

光学レイヤ特性に基づく広域光ネットワークの停止予測

Outage Prediction for Wide-area Optical Network Based on Optical Layer Characteristics

長谷川 陽平[†] 内田 真人[†]
Yohei Hasegawa Masato Uchida

1. はじめに

インターネットサービスプロバイダーやクラウドプロバイダーの中核を支える光バックボーンネットワークはますます広域化し、その上で提供されるサービスは社会に深く浸透している。そのため、広域光バックボーンネットワークをいかに効率良く管理・保守し、その信頼性や可用性を高く維持するかが重要な課題となっている。

Ghobadi ら [1] は、IP 層では観測できない、物理層で観測される光信号品質の瞬間的な降下が、ネットワーク停止の予測因子になると示唆している。実際、光信号品質の瞬間降下が起こると、1 時間以内の停止確率が 50%、1 日以内の停止確率が 70% になることが示されている。しかし、この分析は、光信号品質の瞬間降下イベントが発生した回数とそれに対するネットワーク停止の回数から、比率を単純に算出したのみであり、初等的な分析である。また、光信号品質の瞬間降下イベントに基づいた実際のネットワーク停止予測をおこなっていない。

そこで本論文では、文献[1] の分析結果を踏まえ、光信号品質の瞬間降下イベントに基づいてネットワーク停止の予測をおこなう手法を提案する。提案手法ではまず、瞬間降下イベントの時系列データから、光信号品質およびそれ以外の光学レイヤ特性の特徴量を抽出する。そして、瞬間降下イベントに対するネットワーク停止の有無の 2 クラス分類問題と考へ、抽出した特徴量を用いた機械学習によりネットワーク停止の予測をおこなう。実データを用いた評価実験では、特徴量の抽出方法の差異および光信号品質以外の光学レイヤ特性の有無による比較をおこない、提案手法の有効性を確かめる。

2. 関連研究

通信ネットワークの信頼性や可用性については、これまでに様々な研究 [1-12] がおこなわれてきた。これらの研究は、分析の対象とするネットワークの種類や分析をおこなう際の観点が異なる。

分析対象とするネットワークに特徴のある研究としては文献 [2], [3], [4] がある。Choi ら [2] は、大学キャンパスネットワークにおける障害について分析した。この分析では、ネットワーク停止・障害イベントの空間的および時間的特徴、リンク障害とノード障害の関連、ネットワークアーキテクチャによる影響に注目している。Gill ら [3] は、データセンターにおけるネットワーク障害を大規模に分析した。これにより、ロードバランスが多くのソフトウェア障害に関連することや、ネットワークの冗長性のみでは障害によるパケットロスの影響軽減を示した。Miao ら [4] は、

大規模なワイヤレスセンサーネットワークにおける障害について分析した。各センサーノードにおける評価指標の相関グラフを求め、正常なノードと異常なノードの相関グラフの特徴を比較した。これにより、システムのパフォーマンス低下を捕捉し、潜在的な障害を検出できることを示した。Govindan ら [5] は、Google 社のネットワークで起きた障害について、継続時間や規模、発生したネットワークの部位などの障害の特徴を定量的に分析した。さらに、障害事例を根本的な原因によって分類した。これらの結果を踏まえて、それぞれの障害の事例のカテゴリごとにネットワークの可用性を向上させるための議論をおこない、これを実現するための設計原理を提案した。

通信障害における依存関係に注目した研究としては文献 [6], [7], [8] がある。Markopoulou ら [6] は、IP リンク障害を IP レイヤにおけるパターンにより分類し、それぞれの特徴について分析をおこなった。Gonzalez ら [7] は、IP バックボーンネットワークにおける障害の依存関係について分析し、地理的距離が大きな影響を及ぼすことを示した。Neumayer ら [8] は、通信ネットワークにおいて、災害に対する地理的な脆弱性を評価した。通信ネットワークの構造と障害によるリンク切断をモデル化し、ネットワークに最も大きな影響を与える場合のリンク切断を求められることを示した。Ghobadi ら [1] は、広域光バックボーンネットワークにおける光学レイヤ特性に注目し、ネットワーク障害との関連について分析した。曜日や時間帯によるネットワーク停止が発生する割合の傾向や、光信号品質の瞬間降下がネットワーク停止確率の増大につながることを示した。

通信装置に着目した研究としては、文献[9], [10] がある。Lucie ら [9] は、149,560 個のルーターを 2 年半にわたり大規模に調査した。ルーターの停止とネットワークの回復力の関連性について分析した。Giotsas ら [10] は、コロケーション施設やインターネットエクスチェンジポイント (IXP) のようなピアリングインフラストラクチャーの停止を検出するシステムを提案した。BGP の経路情報に着目して、停止が発生しているインフラストラクチャーの特定を高精度で実現できることを示した。これに加えて、停止が発生した場合のネットワークへの影響についても分析されている。

