

異常トラフィック検出アルゴリズムの 比較検証

廣川 裕
NTT情報流通プラットフォーム研究所

これからの流れ

- アルゴリズムへの要求(振り返り)
- 異常検知アルゴリズムいろいろ
 - 波形予測アルゴリズム
 - Holt-Winters法(HW:rrdtool)
 - Kalman-Hoffding アルゴリズム(KH:原田法)
 - 変化点検出アルゴリズム
 - Traffic Leap/sLump Detection アルゴリズム(TLD:廣川法)
- 各アルゴリズムの精度の比較
- まとめ



原田説明






廣川説明

異常検知アルゴリズム紹介

変化点検出アルゴリズム 「急激な変化を検出」

変化点検出アルゴリズム

トラヒックの波形が急激に変化するポイントを検出する




○: 検出ポイント

変化点検出アルゴリズム

Traffic Leap/sLump Detectionアルゴリズム (TLDアルゴリズム: 廣川法)

TLDアルゴリズムは総務省委託研究
「次世代バックボーンに関する研究開発」による成果である。

TLDアルゴリズム(廣川法)



トラヒックのグラフから昼夜変動を取り除き、
閾値による異常の検出を容易にする。

トラヒックの流量ではなく
直前の値との差分をグラフ化

正規化を行い、昼夜変動の
影響を更に取り除く


急激な変動があったタイミングでのみ
大きなパルスが現れる

TLDアルゴリズムの動作条件

アルゴリズムを動作させるために必要な設定.

•許容量の感度パラメータ

周期性を考慮しないため、保持するデータ数も少なく
短時間の学習期間で動作する。



メモ:

簡単な計算のみで動作
するため、計算処理は軽い。
トラヒック波形毎の設定が
無いため運用が楽。

各アルゴリズムの精度の比較

これまで紹介した異常検出アルゴリズムの精度を検証する

- ・ Holt-Winters法(HW)
- ・ Kalman-Hoffdingアルゴリズム(KH)
- ・ Traffic Leap/sLump Detectionアルゴリズム(TLD)
- ・ MFEEDツール(MF)

運用現場が望むツールの要件整理

ポイント	指標
検知精度	見逃しや誤検知回数の抑制
祝日の対応	カレンダーを用意しなくも動く？
深夜早朝帯の対応	トラフィックが底の時間帯も誤検知しない？
解析に必要なデータ数 (学習期間)	保持期間。より少ないデータで解析できる方が良い。
収束時の回復通知	事象発生時の通知だけでなく、回復時の連絡もできる？
パラメータ数	より簡単な設定で動くもの。

これらの要件に従って各アルゴリズムの比較検証を行う。

アルゴリズムの検証の方法


- ・ JPNAPで観測された**4種類**、**2ヶ月分**の**5分間隔で集計**されたトラヒックデータを使用。
- ・ オペレータの樽井さん、谷津さんを含めた発表者4人で協議し、**異常として検出したい箇所**の**正解リスト**を作成。
- ・ 検出したい箇所は4種のデータ2ヶ月分合わせて**24箇所**。

見逃し

-正解リストの中で検出できなかった箇所

誤検出

-正解リスト以外で検出された箇所



検証に用いた
トラヒックデータ

アルゴリズムの検証の方法

- ・ JPNAPで観測された**4種類**、**2ヶ月分**の**5分間隔**で集計されたトラフィックデータを使用。
- ・ オペレータの樽井さん、谷津さんを含めた発表者4人で協議し、**異常として検出したい箇所**の**正解リスト**を作成。
- ・ 検出したい箇所は4種のデータ2ヶ月分合わせて**24箇所**。

