



類似度に基づいた評価データの選別による マルウェア検知精度の向上

FFRI, Inc.
株式会社 **FFRI**
<http://www.ffri.jp>

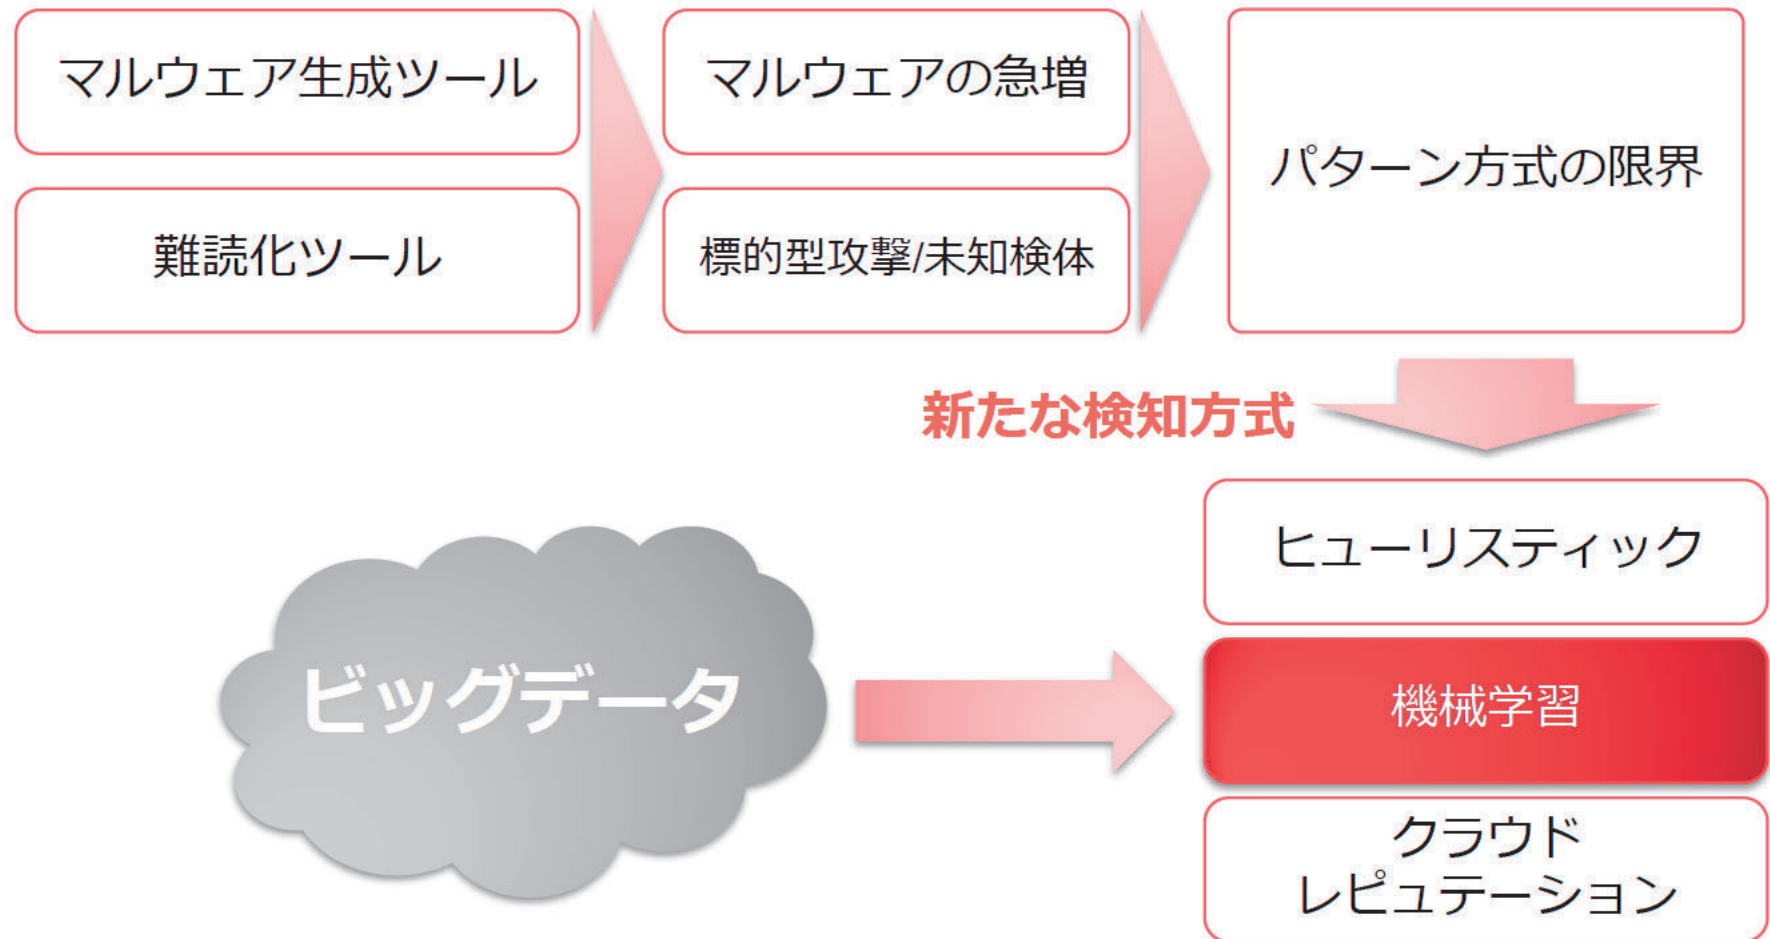
はじめに

- このスライドは CSS/MWS 2013 の発表資料です
 - <http://www.iwsec.org/css/2013/english/index.html>
- 詳細なデータについては、元の論文を参照ください
 - http://www.ffri.jp/assets/files/research/research_papers/MWS2013_paper.pdf
- 質問、コメント等は下記までお願いします
 - research-feedback@ffri.jp