その他にも、ネットワーク種別ごとの通信障害の特徴の違いに着目した研究がある。Uchida [11] は、日本国内において発生した法令上の重大な電気通信事故の発生間隔、継続時間と影響を受けたユーザー数について統計的特徴の分析をネットワーク種別ごとにおこなった。

以上のように、通信障害に関する研究は様々であるが、物理レイヤの光学特性と障害の関連性に注目した研究は著者らの知る限り [1] のみである。

3. 文献[1]の概要

本論文において注目する文献 [1] の概要を述べる。まず、3.1 節では用いられたデータセットについて説明し、3.2 節

[†] 早稲田大学大学院基幹理工学研究科 情報理工・情報通信専攻 Department of Computer Science and Communications Engineering, School of Fundamental Science and Engineering, Waseda University, Tokyo, Japan.

では文献 [1] におけるネットワーク障害の分析について述べる。3.3 節では、光信号品質の瞬間降下イベントについて説明し、3.4 節では文献 [1] における課題と問題点について議論する。

3.1 データセット

文献 [1] では、Microsoft 社が所有する北米の光バックボーンネットワークにおいて、2015 年 2 月から 2016 年 4 月までの 14 ヶ月で取得された光学レイヤ特性のデータに基づいて分析されている。このバックボーンは、約 50 個の光クロスコネクタ、約 100 個の WAN セグメント、および約 1000 個の光チャンネルで構成されている。機密管理の都合上、光クロスコネクタ、セグメントおよびチャンネルの正確な数は公開されていない。

光信号品質の指標として、Q 値が用いられている。Q 値は、信号と雑音の振幅比であり、次式のように定義される [1]。

$$Q = \frac{|\mu_1 - \mu_0|}{\sigma_1 + \sigma_2} \quad (1)$$

ここで、 μ_1 、 μ_0 はそれぞれ 1、0 を表す信号の振幅レベルであり、 σ_1 、 σ_0 はこれらの分散である。Q 値は、値が大きくなるほどよい状態であることを示し、ビット誤り率が低下する。文献 [1] では、毎秒測定された Q 値の 15 分間の平均値を用いている。

3.2 分析内容

文献 [1] では、広域光バックボーンネットワークにおける光学レイヤ特性とネットワーク障害の関連性について分析している。この研究では、大きく分けて 4 つの分析をおこなっている。

1 つ目は、可用性と修復時間に関する分析であり、チャンネルごとの障害の傾向およびその違いについて示されている。2 つ目はセグメント停止の方向対称性に関する分析である。セグメントは 2 つのノード間それぞれの方向につき 1 つずつ存在する。双方向停止した場合は、光ファイバの断線など両者に影響を及ぼす事象が原因である。片方向の場合は、送信機などそれぞれのハードウェアの問題である。セグメント停止の双方向性について分析することで、発生する障害の傾向を示した。3 つ目は時刻依存性に関する分析で、曜日や時間に対するネットワーク停止の傾向が示されている。4 つ目は、ネットワーク停止予測である。IP レイヤでは観測できない、光信号品質 (Q 値) の急激な低下として定義された Q-drop イベントが起こると、ネットワーク停止確率が上昇することから、重要な予測因子となるということが述べられている。これらの分析に加えて、Q-drop イベントはネットワークルーティングに応用できるとしている。Q-drop イベントを監視することで各リンクの停止リスクを計算し、故障確率が高いリンクを避けてルーティングをおこなうことができると述べられている。

3.3 Q-drop イベント

文献 [1] において分析された Q-drop イベントと停止確率の関連に注目する。文献 [1] では、分析対象である 100Gbps QPSK における Q-drop イベントの定義を、Q 値が 6.5 以上

で“安定した値から低下した事象 (when the Q-factor value drops from its stable value)”としている。Q-drop イベントが発生しているチャンネルは利用可能であり、IP レイヤにおける劣化は観測されていない。文献 [1] では、任意の期間における停止率 $P(\text{outage})$ 、Q-drop イベント発生後の停止率 $P(\text{outage given Q-drop})$ とネットワーク停止イベント発生後の停止率 $P(\text{outage given outage})$ を求めている。ここでは、メンテナンスによる計画的なネットワーク停止と障害による突発的な停止を区別してない。観測期間が長くなればなるほど、その観測期間内の停止確率は上昇している。ネットワーク停止イベント発生後の停止率 $P(\text{outage given outage})$ は、通常の停止率 $P(\text{outage})$ と比べて上昇の度合いは緩やかである (文献 [1] の Figure 8 を参照)。このことから、個々の停止は独立であり、お互いに予測因子にならないとされている。一方で、7 日間以内では、通常の停止確率が 12% であるが、Q-drop イベントが発生すると 70% に上昇する。したがって、Q-drop イベントは、ネットワーク停止イベントに対して大きな予測因子であるとされている。

