

## Methylation of Prostate Cancer Predict

專題編號: 113-CSIE-S010

執行期限: 112 年第 1 學期至 113 年第 1 學期

指導教授: 白敦文

專題參與人員: 110820004 黃新哲

110820051 劉秉逸

110590064 劉韶軒

### 三、 模型訓練

利用模型訓練以篩選基因。透過 SMOTE 平衡資料[2]，以解決 Normal 與 Tumor 樣本資料不平衡。

訓練 Random Forest、XGBoost 分群模型，並調整參數。




圖 2. Random Forest 首棵樹的視覺化結果

使用 RFECV 篩選模型特徵，並將結果交集，以確保篩選出的基因具有代表性，而非僅適用於某個特定模型。

### 四、 基因功能性分群

以基因功能性作為分群。使用 GOsimSim 套件的 Wang 方法 [2,3]，對候選的基因計算 GO Term 的相似度矩陣，並以 hierarchical clustering 分群。

最終由各群選出基因，相互組合出最佳搭配。

### 五、 癌症期數分析

將資料以不同期數個別分析，避免基因在早期顯著表現後，受晚期影響而被過早剔除。




圖 3. 前期(藍)後期(紅)甲基化程度分布比較圖表

以早期資料(一、二期)進行實驗流程，篩選出對癌症早期具代表性的基因。

### 六、 實驗結果分析

利用外部資料集檢測挑選出來的基因是否具有良好的預測性。在 450k 資料集中使用 3 個基因能達到 90%以上的準確度。在 850k 資料集中使用 3 個基因能達到 75%左右的準確度。PIA 為前列腺的萎縮性病變，研究表示 PIA 可能與早期前列腺癌有因果關係。在含有 PIA 的資料集中使用 3 個基因能達到 74%左右的準確度。

表 1. 外部資料集測試結果




圖 1.  $\Delta\text{Beta}$  與  $p\text{-value}$  呈現火山圖

### (二) 尋找最佳切點

對 hyer、hypo 資料使用混淆矩陣計算最佳切點，以區分 Normal 與 Tumor 樣本。並且利用 F1-score 以及 AUC/ROC 進行測試，移除表現不佳的基因。

## 參考文獻

- [1] A. B. Smith, C. D. Jones, and E. F. Roberts, "Article Title," *Journal*, Vol., No., pp. 1-10, Date.
- [2] 著者姓名, 「中文期刊論文篇名」, 中文期刊名, 卷, 期, 發行年次, 頁次。
- <https://www.sciencedirect.com/science/article/pii/S0960076016301054>
- GAPDH:<https://link.springer.com/article/10.1007/s12094-012-0924-x>, 引用 140 次 2013
- BMP7:<https://www.sciencedirect.com/science/article/pii/S0002944010620342>
- casa\_token=KrdQTPfw8NwAAAAA:oIvL2kGP\_s5\_MfRd\_Gk9xvFigUjga9WSQkN\_hVYYI8KEguQj\_NtDcYge\_ewRJFUSQ3h\_oDqtLE, 引用 246 次, 007
- NR1H3:<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5381174/>, 被引用 16 次 2017
- CDH23:<https://www.science.org/doi/full/10.1126/sciadv.aaw6710>, 被引用 35 次 2019
- RBPI:<https://jcp.bmjjournals.org/content/57/8/872.abstract>, 被引用 76 次 2004
- VIPR2:<https://www.frontiersin.org/journals/oncology/articles/10.3389/fonc.2022.852358/full>, 被引用 7 次 2022

AJCC Prostate Cancer Stage Groupings													
	Stage I		Stage IIa				Stage IIb		III	Stage IV			
Jewett-Whitmore stage	A1		A2, B0-2						C1-3	D1	D2		
TNM stage	T1a-c N0M0	T2a N0M0	T1a-c N0M0	T1a-c N0M0	T2a N0M0	T2a N0M0	T2b N0M0	T2c N0M0	T1-2 N0M0	T1-2 N0M0	T3a-b N0M0	T4 N0M0	Any T N1M0
Gleason score	≤ 6	≤ 6	7	≤ 6	≤ 6	7	≤ 7	Any	Any	≥ 8	Any	Any	Any
PSA level (ng/ml)	< 10	< 10	< 20	10-19.9	10-19.9	< 20	< 20	Any	≥ 20	Any	Any	Any	Any

2

Dataset	CpG Sites	Percentage
450k_GSE157272(No PIA)	('cg18759209', 'cg03576469', 'cg23740882')	92.86%
	('cg18759209', 'cg03576469', 'cg27223047', 'cg24530250')	89.29%
450k_GSE157272	('cg18759209', 'cg03576469', 'cg23740882')	74.29%
	('cg18759209', 'cg03576469', 'cg27223047', 'cg24530250')	71.43%
450k_GSE47915	('cg18759209', 'cg03576469', 'cg15323528')	100.00%
	('cg18759209', 'cg03576469', 'cg15323528', 'cg08151731')	100.00%
450k_GSE112047	('cg18759209', 'cg03576469', 'cg27223047')	100.00%
	('cg18759209', 'cg03576469', 'cg27223047', 'cg19300568')	100.00%
850k_GSE183040	('cg18759209', 'cg24530250', 'cg15229124')	75.44%
	('cg18759209', 'cg24530250', 'cg15229124', 'cg08378442')	63.16%

## 七、 結論

我們目前找到兩個較穩定的點位，在測試中有著良好的預測性。

- BMP7: cg18759209
- CCDC8: cg03576469

目前對整體 450k 資料的 F1-score 已經達到 90%。實驗結果以能透過少量基因數據檢測出準確的結果，以此達到降低成本、提高效率的目標。

此外我們發現甲基化數據在癌症的不同階段中表現出不一樣的分布，未來有望能以此為方向，提高早期癌症的預測準確度。

## 參考文獻

- [1] Tian Y., Morris T.J., Webster A.P. et al. (2017). ChAMP: updated methylation analysis pipeline for Illumina BeadChips. *Bioinformatics* 33, 3982–3984.
- [2] Chawla, N. V., Bowyer, K. W., Hall, L. O., Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, 16, 321-357.
- [3] Yu G, Li F, Qin Y, Bo X, Wu Y, Wang S. (2010) GOSemSim: an R

package for measuring semantic similarity among GO terms and gene products.

[4] Wang, J. Z., Du, Z., Payattakool, R., Yu, P. S., & Chen, C.-F. (2007). A new method to measure the semantic similarity of GO terms. *Bioinformatics*, 23(10), 1274–1281