

機械学習によるルール順序最適化問題の解法 A Solution Method for the Optimal Rule-Ordering Problem with Machine Learning

蛭田 悠人¹⁾ 田中 賢¹⁾
Yuto Hiruta Ken Tanaka

1 はじめに

パケット分類は、ネットワーク機器に到達したパケットを予め設定した規則に従って分類し、各パケットに対する操作を決定する機能である。TCAM や ASIC などのハードウェアを持たないネットワーク機器においては、決定木やリストなどのインメモリデータ構造を用いてパケットを分類する。前者では木探索によるノードの到達数が、後者ではリストの線形探索によるルールとの比較回数が、パケット分類による通信の遅延を決定する。この遅延を最小化するために、より小さな決定木を構築する発見的解法や、リストのルール順序を最適化する発見的解法が研究されている。Eric らは、決定木に対するパケット分類問題について、深層強化学習により決定木を構築する手法を提案し、機械学習が有効に機能することを示した [1]。

本研究では、深層強化学習によりリストのルール順序を最適化する手法を提案し、ルールリスト並べ替えに対する機械学習の有効性を検討する。

2 ルール順序最適化問題

はじめに、パケット分類をモデル化し、ルール順序最適化問題を形式化する。

パケットは $\{0, 1\}^w$ 上の長さ w のビット列とする。ルールは、合致するパケットの条件を示すビット列 $b_1 b_2 b_3 \dots b_w \in \{0, 1, *\}^w$ と、パケットに適用される評価型 $a \in \{Permit, Deny\}$ からなる。 $*$ は 0 及び 1 のどちらにも合致することを意味する。

パケット分類は図 1 の例のようにモデル化される。ネットワーク機器に到着したパケットは、ルールリストの先頭から順番に照合され、最初に合致したルールの評価型を適用する。評価を決定するまでに行った照合回数を基に、ネットワーク機器全体の遅延を (1) として定義する。

定義 1 (遅延) ルールリスト R 及び頻度分布 F のパケット集合が与えられたとき、ルールリスト全体における遅延の値 $L(R)$ は以下となる。

$$L(R, F) = \sum_i^n i |r_i| \quad (1)$$

ただし、ルール r_i によって評価が決まるパケット数を $|r_i|$ とする。

パケットの頻度分布が与えられると、ルールの順序により遅延 L が変化する。例えば図 1 において、 r_4^P に合致するパケットが最も多いとき、 r_3^D と r_4^P の順序を入れ替えることにより遅延が減少する。ここで、 r_2^D と r_4^P の順序を入れ替えることはできない。両方に合致するパ

1) 神奈川県立理学研究科情報科学領域 Field of Information Science, Graduate School of Science, Kanagawa University

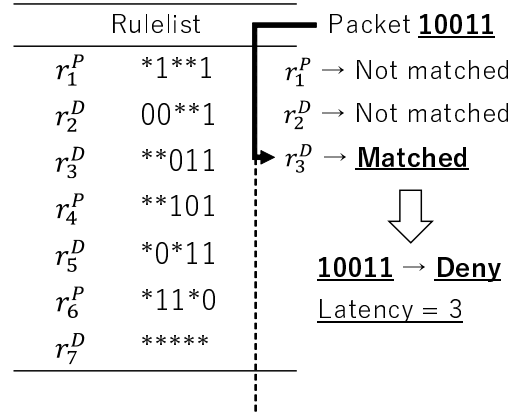


図 1 パケット分類の例

ケット 00101 に対する動作が *Permit* から *Deny* に変化し、元のルールリストと異なる動作を発生させるためである。これを回避するために、入力されたルールリストにより定められている分類ポリシーを保持しながらルールを並べ替えなければならない。これらに基づき、次の最適化問題を定義する。

定義 2 (ルール順序最適化問題)

入力 : ルールリスト R , 頻度分布 F
 出力 : ポリシーを保ち $L(R, F)$ を最小化する
 ルール順序 σ

また、ルールリストのポリシーを持つ並べ替えの制約条件は有向グラフとして表現できる。これを従属グラフと呼ぶ。例えば図 1 のルールリストの従属グラフは図 2 のように表される。




図 2 図 1 のルールリストの従属グラフ

3 既存の発見的解法

ルール順序最適化問題に対する発見的解法として、提案手法に関わる 2 つの手法について説明する。これらの手法は、従属グラフと、各ルールの合致パケット数を指標として整列済みリストを構築する。以降では、ルールの合致パケット数を重みと呼称する。

SGM (Sub Graph Merging) は、Tapdiya らによって提案された発見的解法である [2]。従属グラフの各ノードについて、そのノードから到達可能なノードの重みの平均を比較し、平均が最大となるノードを選択する。その後、そのノードを含まない到達可能ノードの集合に対して同様の操作を行う。これを繰り返し、ルールリストの上位にあるノードから 1 つずつ選択することで整列済みリストを構築する。この手法は、任意のルールリストに対して平均的に遅延を減少させることが知られている。