3.4 課題

文献 [1] では、発生した Q-drop イベントに対してネットワーク停止が起こる確率が求められている。Q-drop イベントが発生していない状態と比較して、ネットワーク停止確率が上昇しているため、予測因子として用いることができるとされている。しかし、この Q-drop イベントに基づいた実際のネットワーク停止予測は、文献 [1] ではおこなわれていない。また、Q-drop イベント発生後のネットワーク停止確率は、1 時間以内で 50%、1 日以内で 68%、7 日以内で 70% となっている。しかし、見方を変えれば、Q-drop イベントが発生したすべての場合においてネットワーク停止が起こると予測した場合、それぞれ 50%、32%、30% で実際には停止しないにも関わらず停止すると予測してしまう (False Positive が発生する) ことになる。

4. 提案手法

本論文では、広域光バックボーンネットワークにおける IP レイヤでは観測できないネットワーク特性の変化として光学レイヤ特性に着目する。特に、光信号品質の指標となる Q 値の瞬間的な降下である Q-drop イベントに基づいた機械学習によるネットワーク停止の予測手法を提案する。

4.1 Q-drop イベントの定義と抽出

文献 [1] では、Q-drop イベントの定義を、Q 値が 6.5 以上で“安定した値から低下した事象 (when the Q-factor value drops from its stable value)”としていた。しかし、これ以上の具体的な言及はない。Q-drop イベントを抽出する上では、イベント発生とみならず条件を明確に設定する必要がある。以下では本論文における Q-drop イベントの定義を与える。

Q-drop イベントは、Q 値の瞬間的かつ急激な低下 (sudden drops) である。平常時の Q 値は大きな値の変化は見られず、ほぼ一定の値で推移する。このことから、平常値と Q-drop イベント発生時との間に閾値を設定することで判別することが自然であると考えられる。しかし、Q 値の安定値は時間とチャンネルにより異なるため、異常値の閾値や平常値の指標を固定値とすることは適切でない。そこで本論文では、次式のように Q-drop イベント発生条件を定義する。

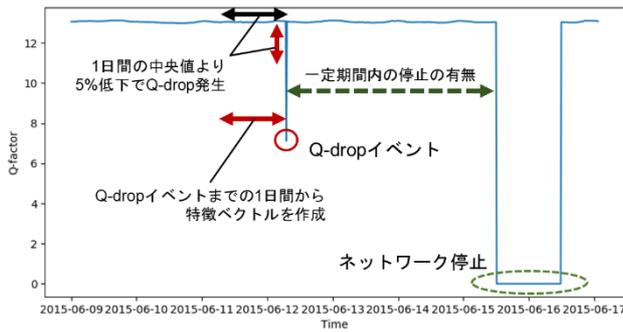


図1 Q-drop イベントの例

$$\frac{q_{ch,t}}{\text{median}(q_{ch,t-95}, \dots, q_{ch,t-1}, q_{ch,t})} < 0.95 \quad (2)$$

ここで、 $q_{ch,t}$ はチャンネル ch の時刻 t におけるQ値である。また、 $\text{median}()$ は括弧内に列挙された数値の中央値である。本論文で扱う光学レイヤ特性のデータは15分ごとの平均値として得られるため、タイムスタンプは15分ごとに1加算される。つまり、式(2)の分母は時刻 t を含む過去1日間のQ値の中央値を意味する。式(2)を満足する時刻 t をQ-dropイベントの発生時刻とする。式(2)は、過去1日間のQ値の中央値を平常値の指標としたときに、注目時点におけるQ値 $q_{ch,t}$ をこの平常値で正規化した値が0.95を下回った場合、すなわち、 $q_{ch,t}$ が平常値の95%を下回った場合にQ-dropイベント発生とみなすことを意味する。Q-dropイベントが発生していない場合は、正規化された値は1.0に近い値をとることが期待される。

Q値の安定値の指標として、平均値ではなく中央値を用いる理由は2点ある。1点目は、平均値を取った場合、Q-dropイベント発生時における大きな変動に影響されてしまい、意図した安定値が得られない場合があるためである。2点目は、短期間の中での平常時のQ値のゆらぎは微小であり、ほぼ一定の値をとるデータが大半を占めているためである。

