



Asymmetrical Margin Approach to Surveillance of Nosocomial Infections Using Support Vector Classification

作者： Gilles Cohen and M´elanie Hilario
St´ephane Hugonnet and Hugo Sax

出處： IDAMP 2003

Intelligent Data Analysis in Medicine and Pharmacology

報告者： 賴璟瑞

指導教授： 童超塵 教授

Contents

Introduction

Data collection and preparation

The imbalanced data problem

Support vector machine

Experimental setup

Results and conclusion

Introduction

■ 院內感染監控(NIs)

- have become a major concern not only in health care institutions but also among the general public.
- Since 1994 the Geneva University Hospital has been undertaking yearly prevalence studies in order to monitor and detect NIs.

■ 關鍵因素在預測和控制感染

- 提供數據以評估問題的嚴重性
- 發現疫情、辨識風險因素
- 對高危險病人、加護病房為目標作控制
- 評估預防方案

Introduction (con.)

- 最終目標 ➡ 減少監測感染的風險並提高病患的安全
- 在未來建立黃金目標 ； 全院預測監控
 - 缺點:超出任何醫院可負擔的成本
 - 建議:選定特定的病房，如重症加護病房
 - 此替代經感染率調查，是有效的監控策略
- 確認風險因素之限制
 - 回溯性質、依賴容易得到之數據、感染率的偏誤
 - 無法查明的疫情、有限的能力

Introduction (con.)

- Support Vector Machine (SVM)
 - 提供良好的數據來衡量嚴重的問題、評估預防方案和幫助分配資源
- 手法上提供NIs的臨床快照(snapshot)活動在指定的一天，並提供有關的頻率和感染特性資訊
- 感染控制政策的功效
 - 可以容易地測量透過廣泛的重複調查

■ *French et al., 1983*

Data collection and preparation

- 院內住院調查
 - 至少48小時才能評估是否存在一個活躍的NIs
- 數據收集
 - medical records、kardex (護理工作單)
 - Xray and microbiology reports
 - interviews with nurses and physicians in charge of the patient

Data collection and preparation

- 在院內感染調查那一天之前的六天，被Centres for Disease Control (CDC)記錄和辨識
- 收集變數存在相關的感染
 - 行政資訊、人口統計特徵、入院診斷
 - 合併症病患嚴重度分數、入院種類
 - 合併症；高血壓的合併症=>糖尿病
 - 各種危險因素的感染
 - 手術、加護病房逗留期間、設備、抗生素、免疫治療
 - clinical and paraclinical information

Data collection and preparation

- 全院監控再收集資訊就要花大約800小時，故利用資料探勘技術去收集2002年病患的研究，目的在及時發現NIs的病患
- 透過醫院專家過濾掉虛假的紀錄和不相關的多餘變數
 - 從688名病人記錄修改成683例
 - 從83種變數修改成49變數
- 而有些變數有缺失值，主要是由於測量錯誤或遺失
 - 缺失值假設為隨機缺失

Data collection and preparation

- 本研究利用類別條件均值class-conditional mean取代缺失值
- 資料探勘目的
 - 前處理的操作通常需要再作回顧性分析(retrospective analyses)
 - 而在數據收集沒有被專門設計

The imbalanced data problem

- 主要困難
 - 在固定數據中分佈存在高偏態
 - 683例中，只有75例感染而608沒有
- 應用中特別重要的議題；數據集不平衡
 - 目標；最大限度地認同少數類
 - For convenience we identify positive cases with the minority and negative cases the majority class
- Asymmetrical soft margin support vector machines
 - biasing the inductive process to boost sensitivity

分類不平衡議題

**Japkowicz,
2002**

- 處理數據的方法，包含超採樣(oversampling)少數類別

**Domingos,
1999**

- 建構成本敏感度分類，將成本高的分配到少數類別的錯誤分群

**Kubat
and Matwin,
1997**

- 以分層採樣去平衡在分群分配的訓練部分


**Ali
et al., 1997**

- 以規劃為基礎的方法，嘗試以學習高信賴規則在少數分類

Support vector machine

- 支撐向量機(SVM)是由Vapnik 在1995 年和AT&T 實驗室團隊所提出的一個新方法，其主要的理論是來自統計學習理論中結構化風險最小誤差法 (Structural Risk Minimization, SRM)。
 - SRM目的；希望分類器能在期望誤差中找到最小值。
- SVM目的
 - 尋求最小化預測結果之誤差上界(SRM)，而不是訓練誤差(ERM)的最小化。
 - Empirical Risk Minimization(ERM) 經驗風險最小化法則