日景らによる手法は、SGM とは対称的にルールリストの下位から選択し整列済みリストを構築する [3]。従属グラフの各連結成分について重みと入次数が小さい順に整列し、入次数 0 のルールを含むルール集合を選択することで整列済みリストを構築する。SGM とは異なり、選択したルールを含む複数のルールを考慮することができるが利点である。

4 提案手法

SGM 及び日景法にはそれぞれに長所と短所が存在する。SGM は、到達可能なルールのみを考慮するため、その範囲に含まれないノードの重みが大きい場合に上位に配置できない場合がある。日景法は、ルール単体の重みで連結成分内の順序を決定するため、連結成分内の順序が最適とならない場合があり、重みの大きいルールを上位に配置できる場合を網羅しきれていない。

それぞれの手法の短所はもう一方の手法の長所によって補うことができる場合が存在すると考えられる。そこで、2 手法を組み合わせた並べ替え法を提案する。任意の従属グラフについて組み合わせ比率と手法の適用順序を決定する発見的解法を考案することは容易ではないため、これを機械学習により代替することで実現する。

Deep Q Network[4] を採用し、深層強化学習によりルール順序最適化問題の解を導出する。概略を図 3 に示す。従属グラフを環境に設定し、グラフからルールを順番に取り出し整列済みリストを構築する。ここで、行動として SGM 及び日景法を選択する戦略をとり、2 つの手法の問題点を補い合うような並べ替え方法を学習する。

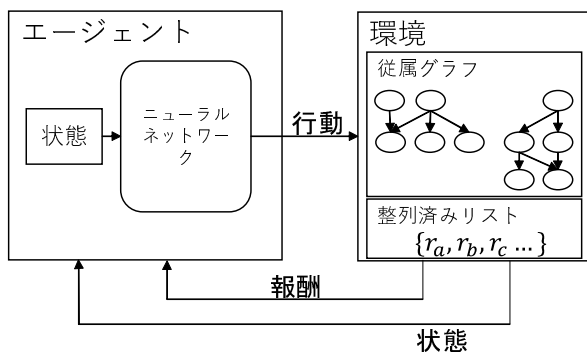


図 3 学習全体の概略

5 評価実験

パケット分類のベンチマークツール Classbench[5] を用いてルール数 500 前後のルールリストとパケット集合を 15 サンプル生成し、SGM、日景法、提案手法のそれぞれで並べ替えた後の遅延を比較する。その結果を表 1 に示す。7 つのサンプルにおいて、太字で示しているように既存手法より遅延の小さなルール順序を求めることができた。特に、SGM と比較し最大で 25% 程度遅延を削減した例が存在した。以上により、遅延を削減したサンプルが存在することから、機械学習がルール順序最適化問題においても有効に機能することが示された。

表 1 各ルールと並べ替え後の遅延 (照合回数)

SGM	Hikage	Proposed
44966	82484	32115
94063	218096	120737
49738	218096	71429
68830	121637	80247
36013	35828	35828
138526	220874	142038
53908	328786	67606
144335	169969	131964
138916	267803	145300
153369	343844	152743
74069	91723	65413
102143	115719	98384
90685	125387	93951
82584	93487	83510
112268	136003	98443

6 おわりに

本研究では、ルール順序最適化問題を解決する 1 つの手段として、深層強化学習を活用し 2 つの発見的解法を使い分ける並べ替え手法を提案し、ルール順序最適化問題に対しても機械学習が有効に機能することを確認した。今後の課題は、より遅延を削減する確率が高くなるように学習を安定化させることと、大規模ルールリストの並べ替えを想定した学習環境の構築である。

参考文献

- [1] Eric Liang, Hang Zhu, Xin Jin, and Ion Stoica. Neural packet classification. In *Proceedings of the ACM Special Interest Group on Data Communication*, pp. 256–269. Association for Computing Machinery, 2019.
- [2] Ashish Tapdiya and Errin W Fulp. Towards optimal firewall rule ordering utilizing directed acyclical graphs. In *2009 Proceedings of 18th International Conference on Computer Communications and Networks*, pp. 1–6. IEEE, 2009.
- [3] 日景喬一, 山田敏規. ルール間の依存関係を保持したファイアウォールの負荷最小化のためのアルゴリズム. In *IEICE Conferences Archives*. The Institute of Electronics, Information and Communication Engineers, 2016.
- [4] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A Rusu, Joel Veness, Marc G Bellemare, Alex Graves, Martin Riedmiller, Andreas K Fidjeland, Georg Ostrovski, et al. Human-level control through deep reinforcement learning. *nature*, Vol. 518, No. 7540, pp. 529–533, 2015.
- [5] David E Taylor and Jonathan S Turner. Classbench: A packet classification benchmark. *IEEE/ACM transactions on networking*, Vol. 15, No. 3, pp. 499–511, 2007.