上述の定義に従い、各チャンネルからQ-dropイベントを切り出す(図1)。具体的には、Q-dropイベント終了時から24時間前までの時系列データを切り出す。24時間前までのデータも含めることで、Q-dropイベント発生中の異常値だけでなく、通常時の光学レイヤ特性の特徴を得ることができる。通常時の特性と比較することで、異常な値がどれだけ平常時と離れているかの指標とすることができる。

4.2 特徴ベクトルへの作成とラベルの付与

光学レイヤ特性のデータはチャンネルごとに15分間隔で得られるため、データ数は1日分で96個となる。取得できる光学レイヤ特性の種類は、Q値、送信パワー、波長分散、偏波モード分散の4つである。したがって、1つのQ-dropイベントは、 $96 \times 4 = 384$ 次元のデータとして表現される。しかし、このままの表現ではデータ次元数が大きすぎるため、機械学習への入力としては適さない。そこで、代表値とその正規化(標準化)を用いて特徴ベクトルを作成する。

まず、Q値、送信パワー、波長分散、偏波モード分散に対して、Q-dropイベント発生までの1日間の最大値と最小

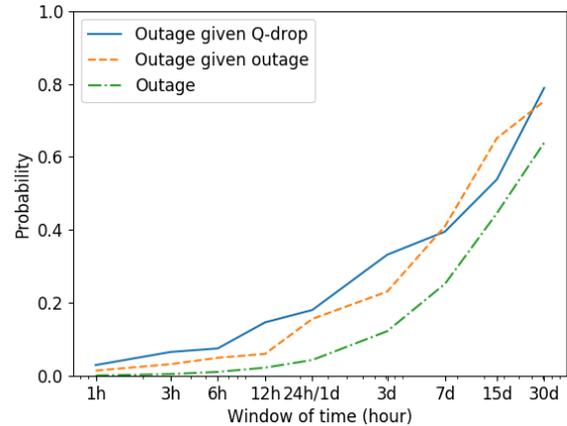


図2 各イベントに対するネットワーク停止確率

値を取る。そして、ここで得られた最大値および最小値に対して、中央値を基準とした標準化を施す。通常、データ X に含まれる i 番目の要素 x_i に対して通常の標準化された値 z_i は、データ X の平均 μ と標準偏差 σ を用いて、

$$z_i = \frac{x_i - \mu}{\sigma} \quad (3)$$

と表される(Z-score)。しかし、上述したように、はずれ値による影響を防ぐため、本論文では平均値ではなく中央値を基準にする。すなわち、中央値からの標準偏差 σ_{med} を用いて、 x_i の標準化後の値 m_i を次のように定義する。

$$m_i = \frac{x_i - \text{median}(X)}{\sigma_{\text{med}}} \quad (4)$$

さらに、Q-dropイベントの継続時間[分]を特徴量の1つとして用いる。抽出した時系列データの中で、Q値が式(2)を満たしていた時間、すなわち1日間の中央値の95%を下回っていた時間をQ-dropイベントの継続時間とみなし、これを特徴量とする。以上より、4つの光学特性の正規化された最大値と最小値と継続時間により9次元の特徴ベクトルが作成される。

得られたQ-dropイベント特徴ベクトルに対してラベリングをおこなう。一定の期間内にネットワーク停止があった場合は1、停止がなかった場合は0とする。すなわち、Q-dropイベントに対して、停止あり・なしの2クラス分類問題と考える。ラベリングした特徴ベクトルを、機械学習アルゴリズムを用いて分類することで、発生したQ-dropイベントに対してネットワーク停止が起こるか否かを予測する。

5. 評価実験および考察

提案手法の有効性を、実データを用いて評価する。Q-dropイベントから抽出した特徴ベクトルを用いた機械学習アルゴリズムによってネットワーク停止を予測した場合の性能が、特徴ベクトルを作成するために用いた光学レイヤ特性や、特徴ベクトルの作成方法にどのように影響されるかを確認する。

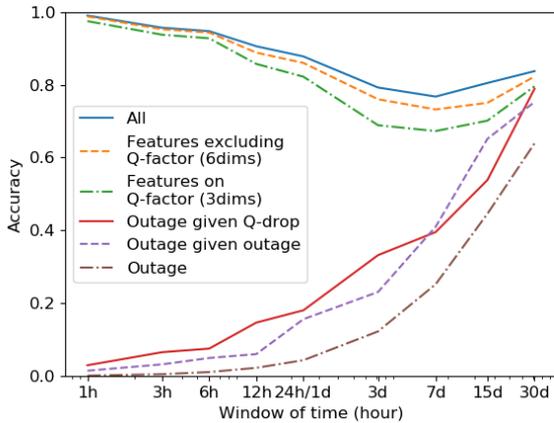


図 3 正解率 (光学レイヤ特性による比較)