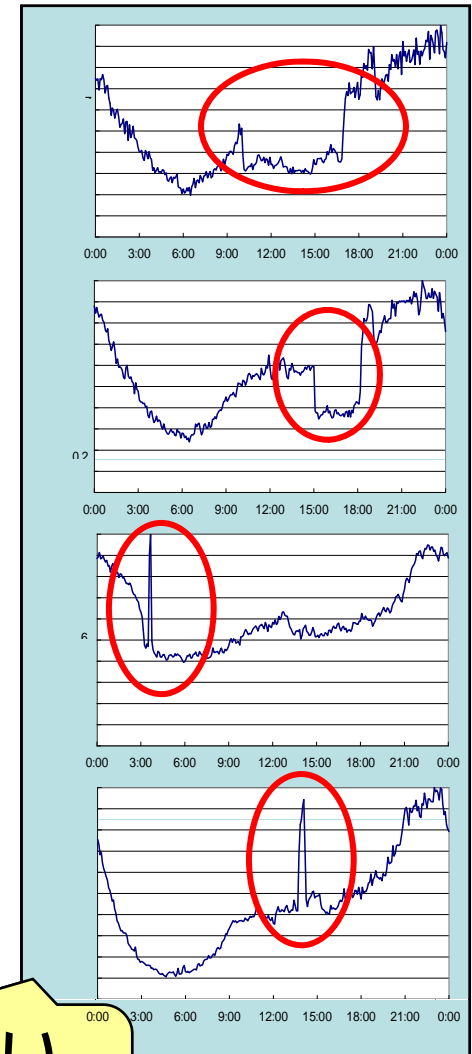
見逃し

-正解リストの中で検出できなかった箇所

誤検出

-正解リスト以外で検出された箇所


検出したい
箇所の例



検知精度の比較(1/2)

見逃し発生回数

多い ← → 少ない




データ	データA	データB	データC	データD
Holt-Winters法	3回/4箇所	2/14	0/1	0/5
KHアルゴリズム	1/4	2/14	0/1	0/5
TLDアルゴリズム	0/4	3/14	0/1	0/5
MFEEDツール	2/4	1/14	0/1	0/5

見逃しの発生回数については大きな差は無い。

検知精度の比較(2/2)

誤検出の発生率


多い ← → 少ない



データ	データA	データB	データC	データD
Holt-Winters法	0.78回/日	0.59	0.51	0.86
KHアルゴリズム	0.63	0.05	0.02	0.32
TLDアルゴリズム	2.14	0.17	0.07	0.64
MFEEDツール	0.44	0.15	0.00	0.05

- ・ HW法がやや誤検出が多い。
- ・ TLDアルゴリズムはデータAで特に誤検出が多く発生。

周期変動を誤検出 (TLDアルゴリズム固有の問題)