アジェンダ

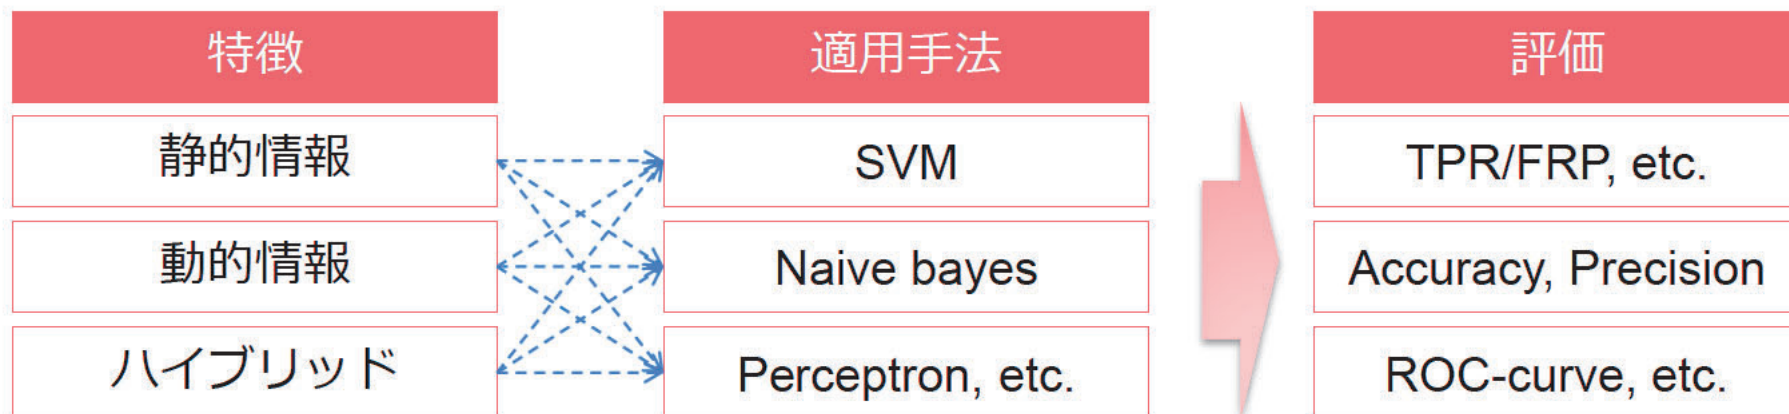
- 背景
- 課題
- 本研究の目的
- 実験1
- 実験2
- 実験3
- 考察
- まとめ

背景 - マルウェア及び対策技術の現状





背景 – 関連研究の概観

- 下記要素の組み合わせ、工夫が中心
 - 採用する特徴、特徴の加工方法、各種パラメーター設定等
- TPR90%超, FPR1%未満等、比較的良好な結果も



課題

- 機械学習一般において
 - 学習データ/評価データの傾向が著しく異なる場合、分類精度が著しく低下する **(結果はデータ次第)**
- マルウェア/正常系ソフトウェアにおいてはどうか?
 - 類似性の分布が広い
→ 学習/評価データで傾向が異なる可能性大



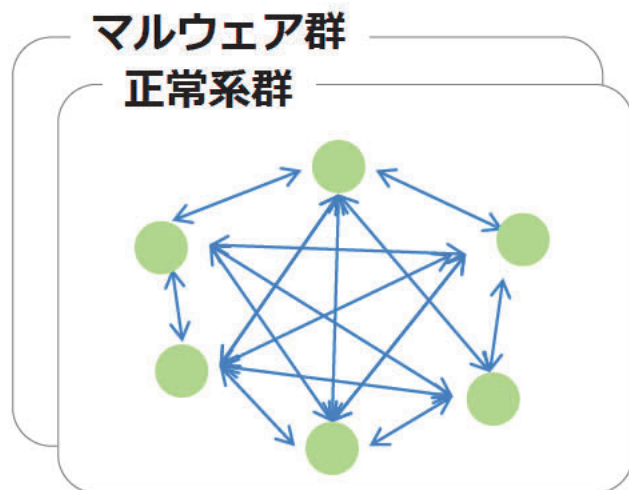
本研究の目的

機械学習によるマルウェア検知の有効性を検討する

- ① マルウェア群/正常系ソフトウェア群の分布(類似度)傾向について調査する (実験1)
- ② 分布の違いによる分類精度への影響を調査する (実験2)
- ③ 上記結果に基づき、学習データから類似度が低いデータを除外した場合の分類精度の変化について調査、考察する(実験3)