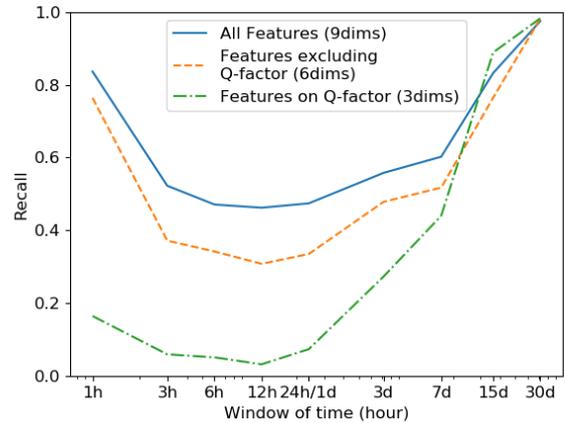


図 5 再現率 (光学レイヤ特性による比較)

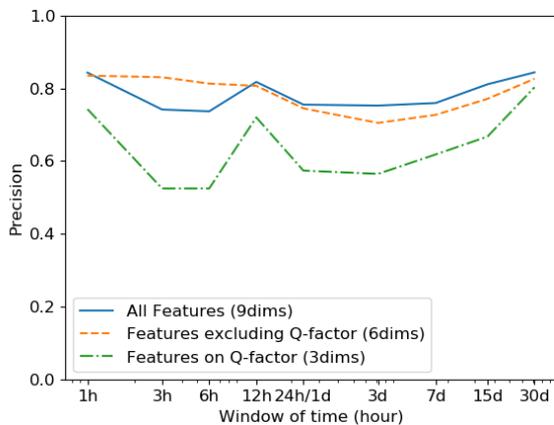


図 4 適合率 (光学レイヤ特性による比較)

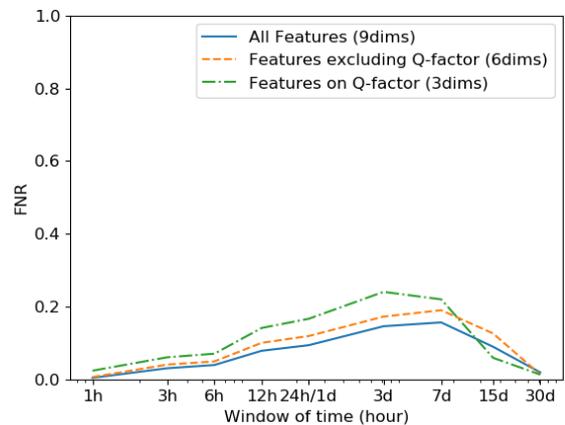


図 6 偽陰性率 (光学レイヤ特性による比較)

5.1 データセットと文献[1]の再現実験

文献 [1] で用いられたデータのうち、無作為に選ばれた 115 セグメントにわたる 4000 チャンネルのデータが公開されている[12]. 各セグメントには、10~200のチャンネルが含まれている. このデータセットでは、2015 年 2 月から 2016 年 4 月までの 14 ヶ月の測定期間において、15 分ごとに Q 値、送信パワー、波長分散、偏波モード分散 (の平均値) が与えられる. 本論文では、文献 [1] とほぼ同様の条件で評価を行うために、[12] のデータセットを用いた.

[12] のデータセットの妥当性を確かめるために、文献 [1] におけるネットワーク停止確率の再現実験をおこなった. Q-drop イベント発生後、ネットワーク停止発生後、平常時における 1 時間以内から 30 日以内にかけての停止確率を図 2 に示す. Q-drop イベント発生後の確率は、本論文における独自の定義を用いているため、文献[1] で示されたグラフ (Figure 8) とは詳細な形状は異なっている. しかしながら、ネットワーク停止後の停止確率と平常時の停止確率はほぼ一致しており、定性的には同様の結果が得られている.

5.2 評価方法

本論文では、Q-drop イベントから作成した特徴ベクトルを、一定期間内におけるネットワーク停止の有無による 2

クラス分類問題と考える. 評価実験では、2 クラス分類をおこなう機械学習アルゴリズムとして、SVC (Support Vector machine Classification) を用いる. また、テスト方法として、 K 分割交差検証を用いる. すなわち、データをランダムに K 個のグループに分割し、1 つをテストデータ、そのほかのグループを学習データとしてテストをおこなう. そして、これをすべてのグループがテストデータを 1 度ずつ経験するように繰り返す. 本実験では、分割数が多すぎる場合にはテストデータ数が少なくなってしまうことを考慮し $K=5$ とした. テストにより得られる評価指標は、5 回のテストの平均を取るものとする. データの分割と繰り返しにより、テストデータおよび学習データの偏りを防ぐ.

