

機械学習によるSQLインジェクションの有効な特徴量の探索

Searching for Effective Features of SQL Injection Using Machine Learning

研究駆動コース 29R 林 美里

1. 研究背景・目的

- SQLインジェクション攻撃(SQLi)により、個人情報の搾取や改ざんの被害が続いている[1][2]。
- これまでの研究では、HTTPクエリ文字列の長さ、エントロピー、閉じ括弧の有無を特徴量として使用[3]。ここで、エントロピー $H(X) = -\sum_{i=1}^n P_i \log_2 P_i$ (P_i :HTTPクエリ文字列中の文字の出現確率)

英語の文章は単語と文法構造で意味を表すが、

SQL文は記号を使って条件を指定する

英文	My name is Hayashi and I like electronics.
SQL文	SELECT * FROM users WHERE name = 'Hayashi' AND hobby = 'electronics';

→ SQLインジェクションの検出において、

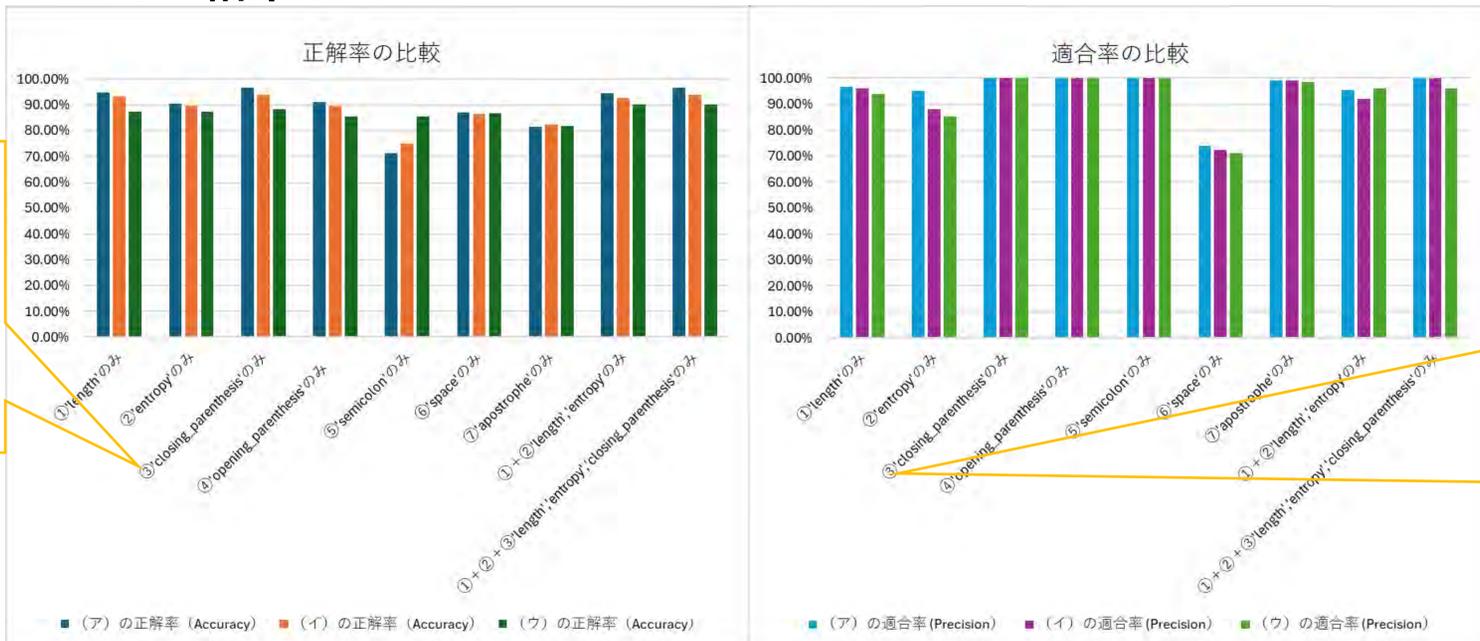
クエリ内の記号(特殊文字)の有無は重要なポイントになり得る

- 攻撃検出の精度向上には「適切な特徴量の選定」が不可欠。適切な特徴量を探索し、攻撃と通常のクエリを高精度に分類することが重要。本研究では「どの特徴量がSQLi検出に有効か？」を検証。

2. 研究方法

- データセット: HttpParamsDataset(異常ラベル付きHTTPクエリ文字列を含む)[3]と園田先生提供のデータセット[2]
- 仮定:
 - SQLiのHTTPクエリ文字列は、特定のSQL文法に基づき、通常のクエリと異なるエントロピーを持つ。
 - SQLi特有の記号の出現頻度を考慮[2]。
 - 特徴量エンジニアリング:
 - エントロピーを算出し、数値化。
 - 参考文献[3]のTrainデータ(sqli:7,235行)中での閉じ括弧の出現割合と、参考文献[2]の園田先生提供のTrainデータ(sqli:625行)中での閉じ括弧の出現割合を調査 → それぞれ90.91%、45.92%であった。
- 検出器開発 (DecisionTreeClassifier(決定木)を使用):
 - length, entropy, closing_parenthesisなどの組み合わせでSQLiの検出器を作成。精度評価を実施。

3. シミュレーション結果



・①から⑦の組み合わせで正解率(Accuracy)が高いものを探した。③閉じ括弧のみでも高い正解率が得られた。

・ Webアプリケーションファイアウォール(WAF)では誤検知(False Positive)が問題となる。誤検出しない確率である適合率(Precision)を見てみると、③閉じ括弧のみでも高い適合率が得られた。

使用データセット:

- (ア) 参考文献[3]のTrainデータ(norm:12,870行, sqli:7,235行)及びTestデータ(norm:6,434行, sqli:3,617行)。
- (イ) 参考文献[3]のTrainデータの先頭からnorm: 1,112行を抽出したTrainデータ(norm:1,112行)と参考文献[2]の園田先生提供のTrainデータ(sqli:625行)及び参考文献[3]のTestデータ(norm:6,434行, sqli:3,617行)。参考文献[2]と参考文献[3]の両方からnormとsqliの比率を変えずにTrainデータを作成。
- (ウ) 参考文献[3]のTrainデータの先頭からnorm: 1,112行を抽出したTrainデータ(norm:1,112行)と参考文献[2]の園田先生提供のTrainデータ(sqli:625行)及び参考文献[3]のTestデータの先頭からnorm: 556行とsqli:312行を抽出したTestデータ(norm:556行, sqli:312行)。参考文献[3]のTrainデータ(sqli:7,235行)と参考文献[2]のTrainデータ(sqli:625行)のsqliの比率に合わせて参考文献[3]のTestデータのデータ数を削減。

● 結果:

- closing_parenthesisのみでも高い正解率(Accuracy)を達成。
- 適合率(Precision)においてもclosing_parenthesisのみで高い値を確認。

4. 結論

- 機械学習モデルの性能は入力データ(特徴量)に大きく依存。SQLiの特徴を考慮した新たな特徴量を提案・評価。
- Webアプリケーションのセキュリティ強化に貢献する可能性を示した。

参考文献

- [1] IPA 脆弱性対策情報データベース「CWE-89 SQLインジェクション」
- [2] 園田道夫, 中央大学博士論文「潜在的要因を考慮したSQLインジェクション攻撃検知システムの開発」
- [3] Chiheb Chebbi 他, 「セキュリティエンジニアのための機械学習」, オライリージャパン