実験1(1/3) – 実験方法

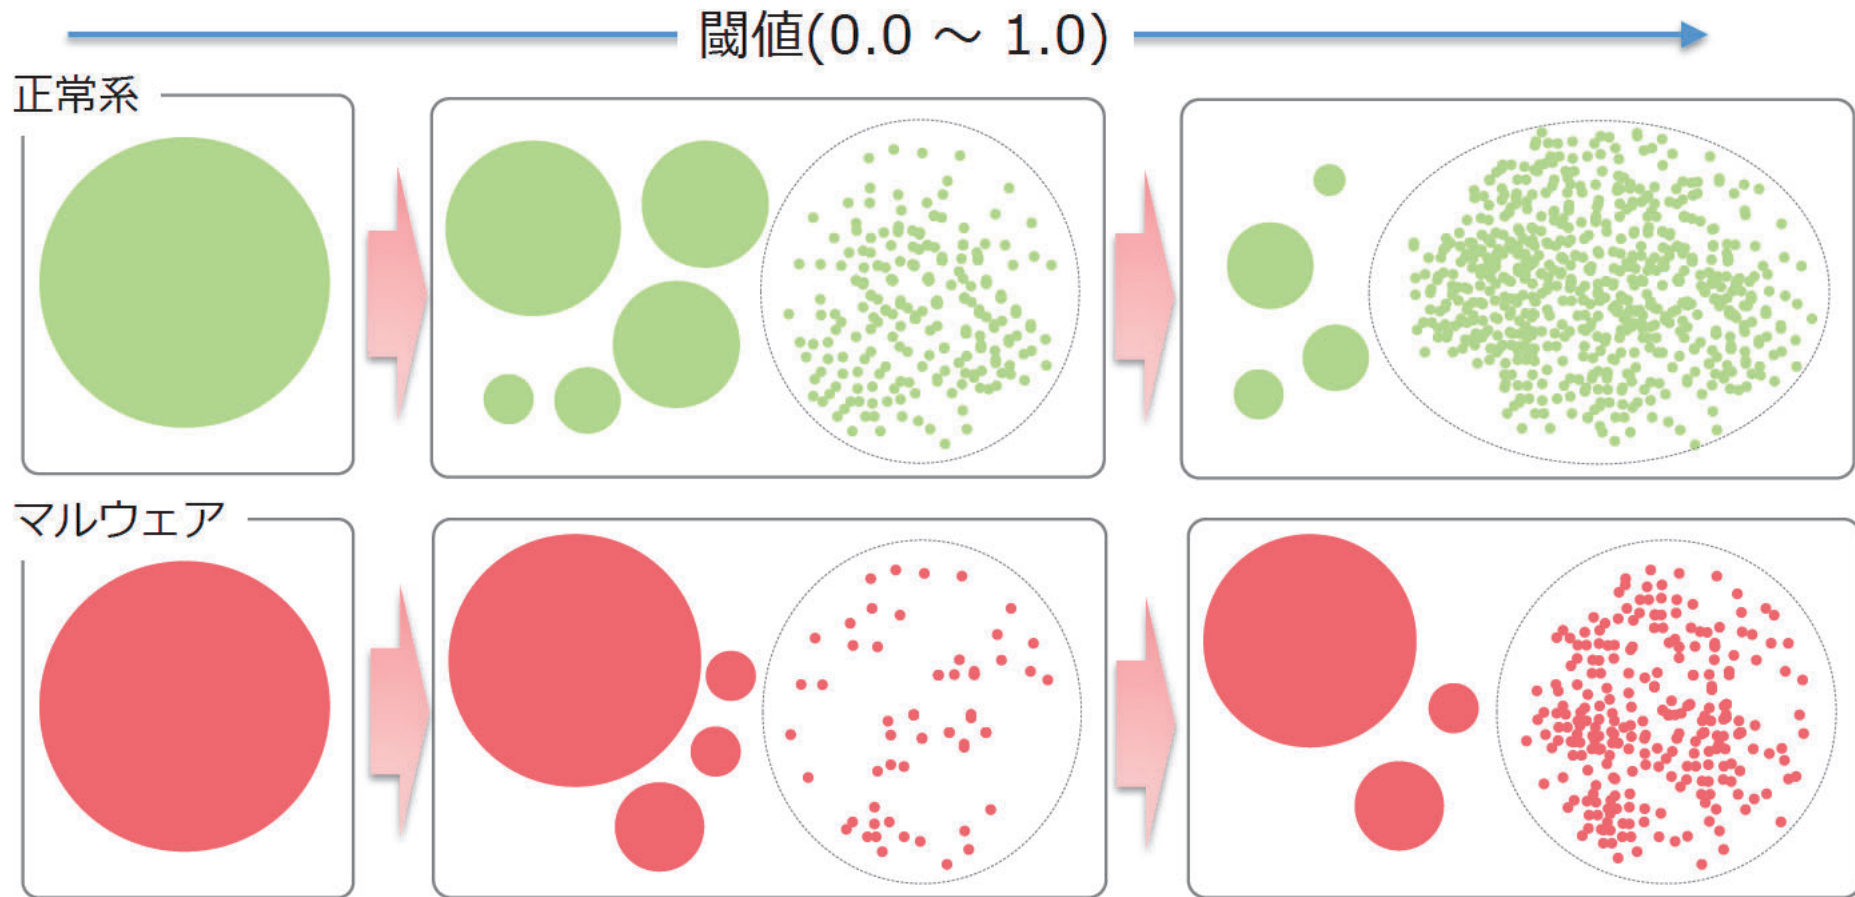
- FFRI Dataset 2013 / 独自に用意した正常系ソフトウェアを利用
- マルウェア/ 正常系同士の相互の類似度を算出 (Jubatus, MinHash)
- 時系列でのAPIコールの4-gramを特徴として利用
 - 例: *NtCreateFile_NtWriteFile_NtWriteFile_NtClose: n回*
NtSetInformationFile_NtClose_NtClose_NtOpenMutext: m回, etc.