予測結果と実際のラベルに対して正解率 (Accuracy)、適合率 (Precision)、再現率 (Recall)、偽陰性率 (FNR: False Negative Rate) を算出して比較する. 正解率は、Q-drop イベント発生後、停止発生後および通常時における停止確率、Q-drop イベント発生後における非停止確率とも比較し、本論文における提案手法の有効性について検討する. 適合率は、ネットワークが停止すると予測した事例のうち、実際に停止する割合を示す. 再現率は、停止する事例のうち、停止すると予測することができた事例の割合を示す. 偽陰性率は、停止する事例を停止しないと予測してしまった事例の割合を示す. これらの指標を比較することで、提

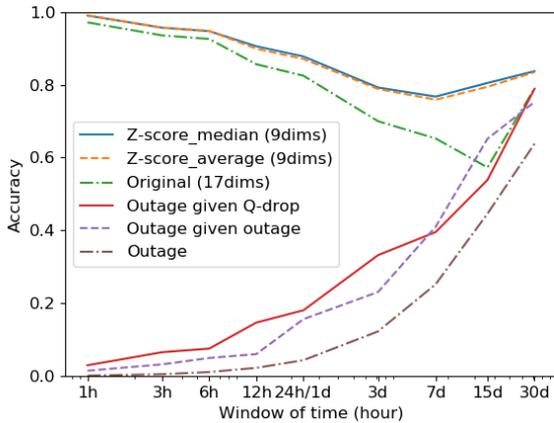


図 7 正解率 (特徴抽出方法による比較)

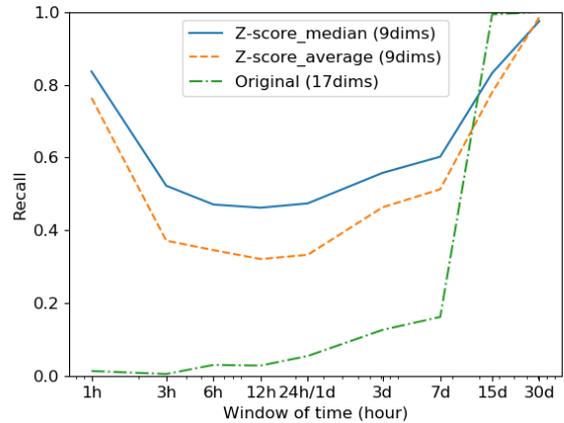


図 9 再現率 (特徴抽出方法による比較)

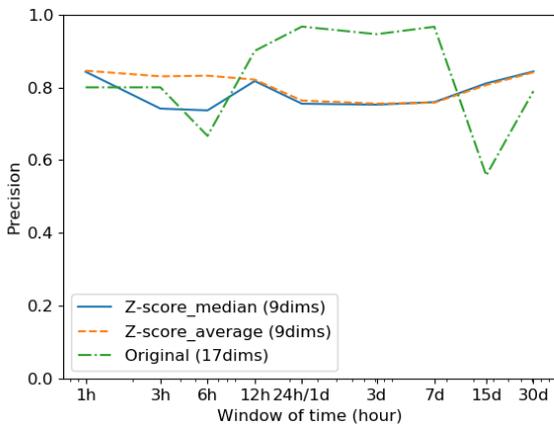


図 8 適合率 (特徴抽出方法による比較)

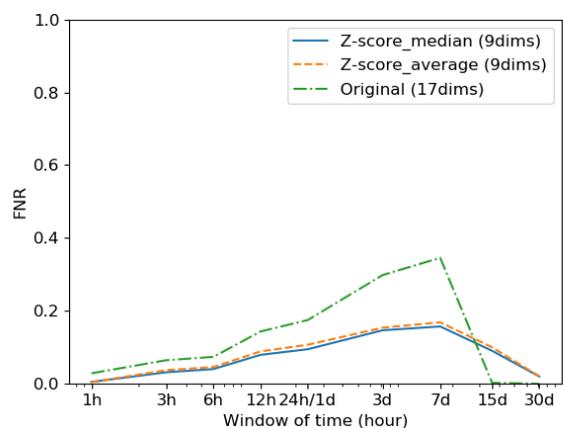


図 10 偽陰性率 (特徴抽出方法による比較)