Separating hyperplane



所以處理分類的函數為

$$f(\mathbf{x}) = \text{sign}\left(\sum_{k=1}^s 1\alpha_k y_k (\mathbf{x}_k \mathbf{x}) + b\right) \quad (3.9)$$

當 $f(\mathbf{x}) > 0$ 時，代表該資料和標示為 +1 的資料同一類；反之則是屬於另一類[21]。

$$\text{Minimize } \frac{1}{2} \|\mathbf{w}\|^2 \quad \text{subject to } y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad \forall i \quad (3.6)$$

利用 Lagrange 乘數方法((Lagrange Multiplier Method))可將(3.6)轉換

$$\begin{aligned} \text{Maximize } W(\alpha) &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1, j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \\ \text{subject to } & a_i \geq 0, \sum_{i=1}^n a_i y_i \mathbf{x}_i = 0 \end{aligned} \quad (3.7)$$

接著藉由二次規畫 (Quadratic Programming) 方法可以求出滿足(3.7)的 α_i 集合，且

$\mathbf{w} = \sum_{i=1}^n 1\alpha_i y_i \mathbf{x}_i$ ，其中 α_i 不為 0 的 \mathbf{x}_i 即稱為支持向量(support vector)。假設共有 s 個支持

向量，因此改寫 $\mathbf{w} = \sum_{k=1}^s 1\alpha_k y_k \mathbf{x}_k$ ，可得到邊界方程式

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = \sum_{k=1}^s 1\alpha_k y_k (\mathbf{x}_k \mathbf{x}) + b \quad (3.8)$$

Soft margin

在大部分的情形中，往往很難找到一條邊界可以完整的將資料群分開(圖 3.6)，因此必須容忍分類錯誤的行情發生。今 ξ 為分類錯誤時所需付出的代價(圖 3.7)，所以(3.5)




圖 3.6 分類錯誤




圖 3.7 加入 ξ 參數

目標同樣為最大化 m ，所以解

$$\text{Minimize } \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \quad \text{subject to } y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad (3.11)$$

利用 Lagrange 乘數方法將(3.11)轉換可得

$$\begin{aligned} \text{Maximize } W(\alpha) &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1, j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \\ \text{subject to } C &> \alpha_i \geq 0, \quad \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i = 0 \end{aligned} \quad (3.12)$$

到此步驟可以發現，為了容忍分類錯誤的發生而加入錯誤代價，僅僅改變了 α_i 的上限而已。

因此，可以定義核心函數(kernel function)

$$k(\mathbf{x}, \mathbf{y}) = \langle \phi(\mathbf{x}), \phi(\mathbf{y}) \rangle \quad (3.13)$$

如此一來，即可直接利用核心函數計算出資料在特徵空間中的內積值，不需將資料映射到特徵空間中後再進行內積運算，所以(3.12)可改寫為

$$\begin{aligned} \text{Maximize } W(\alpha) &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1, j=1}^n \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j) \\ \text{subject to } C &> \alpha_i \geq 0, \sum_{i=1}^n \alpha_i y_i = 0 \end{aligned} \quad (3.14)$$

同樣的，以 Quadratic Programming 方法找出滿足上式條件的 α_i 集合和 $\mathbf{w} = \sum_{k=1}^s 1 \alpha_k y_k \mathbf{x}_k$ ，

可得到邊界方程式

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = \sum_{k=1}^s 1 \alpha_k y_k k(\mathbf{x}_k, \mathbf{x}) + b \quad (3.15)$$

最後，處理分類的函數為

$$f(\mathbf{x}) = \text{sign} \left(\sum_{k=1}^s 1 \alpha_k y_k k(\mathbf{x}_k, \mathbf{x}) + b \right) \quad (3.16)$$

當 $f(x) > 0$ 時，代表該資料和標示為 +1 的資料同一類；反之則是屬於另一類[21]。

Asymmetrical soft margin

- In order to adapt the SVM algorithm to these cases the basic idea is to introduce different error weights C^+ and C^- for the positive and the negative class, which results in a bias for larger multipliers α of the critical class.

$$\begin{aligned} \text{minimize} \quad & \frac{1}{2} \|\mathbf{w}\|^2 + C^- \sum_{i: y_i = -1}^n \xi_i^- + C^+ \sum_{i: y_i = +1}^n \xi_i^+ \\ \text{s.t} \quad & (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i^+, \\ & (\mathbf{w} \cdot \mathbf{x}_i + b) \leq -1 + \xi_i^- \end{aligned} \quad (9)$$