毎日**同じ時刻**に急変動が発生するトラフィックで発生

- TLDは周期性を考慮していない。
- これらの変動を全て検出してしまう。

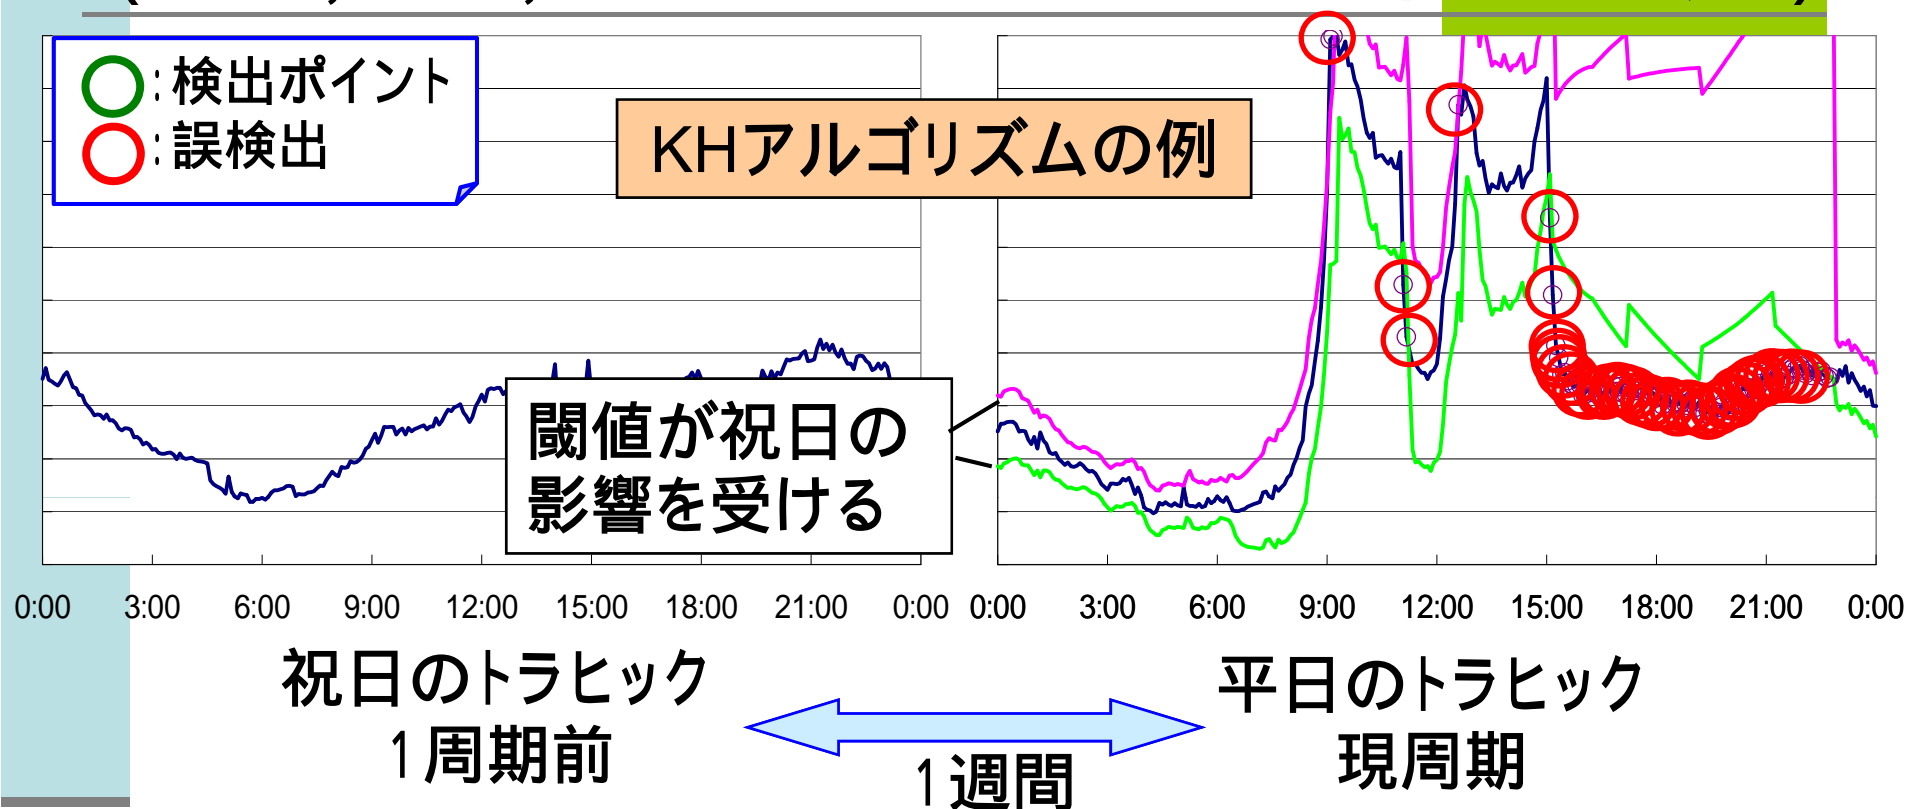
各アルゴリズムの比較

ポイント	HW	KH(原田)	TLD(廣川)	MF(樽井)
検知精度				

周期変動を誤検出

祝日による誤検出

(HW, KH, MFアルゴリズム固有の問題)



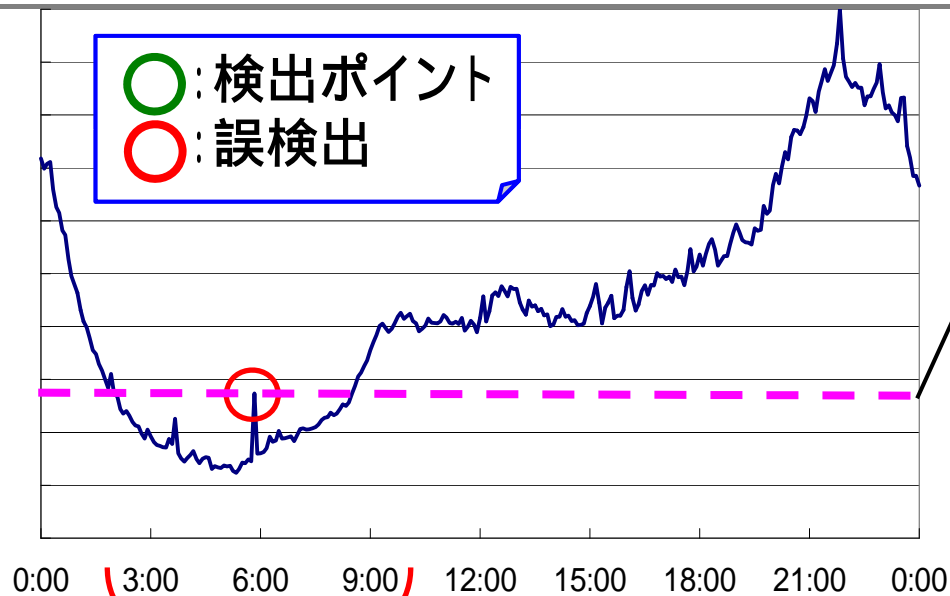
平日と休日・祝日で特徴が大きく異なるトラヒックで発生。
- 週変動を考慮したアルゴリズムでも、**祝日には対応できない。**

各アルゴリズムの比較

ポイント	HW	KH(原田)	TLD(廣川)	MF(樽井)
検知精度				
祝日の対応	×	×		×

祝日に対応していない

深夜早朝帯の誤検出 (全アルゴリズム共通の問題)