案手法の有効性を確認する。

5.3 実験結果

5.3.1 光学レイヤ特性の比較

まず、ネットワーク停止予測における光学レイヤ特性の貢献度に注目する。本論文では、文献 [1] とは異なり、Q 値以外の光学レイヤ特性を用いて特徴ベクトルを定義している。そこで、すべての光学レイヤ特性による 9 次元の特徴ベクトルを用いた場合「All Features (9 dims)」、Q 値のみに関する 3 次元の特徴ベクトルを用いた場合「Features on Q-factor (3 dims)」（ただし、Q-drop イベント継続時間を含む）、Q 値以外の光学レイヤ特性による 6 次元の特徴ベクトルを用いた場合「Features excluding Q-factor (6 dims)」について予測性能を比較した。なお、各光学レイヤ特性の特徴は、式(4)を用いて標準化されている。各特徴ベクトルを用いたときの正解率、適合率、再現率、偽陰性率をそれぞれ図 3~6 に示す。

使用した特徴ベクトル毎の正解率を図 3 に示す。本図には図 2 に示した結果を再掲している。本図より、どの特徴ベクトルを用いた場合であっても、提案手法により達成される正解率は、Q-drop イベント発生後にネットワーク停止が起こる確率よりも高い。これは、Q-drop イベントの発生後に必ずネットワーク停止が発生すると断定するよりも、

提案手法によりネットワーク停止を予測した方が正確であるということを示している。

また、すべての特徴ベクトルおよび評価指標共通 (図 3~6) の特徴として、イベント発生からの期間が短い 1 時間から 7 日間に向けて正答率が減少している。このため、提案手法は短期間における予測において特に効果的であるといえる。一方で、15 日以上将来における正解率が向上している。これは、15 日以内および 30 日内の再現率 (図 5) と偽陰性率 (図 6) が向上していることから、Q-drop イベントに対するネットワーク停止が発生する事例数が増大したためであると考えられる。この場合、各特徴ベクトル間の性能差は小さくなっており、Q 値とそのほかの光学レイヤ特性の間でネットワーク停止の予測のしやすさの大きな違いは見られない。また、評価期間全体を通して「Features on Q-factor」よりも、「All Features」および「Features excluding Q-factor」の方が、各評価指標が優れている。これは、Q 値のみに関する 3 次元の特徴ベクトルを用いるのではなく、Q 値以外の光学レイヤ特性に関する特徴ベクトルも用いた方が、ネットワーク停止の予測精度を向上する上で有効であるということを示している。

図 4 に示した適合率に関する各特徴ベクトルの特性を比較すると、3 時間以内および 6 時間以内において「All Features」が「Features excluding Q-factor」よりも低い値を示している。「Features on Q-factor」とグラフの概形を比較

すると、Q 値による精度低下に影響されているものと考えられる。しかし、再現率および偽陰性率は「All Features」が優れていることから、この 2 つの期間においても Q 値はネットワーク停止の発生事例の見逃しを防ぐことに貢献していると考えられる。また、そのほかの期間における適合率および再現率、偽陰性率は「All Features」が「Features excluding Q-factor」よりも優れた結果を示しており、すべての光学レイヤ特性を用いた方がネットワーク停止を正確に予測できるといえる。

5.3.2 特徴抽出法の比較

次に、特徴ベクトルの作成手法に注目する。提案手法では、各光学レイヤ特性に対して、中央値を基準とした標準化をおこなう。これにより作成した特徴ベクトルを用いた場合を「Z-score_median (9dims)」とする。また、標準化をおこなわず、光学レイヤ特性の最大値、最小値、中央値、(中央値を基準にした)標準偏差をそのまま用いて特徴ベクトルを作成した場合を「original (17dims)」とする。そして、「Z-score_median」と「original」を比較することで、標準化の有効性を確かめる。さらに、平均値を基準とした通常の標準化により特徴ベクトルを作成した場合を「Z-score_average (9dims)」とする。そして、「Z-score_median」と「Z-score_average」を比較することで、中央値を基準とした標準化の有効性を確かめる。各特徴ベクトルの正解率、適合率、再現率、偽陰性率をそれぞれ図 7~10 に示す。

正解率に注目すると、全ての期間において、「original」に比べて標準化した 2 つの特徴ベクトルを用いた場合の方が適切にネットワーク停止を判別することができていることがわかる。一方で、適合率に関しては「original」の方が優れている期間 (12 時間から 15 日間) が存在する。しかし、それと同じ期間の偽陰性率に関しては「original」の方が劣っている。また、再現率に関しても「original」の方が優れている期間 (15 日間以降) が存在する。しかしこの場合も、同じ期間における適合率と偽陰性率に関しては「original」の方が劣っている。以上より、全ての期間において、標準化を施した方が正解率を向上でき、バランスの良いネットワーク停止予測が可能になったものと考えられる。