	A	B	C		
A	A	B	C	...	
B	A	—	0.8	0.52	...
C	B	—	—	1.0	...
...	C	—	—	—	...
...	...	—	—	—	—


実験1(2/3) – 実験方法

- 類似度に閾値を設けてデータをグループ化



実験1(3/3) - 実験結果

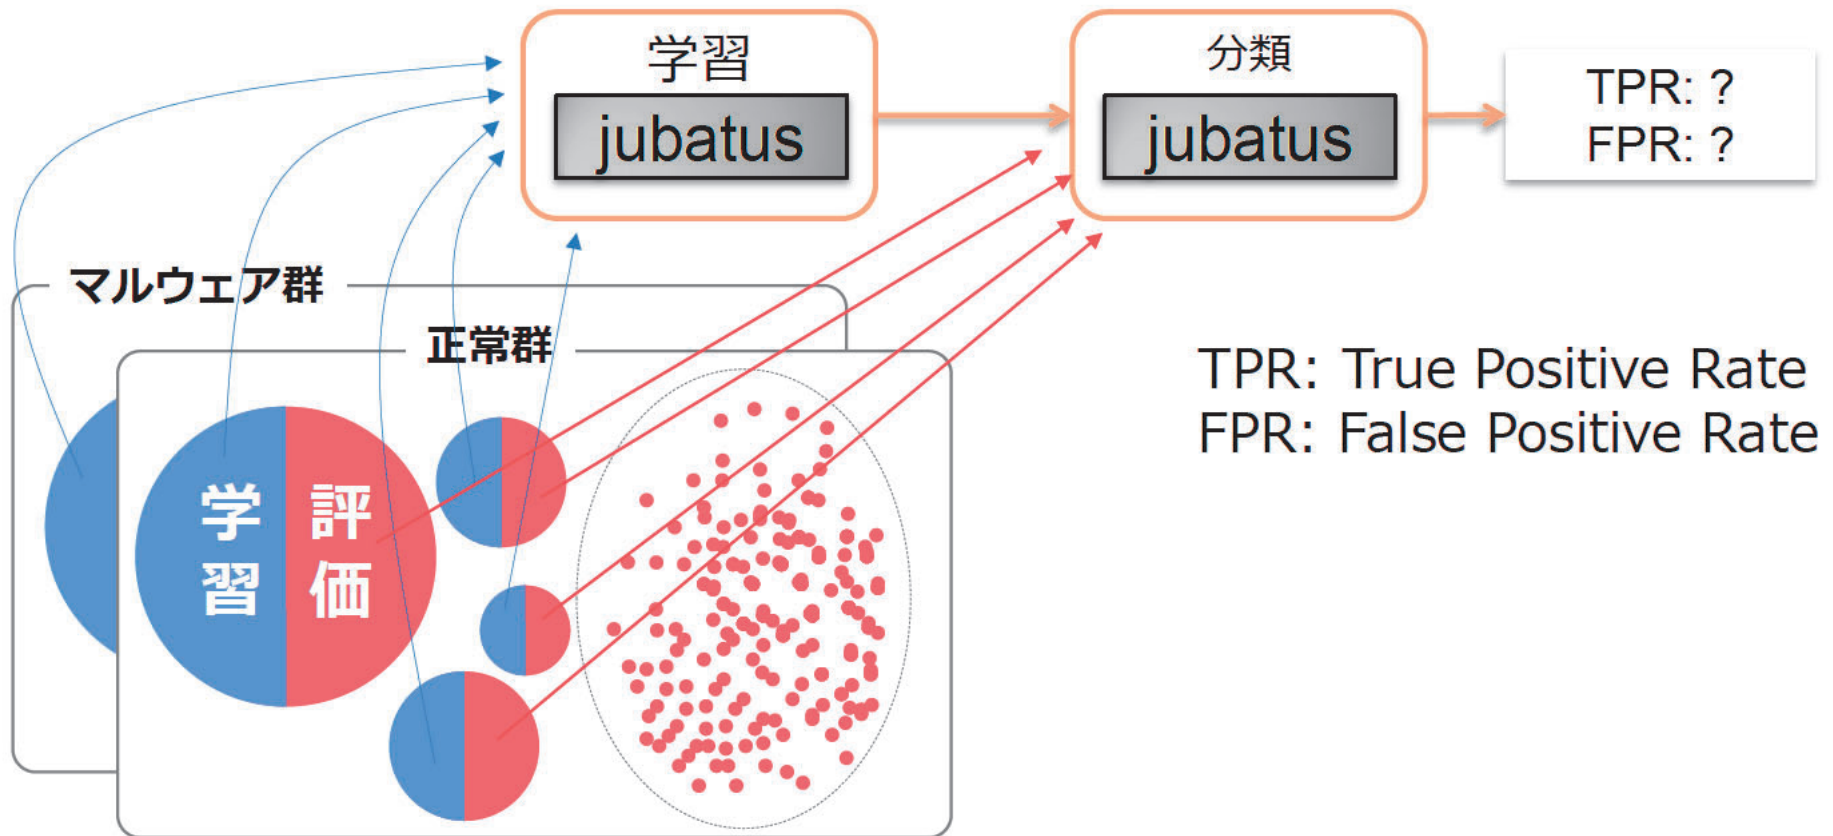
正常系は、マルウェアに対して似たものを見つけ難い



類似度の閾値

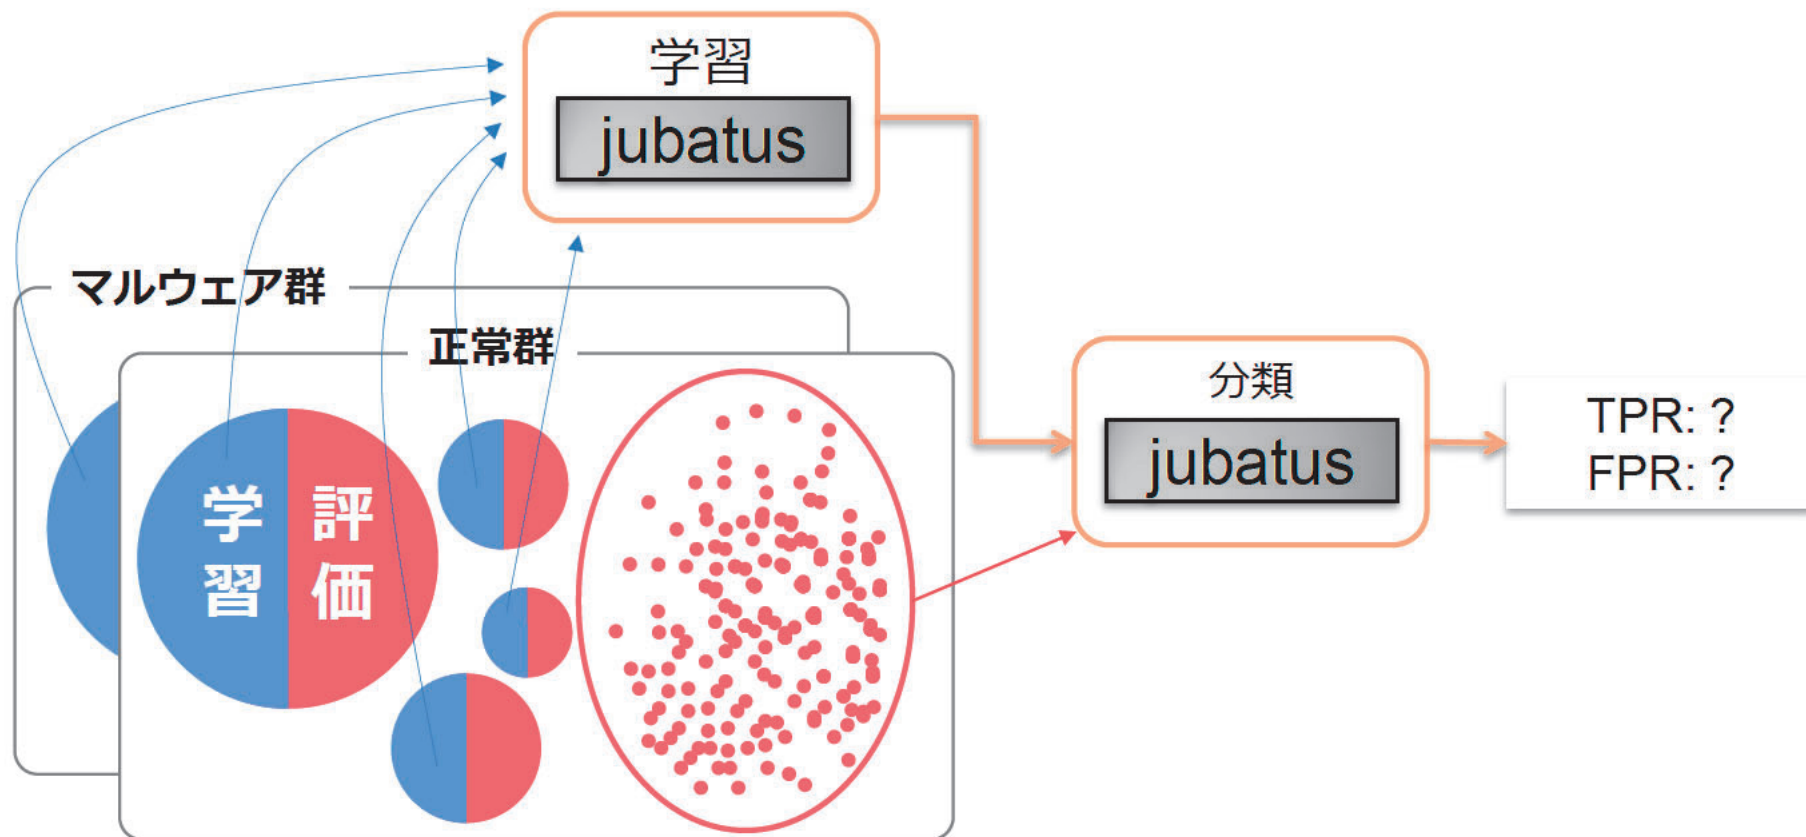
実験2(1/3) – 実験方法

- 学習-評価データの傾向差異は、分類精度にどの程度の影響を与えるか?
- 閾値0.9の状態を2分割し、学習・分類を実施(Jubatus, AROW)