Performance metrics

- 在分類任務上，分類效能一般量化在預測的準確性，在測試集上誤判數據點的分數。
- 混亂矩陣

		預測	
		C ₁	C ₂
真實	C ₁	<i>TP</i>	<i>FN</i>
	C ₂	<i>FP</i>	<i>TN</i>


$$\text{敏感度} = \frac{TP}{TP + FN}$$

$$\text{特定性} = \frac{TN}{FP + TN}$$

$$\begin{aligned} \text{正確性} &= \text{敏感度} + \text{特定性} \\ &= \frac{TP + TN}{TP + FN + FP + TN} \end{aligned}$$

ROC curves

- 西元1980年代以來，流行採用ROC (receiver operating character (area under the curve) 面積) 法的正確度。




面積」
法的正

- ROC 曲線之截切點特異度 (1 - 假陽性率) 點。

可能之
感度及
黃軸為
各座標

Results (sym. margin)



SVM classifier against different C values

Results (asym. margin)

Controlling the sensitivity of SVM




Table 1: Performance for different SVM configurations (original class distribution: 0.11 pos, 0.89 neg)

SVM Classifier	Hyperpar.	Accu- racy	Sensi- tivity	Specifi- city
RBF Gaussian	($\sigma = 0.1$)			
asym. margin	$C^+ = 3$	0.876	0.586	0.912
asym. margin	$C^+ = 5$	0.828	0.76	0.837
asym. margin	$C^+ = 11$	0.816	0.88	0.809
asym. margin	$C^+ = 29$	0.744	0.92	0.722

Performance of the asymmetrical-margin SVM classifier against different C^+ values

Results (compare)

■ Cohen et al., 2003

Table 2: Over/undersampling via synthetic example generation (0.5 pos 0.5 neg). Bracketed figures are baseline sensitivity rates obtained prior to class balancing.

Classifier	Accu.	Sensitivity	Specif.	Method	
IB1	0.84	0.56 [0.19]	0.88	KMU	K-means based undersampling
貝氏判別 決策樹 推進法 NaiveBayes	0.75	0.87 [0.57]	0.74	HYB	
C4.5	0.68	0.72 [0.28]	0.67	KMU	hybrid method
AdaBoost	0.75	0.84 [0.45]	0.74	KMU	
SVM	0.75	0.83 [0.43]	0.74	KMU	

- The best sensitivity rate in these previous experiments was 0.87, attained by Naive Bayes coupled with hybrid over/undersampling via prototype generation.
- SVMs using asymmetrical margins and a C+ parameter of 29 perform remarkably better with a sensitivity rate of 0.92.

Results (ROC curve)




Figure 3: ROC Curve for SVM classifiers varying error weight values for the positive class C^+

Conclusion

- 根據病患去預測感染風險，其分析結果最主要障礙
 - 罕見的陽性問題
- 為了處理這問題，利用 (asymmetrical soft margin) 演算法，得到最大邊距在少分類的另一邊。
- Symmetrical soft margin SVMs 中敏感度 【2.6-50.6】 %
- Asymmetrical soft margin SVMs 中敏感度 【58.6-92】 %

類別不平衡問題

- 在分類問題中，類別不平衡問題(Class Imbalance Problems)會使分類器在訓練時產生偏誤，導致其對少數類別(Minority Class Examples)有相當低的預測正確率。
- 這個問題是因為不平衡的資料所造成，在此種型態資料中，一個類別的樣本數會遠超過其它類別的樣本數，使類別樣本的分佈呈現偏斜狀況(Skewed Class Distribution)，而相較於多數類別樣本，少數樣本通常是較感興趣的類別。
 - 例如，醫學診斷資料的少見疾病

- 
- 當從不平衡資料萃取數據時，傳統的资料探勘方法會對多數類別樣本追求高的分類正確率，但對少數類別有極差的預測正確率，所以它們並不適合用來處理類別不平衡的資料。
 - 利用對稱與不對稱SVMs進行比較，再以混亂矩陣分析其敏感度、特定性、正確性，最後再以ROC curve呈現圖表。



國立雲林科技大學工業工程與管理所
Graduate school of Industrial Engineering & Management,
National Yunlin University of Science & Technology

系統可靠度實驗室 System Reliability Lab.
<http://campusweb.yuntech.edu.tw/~qre/index.htm>

THE END