次に、中央値を基準に標準化した特徴ベクトルを用いた場合「Z-score_median」と平均値を基準に標準化した特徴ベクトルを用いた場合「Z-score_average」を比較する。両者の正解率と偽陰性率は同等程度となっている。適合率については、3 時間から 6 時間の期間において「Z-score_average」の方が優れているが、「Z-score_median」の性能も十分に高いといえる。再現率については全ての期間において「Z-score_median」の方が優れている。以上より、中央値を基準に標準化した特徴ベクトルを用いることの有効性が確認された。

6. まとめ

本論文では、Q-drop イベントとそれ以外の光学レイヤ特性の時系列データに基づいて広域光ネットワークの停止予測を行う手法を提案した。この提案手法では、Q-drop イベントの継続時間と、イベント発生までの 1 日間の時系列データにおける各光学レイヤ特性の代表値を特徴として用いた。評価実験では、Q 値以外の光学レイヤ特性においてもネットワーク停止予測に関連性があることが示された。ま

た、ネットワーク停止予測を向上する上では、時系列データの標準化の方法が重要であることが確かめられた。

本論文では、Q 値とその他の光学レイヤ特性に分けて比較検討をおこなったが、Q 値以外のどの特性が分類器の性能に貢献しているかは分析できていない。さらに、特徴抽出の方法については議論をしたが、どの特徴が強く作用しているかは分析できていない。したがって、より細かな影響力分析を進めることが今後の課題である。また、本論文における評価実験では SVM を用いたが、そのほかの機械学習アルゴリズムを用いた場合の比較検討が必要である。

謝辞

本研究の一部は、日本学術振興会における科学研究費補助金基盤研究(C)(課題番号 17K00135)による支援を受けている。ここに記し謝意を表す。

参考文献

- [1] Monia Ghobadi and Ratul Mahajan, "Optical Layer Failures in a Large Backbone", 2016 Internet Measurement Conference, pp. 461-467 (2016).
- [2] Baek-Young Choi, Sejun Song, George Koffler and Deep Medhi, "Outage Analysis of a University Campus Network," 2007 16th International Conference on Computer Communications and Networks, Honolulu, HI, pp. 675-680 (2007).
- [3] Phillipa Gill, Navendu Jain and Nachiappan Nagappan, "Understanding Network Failures in Data Centers: Measurement, Analysis, and Implications," SIGCOMM, pp.350-361, (2011).
- [4] Xin Miao, Kebin Liu, Yuan He, Yunhao Liu and Dimitris Papadias, "Agnostic Diagnosis: Discovering Silent Failures in Wireless Sensor Networks," in IEEE Transactions on Wireless Communications, vol. 12, no. 12, pp. 6067-6075, (2013).
- [5] Ramesh Govindan, Ina Minei, Mahesh Kallahalla, Bikash Koley and Amin Vahdat, "Evolve or Die: High-Availability Design Principles Drawn from Google's Network Infrastructure," SIGCOMM, pp.58-72, (2016).
- [6] Athina Markopoulou, Gianluca Iannaccone, Supratil Bhattacharyya, Chen-Nee Chuah, Yashar Ganjali, Christophe Diot, "Characterization of Failures in an Operational IP Backbone Network", IEEE/ACM Transactions on Networking, vol. 16, no. 4, pp. 749-762 (2008).
- [7] Andres J. Gonzalez, Bjørn E. Helvik, Jon K. Hellan and Pirkko Kuusela, "Analysis of Dependencies between Failures in the UNINETT IP Backbone Network," 2010 IEEE 16th Pacific Rim International Symposium on Dependable Computing, Tokyo, pp. 149-156 (2010).
- [8] Sebastian Neumayer, Gil Zussman, Reuven Cohen and Eytan Modiano, "Assessing the Vulnerability of the Fiber Infrastructure to Disasters," in IEEE/ACM Transactions on Networking, vol. 19, no. 6, pp. 1610-1623, (2011).
- [9] Matthew Lucie and Robert Beverly, "The Impact of Router Outages on the AS-level Internet," SIGCOMM, pp.488-501, (2017).
- [10] Vasileios Giotsas, Christoph Dietzel, Georgios Smaragdakis, Anja Feldmann, Arthur Berger and Emile Aben, "Detecting Peering Infrastructure Outages in the Wild," SIGCOMM, pp.446-459, (2017).
- [11] Masato Uchida, "Statistical characteristics of serious network failures in Japan", Reliability Engineering & System Safety, Vol.131, (2014)
- [12] Microsoft, "Wide-Area Optical Backbone Performance", <https://www.microsoft.com/en-us/research/project/microsofts-wide-area-optical-backbone/> (2017).