実験2(2/3) – 実験方法


- 学習-評価データの傾向差異は、分類精度にどの程度の影響を与えるか?
- 閾値0.9の状態を2分割し、学習・分類を実施(Jubatus, AROW)




実験2(3/3) - 実験結果

学習データ/評価データの傾向が異なると分類精度が低下する

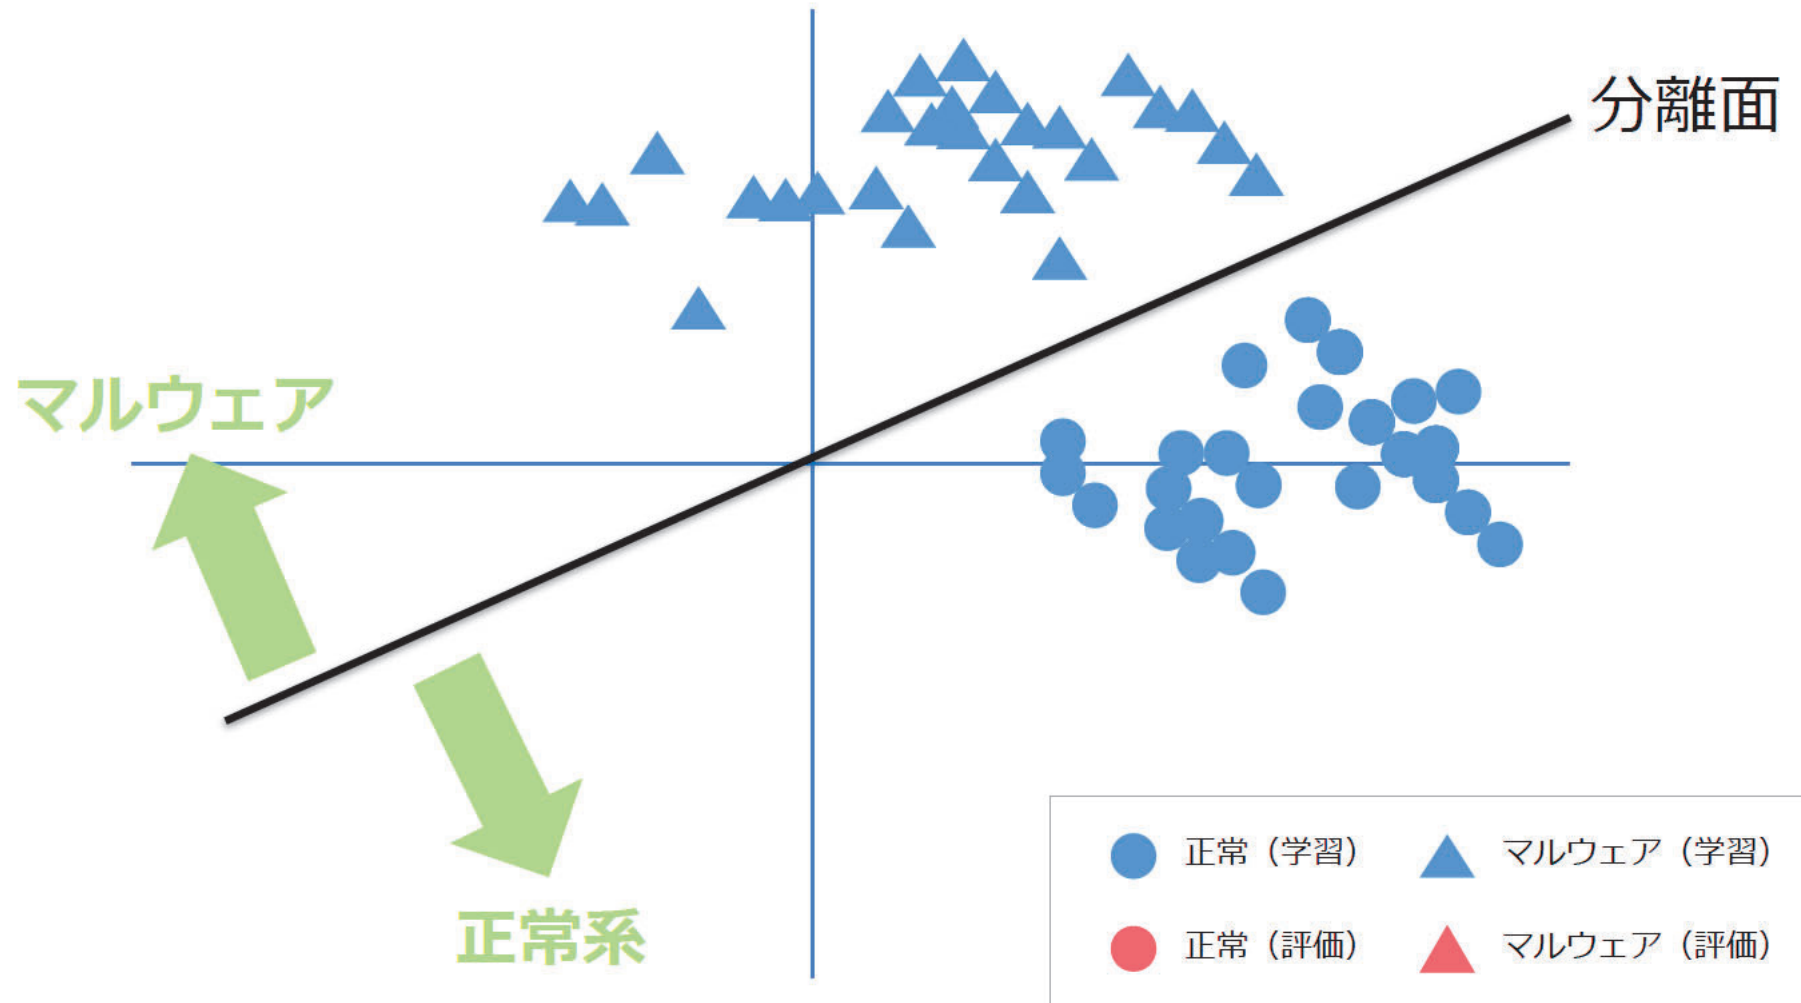
■ TPR



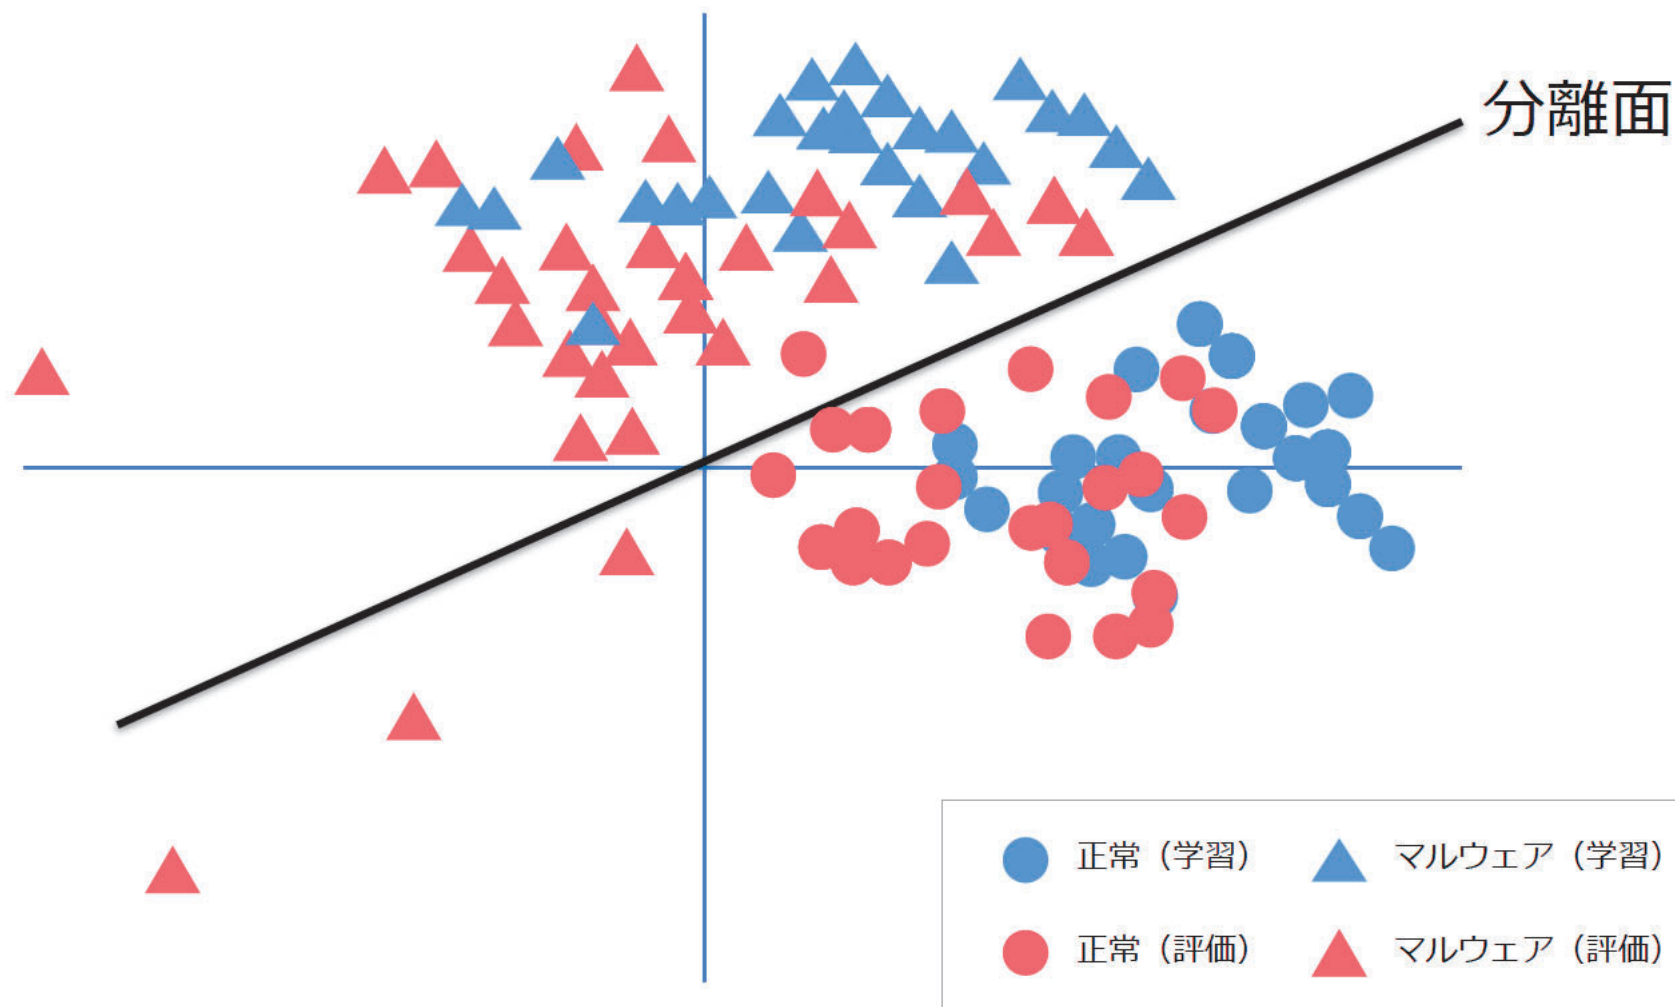
■ FPR



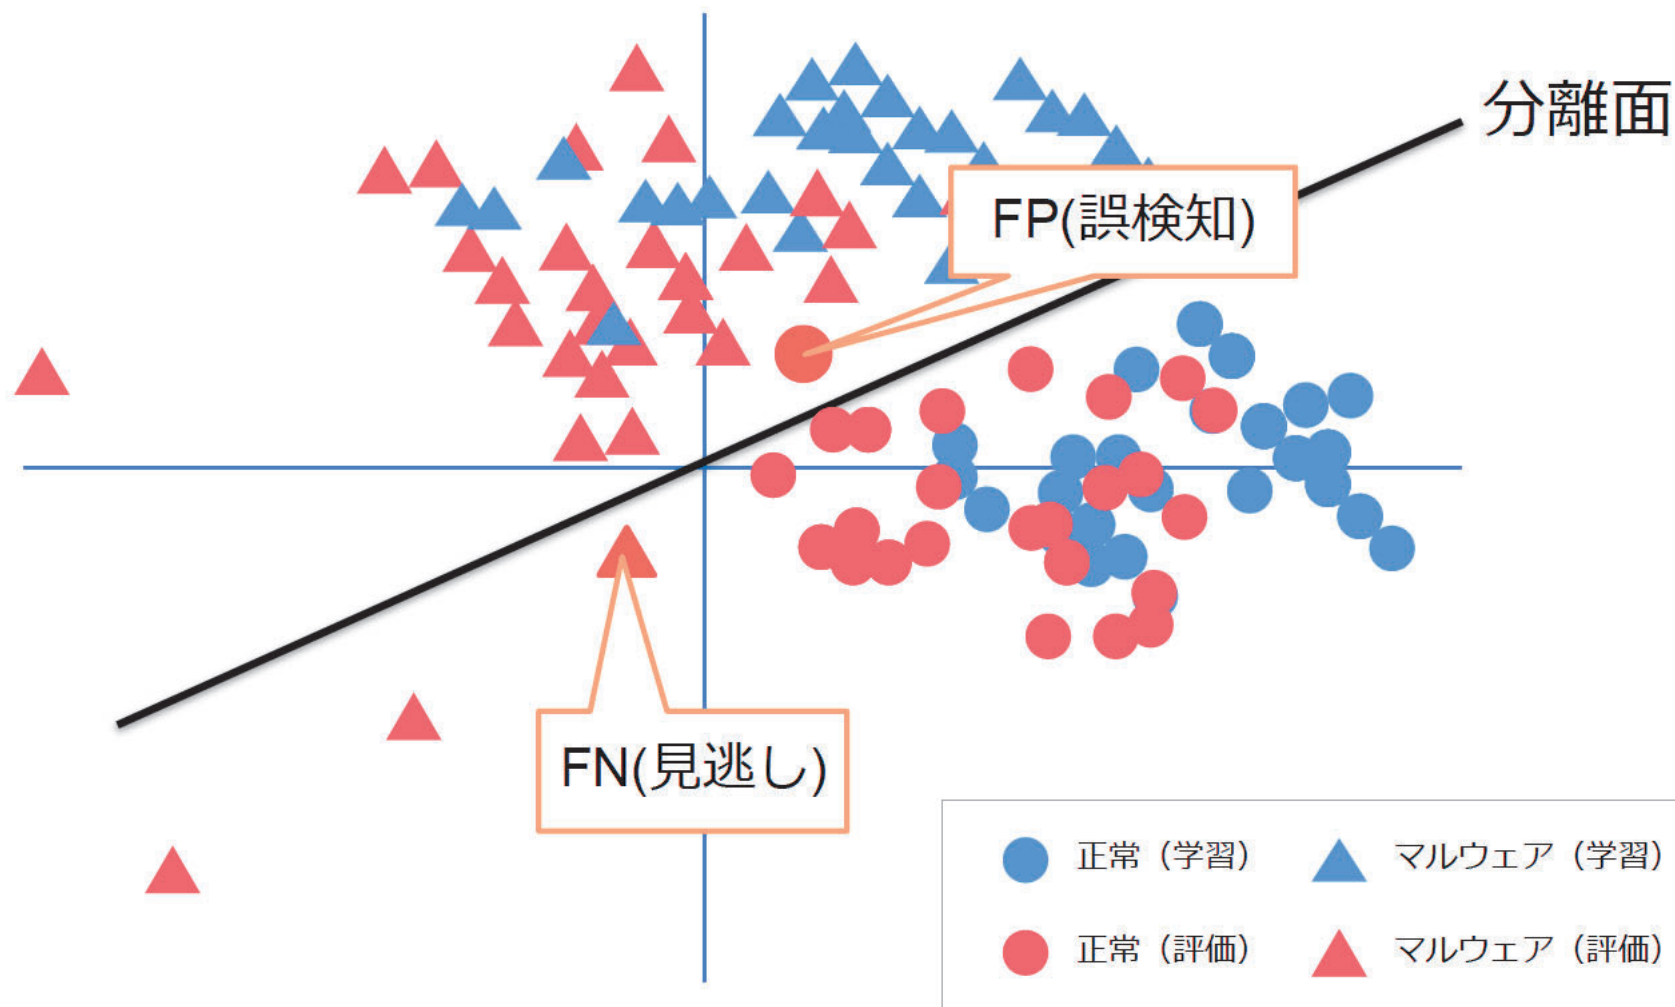
実験3(1/6) - 学習完了状態



