



© Видавець Інститут кібернетики імені В.М. Глушкова НАН України, 12.07.2026

Це – препринт відкритого доступу за ліцензією CC BY-NC-ND 4.0

<https://creativecommons.org/licenses/by-nc-nd/4.0/legalcode.uk>

Автор підтверджує, що даний препринт відповідає всім вимогам Договору приєднання

https://arxiv.nas.gov.ua/public/accession_agreement.html

Ефективний баєсівський класифікатор для великої кількості атрибутів

Денков Іван Дем'янович¹[0009-0007-7989-2169], Тульчинський Вадим Григорович¹[0000-0002-0280-223X]¹Інститут кібернетики імені В. М. Глушкова НАН України, проспект Академіка Глушкова, 40, Київ, 03187, Україна

havoc85@gmail.com

Анотація. Метою роботи є розв'язування ряду прикладних задач класифікації, загальною рисою яких є мала вибірка при детальній інформації про об'єкти і слабка кореляція відомих властивостей об'єкту з цільовим параметром. Для таких задач запропоновано алгоритм Jumbled Naïve Bayes Booster (Перемішуючий наївний баєсів підсилювач), який є модифікацією наївного методу Баєса, що зберігає його кращі риси (зрозумілість роботи моделі, стійкість до незбалансованості вибірки, можливість врахування статистичної відмінності навчальної вибірки і реального світу, обчислення ступеню впевненості в результаті), зменшуючи структурний ризик (ризик перенавчання) і підвищуючи продуктивність. Алгоритм випробувано на даних прогнозування ризику небезпечних ускладнень серцево-судинних захворювань.

Ключові слова: задача класифікації, наївний баєсівський метод, структурний ризик, перенавчання, швидкодія, розмірність простору, паралельні обчислення.

1 Вступ

У багатьох прикладних задачах, зокрема в медичній галузі, навчальна вибірка складається з обмеженої кількості зразків-об'єктів, щодо кожного з яких доступна детальна інформація. Природні обмеження розміру вибірки (рідка форма хвороби, дорогі дослідження тощо) сильно ускладнюють задачі машинного навчання. Методи поповнення вибірки штучними зразками є ризикованими, якщо ми працюємо з складними об'єктами, подібними до організму людини. Залежність між ознаками впливає на ймовірність їх випадкових комбінацій в природі, а автоматичне визначення класу (умовної ознаки хвороби, чи чогось подібного) за штучними даним є непевним саме внаслідок відсутності хорошої моделі, що є передумовою таких задач.

Малі за розміром вибірки створюють значні обмеження щодо складності моделі. (Проста модель, з низькою мірою Вапника-Червоненкіса необхідна для запобігання високому структурному ризику, тобто перенавчанню). Проте потреба у машинному навчанні виникає переважно саме тоді, коли між відомими атрибутами зразків та цільовим параметром відсутня сильна кореляція, тобто не вдається обрати невелику кількість індикаторів. Отже модель має бути і простою, і здатною врахувати багато ознак-атрибутів.

В нашій роботі, яка виникла з прикладних задач кардіології та онкології, ми враховували ще кілька бажаних властивостей методу навчання:

- здатність оцінювати та порівнювати ступінь впевненості;
- можливість пояснити результати та проаналізувати підстави прийняття рішення моделлю;
- можливість сильного дисбалансу навчальної вибірки;
- здатність до регулювання класифікатора з урахуванням асиметричної небезпеки помилки та або відомої ймовірності класів у генеральній сукупності;
- можливість роботи при відсутності значень деяких ознак.

Баєсівські класифікатори, зокрема, Наївний баєсівський класифікатор (Naïve Bayes Classifier, NBC) мають багато з перелічених рис. Додатково перевагою NBC є відсутність гіперпараметрів, що дозволяє тренувати модель з крос-валідацією на 2, а не 3 підвибірках, що суттєво для випадку обмеженої кількості зразків, що ми розглядаємо. Їх додатковою перевагою.

Наукове обґрунтування методу Баєса передбачає взаємну незалежність ознак. Статистична перевірка може бути ненадійною для малих вибірок. До того, у певних предметних областях (включно з медичною) твердження про незалежність ознак потребує додаткового дослідження: у складних системах все пов'язане з усім. З розповсюдженням застосування машинного навчання на такі системи, проблема навчання на коротких вибірках з великою кількістю атрибутів набуває додаткової актуальності.

