goldsby DL (2008) Constitutive relationships and physical basis of fault strength due to flash heating. Journal of Geophysical Research: Solid Earth, 113 (B1) . <https://doi.org/10.1029/2007JB004988>
- Sundermeyer M, Schlüter R, Ney H (2012) LSTM neural networks for language modeling. Proc. Interspeech, 194-197. <https://doi.org/10.21437/interspeech.2012-65>