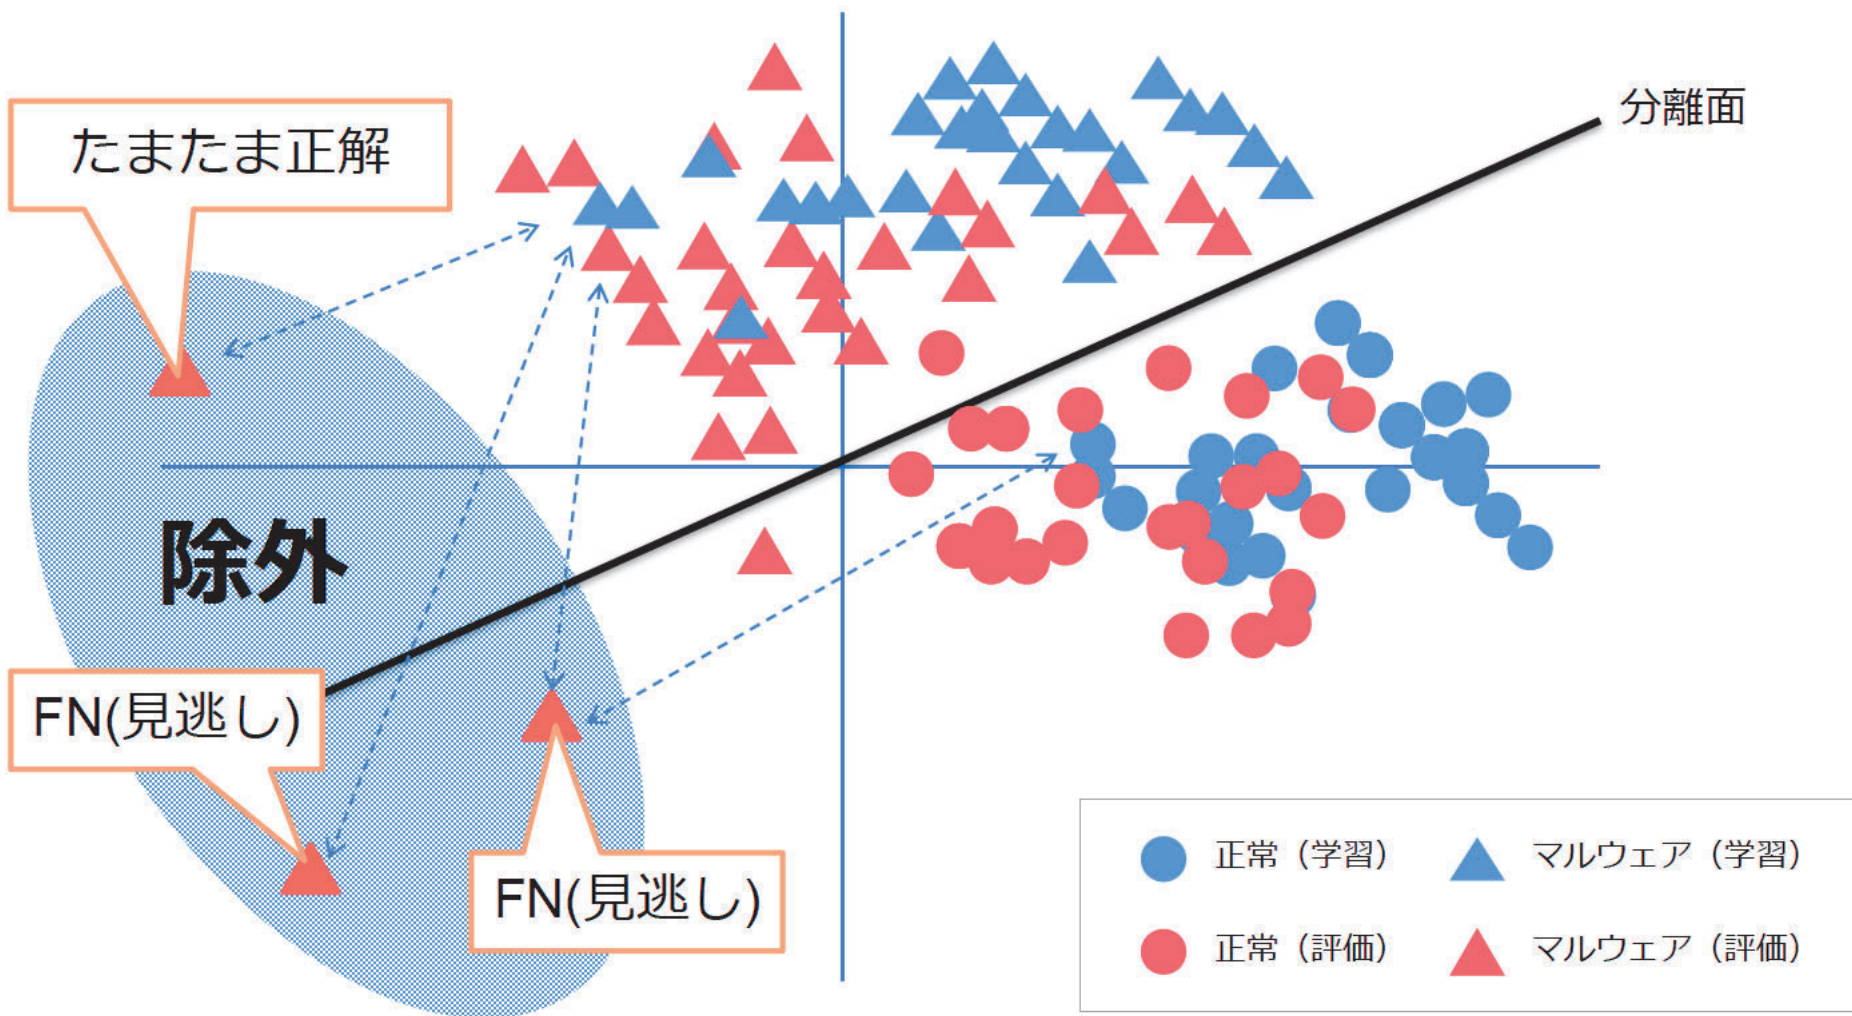
実験3(2/6) - 分類完了状態



実験3(2/6) - 分類完了状態




実験3(3/6) - 類似度の低い評価データ




実験3(4/6) - TPRへの影響

分類対象の減少 \propto TPR向上




実験3(5/6) - FPRへの影響

分類対象の減少 \propto FPR向上



実験3(6/6) - 分類対象データ数の推移

正常系の方がマルウェアに比べて減少率が高い



考察(1/3)

- 実際の適用シーン
 - マルウェアか正常系か分からないファイルを分類