Описаний далі алгоритм Jumbled Naïve Bayes Booster (Перемішуючий наївний баєсів підсилювач, JNBV) поєднує NBC з концепцією випадкових проекцій, що дала багато цікавих результатів в різних галузях штучного інтелекту і машинного навчання за останні два десятиріччя. Випадкові проекції, зменшуючи розмірність простору для методу Баєса, одночасно знижують взаємну залежність змінних внаслідок ортогональності гіперпросторів, на які відбувається проектування. Таким чином забезпечується умова незалежності ознак, потрібна для коректного застосування методу Баєса.

Проведені експерименти показали перевагу запропонованого алгоритму JNBV над іншими варіаціями методу Баєса для задачі з малою вибіркою та великою кількістю атрибутів щодо точності та швидкодії при малих розмірностях моделей.

2 Пов'язані роботи

NBC породив ціле сімейство алгоритмів, мета котрих – послабити припущення про незалежність ознак. Класичним прикладом є алгоритм дерева Чоу-Лю (Chow-Liu tree) [1]. В його основі лежить обчислення взаємної інформації між усіма парами ознак, до яких також приєднують цільову ознаку (результуючий клас). Після цього на зазначених параметрах будують остовне дерево, яке максимізує взаємну інформацію. Через участь у побудові дерева цільового параметру початкова модель Чоу-Лю не призначалась для класифікації, але подальша модифікація створила на її основі алгоритм класифікації. Іншим відомим алгоритмом є Tree Augmented Naïve Bayes (TAN) [2]. Він має подібний перший крок: побудова максимального остовного дерева ознак. Але далі він працює за

принципом баєсівської мережі: ймовірності обчислюються з урахуванням того, що в кожній ознаці є ознака-предок в дереві. Клас додається як вершина-предок кожній ознаці.

Сучасні методи розвивають ідеї класичних. Наприклад, *k*-Tree Augmented Naïve Bayes (*k*-TAN) [3] допускає складніші залежності між ознаками: кожна ознака може бути залежною від декількох інших. Складність побудованої структури визначається величиною «ширина куста дерева», яка не має бути більшою за *k*, тобто, обмежується кількістю зв'язків між вершинами в одній кліці (підмножина графа, де усі вершини пов'язані між собою). Іншою модифікацією є Hierarchical Dependency Constrained Tree-Augmented Naïve Bayes (Hie-TAN) [4]. Тут враховуються ієрархічні залежності між ознаками (якщо два атрибути знаходяться у відношенні «предок–нащадок» і мають однакове значення для визначення класу, один з них вважається надлишковим і не включається до структури). Якщо попередні методи здебільшого концентрувалися на зміні структури глобального дерева зв'язків між атрибутами, то Evolutionary Weighted Lazy Naïve Bayes (EWLNB) [5] не змінює структуру, а будує локальну модель навколо класифікованого об'єкта («ледаче навчання»). Тобто, беруться *k* найближчих сусідів, на яких навчається локальний NBC, працюючи не з усією вибіркою, що являє собою складну суміш груп, а з відносно невеликою групою близьких за властивостями об'єктів.

Велика кількість модифікацій, зокрема опублікованих протягом 2020-х років, свідчить про актуальність методу Баєса. Але нові алгоритми переважно додають гіперпараметри та обчислювальну складність, тобто підвищують вимоги до розміру вибірки і час тренування, залишаючись у рамках раніше створених парадигм. Тому, хоча в публікаціях вони демонструють вищу точність, на практиці досі більш популярними є алгоритми 1990-х – першої половини 2000-х, особливо, TAN.

3 Опис алгоритму

Алгоритм JNBV працює з бінарними векторами. Небінарні ознаки кодуються аналогічно іншим подібним алгоритмам.

- Якщо атрибут має більше ніж 2 можливих значення, але скінчену кількість *n*, для застосування JNBV він перетворюється на *n* бінарних розрядів вхідного вектора, а його значення кодується 1 в розряді, що відповідає номеру значення, і 0 в решті розрядів.
- Подібним чином кодуються безперервні величини, що мають обмежений діапазон, наприклад, відсотки за умови що вони обмежені діапазоном від 0 до 100. