


低い誤検知率で異常を検知 部分AUC最大化のための半教師あり学習


岩田具治, 藤野昭典, 上田修功
NTTコミュニケーション科学基礎研究所

ラベルなしデータを活用することで部分AUC
(偽陽性率が特定の範囲での真陽性率) を高
める手法を考案

少量のラベルありデータ



ラベルなしデータ



偽陽性率: 負例を誤って陽性と判別する割合
真陽性率: 正例を正しく陽性と判別する割合

本技術

偽陽性率0.1以下で
真陽性率向上

陽性判定に関して、
1割の「誤り」(偽陽性)を許して、
「正解」(真陽性)率を向上


- 機械学習技術による異常値検出は、二値(異常、正常) 分類問題と見なせる
- 評価は正答率ではなく、偽陽性率(false positive rate)をできるだけ抑え、真陽性率(true positive rate)が高い分器を設計することが重要
- 信頼性の高い分類結果を得るため、二値分類問題の評価尺度として部分AUCが注目されている

• 部分AUC

- Partial Area Under the Receiver Operating Characteristic Curve
- 偽陽性率が α から β のときの真陽性率曲線の下での面積

• 応用例

- 異常検知
 - 異常と誤って検知するとオペレータの負担増
- 病気診断
 - 病気と誤って診断すると不必要な検査によりコスト増



従来技術：教師あり部分AUC最大化法


ラベルありデータを入力とし、部分AUC最大化によりスコア関数を学習

スコア関数 $s(\mathbf{x})$

データ $\mathbf{x}$ の正例「らしさ」を出力する関数
ニューラルネット等でモデル化

$$\text{pAUC}(\alpha, \beta) = \mathbb{E}[I(s(\mathbf{x}^{\text{P}}) > s(\mathbf{x}^{\text{N}}))]$$

正例のスコアが、偽陽性率 α から β の間にある負例のスコアよりも高くなる割合





正例らしい ← スコア関数 $s(\mathbf{x})$ でソート → 負例らしい

(A) $\text{pAUC}(\alpha, \beta) = 2/5$

(B) $\text{pAUC}(\alpha, \beta) = 3/5$


$\text{AUC} = 19/25$ $\alpha = 0$ $\beta = 0.2$
(偽陽性率=0.2)

$I()$: 指示関数
 $\mathbb{E}$: 期待値



ラベルなしデータから計算できる 2 つの部分AUCの近似を導出し、スコア関数学習として利用

- θ_P を境に、スコアの良い（悪い）ラベルなしデータは仮の正例（負例）とみなす
- 正例と仮の負例、仮の正例と負例に対し、部分AUCを計算



$$\begin{aligned} & \mathbb{E}[I(s(\mathbf{x}^P) > s(\mathbf{x}^U))] \\ &= \text{pAUC}_{PU}(\theta_P + \alpha\theta_N, \theta_P + \beta\theta_N) \\ &\approx \text{pAUC}(\alpha, \beta) \end{aligned}$$

正例とラベルなしデータで
計算される近似部分AUC

$$\begin{aligned} & \mathbb{E}[I(s(\mathbf{x}^U) > s(\mathbf{x}^N))] \\ &= \text{pAUC}_{NU}((0, \theta_P)(\alpha, \beta)) \\ &\approx \text{pAUC}(\alpha, \beta) \end{aligned}$$

負例とラベルなしデータで
計算できる近似部分AUC

3つの部分AUCの重み付き和を最大化

$$L = \lambda_1 \text{pAUC}(\alpha, \beta) + \lambda_2 \text{pAUC}_{\text{PU}}(\theta_P + \alpha\theta_N, \theta_P + \beta\theta_N) + \lambda_3 \text{pAUC}_{\text{NU}}((0, \theta_P)(\alpha, \beta))$$

正例と負例で計算
されるpAUC

正例とラベルなしデータ
で計算されるpAUC

負例とラベルなしデータ
で計算されるpAUC


- 重みパラメータ λ は開発データでチューニング
- pAUCを微分可能にするために指示関数をシグモイド関数で近似
- 微分可能であれば任意のモデルをスコア関数として利用可能

(参考) 部分AUC近似のポイント


ラベルなし陽性率と真陽性率/偽陽性率の曲線の下
の面積で部分AUCを近似

- 「ラベルなし陽性率」を新たに導入
 - ラベルなしデータを陽性と判別する割合

正例とラベルなしデータで
計算される近似部分AUC：
$$\text{pAUC}_{\text{PU}}(\theta_P + \alpha\theta_N, \theta_P + \beta\theta_N) \\ \approx \text{pAUC}(\alpha, \beta)$$



負例とラベルなしデータで
計算される近似部分AUC：
$$\text{pAUC}_{\text{NU}}((0, \theta_P)(\alpha, \beta)) \\ \approx \text{pAUC}(\alpha, \beta)$$



9個中8個のデータセットで従来手法より同等以上のテスト部分AUCを達成

	教師あり				半教師あり					提案技術
	最小化 エントロピー	クロス エントロピー	最大化 AUC	最大化 pAUC	自己学習	最大化 AUC [1]	最大化 AUC [2]	最大化 pAUC [1]	最大化 pAUC [2]	
Anthyroid	0.442	0.436	0.517	0.494	0.516	0.445	0.428	0.506	0.503	
Cardiotocography	0.680	0.705	0.698	0.701	0.661	0.665	0.686	0.637	0.725	
InternetAds	0.664	0.697	0.695	0.723	0.629	0.631	0.621	0.590	0.672	
KDDCup99	0.949	0.941	0.944	0.956	0.929	0.914	0.943	0.904	0.961	
PageBlocks	0.679	0.677	0.717	0.724	0.746	0.744	0.729	0.753	0.727	
Pima	0.255	0.324	0.387	0.383	0.384	0.364	0.327	0.346	0.355	
SpamBase	0.698	0.690	0.691	0.691	0.663	0.627	0.662	0.617	0.687	
Waveform	0.624	0.619	0.598	0.628	0.571	0.548	0.595	0.500	0.609	
Wilt	0.326	0.440	0.813	0.780	0.803	0.687	0.539	0.790	0.845	

テスト部分AUC ($\alpha=0, \beta=0.3$) , 太字はt検定でベストなものと有意が差がないことを表す
スコア関数はすべてニューラルネットモデル化

[1] XIE, Zheng; LI, Ming. Semi-supervised AUC optimization without guessing labels of unlabeled data. AAAI, 2018

[2] SAKAI, Tomoya; NIU, Gang; SUGIYAMA, Masashi. Semi-supervised AUC optimization based on positive-unlabeled learning. *Machine Learning*, 2018

- 異常検知への応用
 - ドメイン適応技術との融合
-
- 参考文献
 - Tomoharu Iwata, Akinori Fujino, Naonori Ueda, Semi-supervised Learning for Maximizing the Partial AUC, AAAI, 2020