- 実験 3 を適用した場合
 - 学習データ中に似たものがあれば分類対象に
 - 似たものがなければ対象外
 - 正解がマルウェアであればFalse Negative(見逃し)
 - 正解が正常系であればTrue Negative (結果的に正解)
- 上記より本質的には
「**ユニークなマルウェアのTPR**」に関する問題
(ユニークなマルウェアは見逃しがちに)

考察(2/3)

- 現状のようにマルウェアが多数の亜種を持つ場合、
 - 機械学習によるマルウェア検知は効果が期待できる
- 多数の亜種を持つ = 生成ツール
- 下記の調査が必要ではないか
 - マルウェア生成ツールの利用、普及動向
 - Anti-Machine Learning detection等の可能性

考察(3/3)

- 対象外としたマルウェアについて
 1. 別の特徴を用いた分類を行う
 2. データを増やす (ユニーク → 非ユニークへの推移)
 3. 機械学習以外の手法による検知を行う

まとめ

- マルウェアと正常系では類似度の分布が異なる（実験1）
- これにより分類精度の悪化が発生する(実験2)
- 類似度の低いデータを除外した場合、
ユニークなマルウェアのTPRが悪化する（実験3）
- 継続的なマルウェア、及び生成ツール等の動向調査が必要
- （正常系ソフトウェアを検知する技術が必要ではないか?）