異常が検出されたが
流量は少ない

検出すべきか
意見が分かれる箇所

流量の減る時間帯

深夜から明け方にかけての時間帯は誤検出とした。


- アルゴリズム的には検出すべき。
- このトラヒック増加を検出してもオペレータは嬉しくないのか？

各アルゴリズムの比較

ポイント	HW	KH(原田)	TLD(廣川)	MF(樽井)
検知精度				
祝日の対応	×	×		×
深夜早朝帯の対応	×	×	×	×

どのアルゴリズムも
対応できていない

学習不足による誤検出 (HW, KHアルゴリズム固有の問題)



周期性を考慮したアルゴリズムは長い学習期間を要する。
-学習が不十分だと上図のように誤検出が発生する。

各アルゴリズムの比較

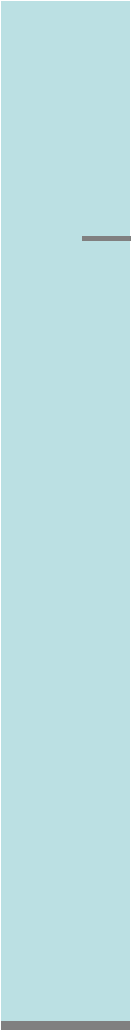
ポイント	HW	KH(原田)	TLD(廣川)	MF(樽井)
検知精度				
祝日の対応	×	×		×
深夜早朝帯の対応	×	×	×	×
解析に必要なデータ数 (学習期間)	×			

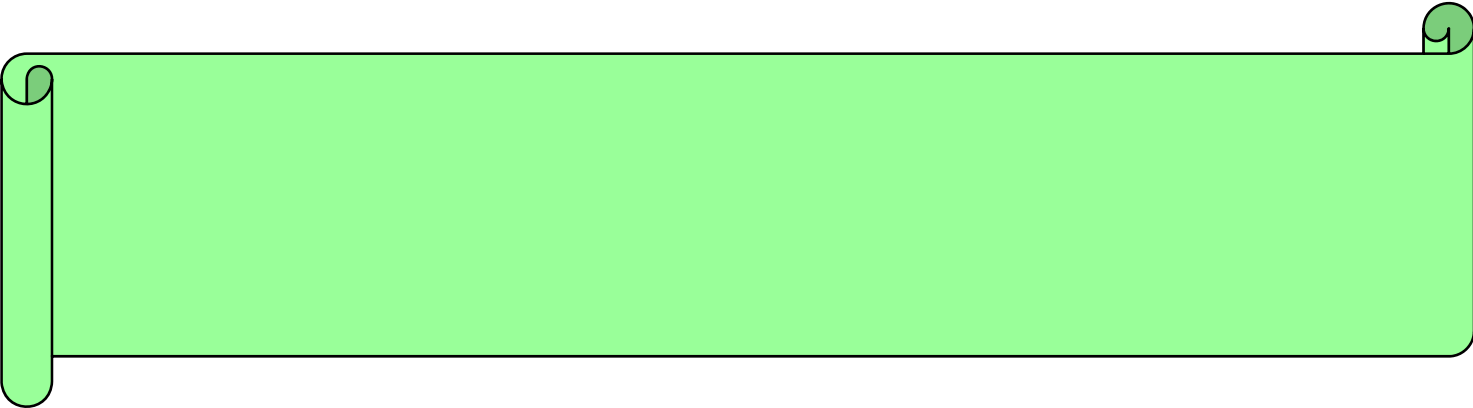
学習期間が必要
(KHの方が短い)

各アルゴリズムの比較

ポイント	HW	KH(原田)	TLD(廣川)	MF(樽井)
検知精度				
祝日の対応	×	×		×
深夜早朝帯の対応	×	×	×	×
解析に必要なデータ数 (学習期間)	×			
収束時の回復通知	×			×
パラメータ数	×			×

- ・ 回復通知はKH、TLDで部分的に実現。
- ・ KH、TLDはパラメータ設定の手間が少ない。





まとめ

まとめ

現状では全ての要件を満たすアルゴリズムは無い

アルゴリズムが検出する異常≠オペレータが思う異常

-深夜早朝帯のトラヒック増加は検出すべきか？

その他、精度以外にも考えることもある

-大量のトラヒックデータを監視する時

計算時間、必要とするメモリ量は大丈夫か？ etc.

今後の取り組み

KHアルゴリズム(原田法)

- ・トラヒック分割の箱長の自動調整法検討
- ・祝日トラヒックへの対応

TLDアルゴリズム(廣川法)

- ・周期的に発生する急変動の対応
- ・深夜早朝帯の誤検出への対応

おわり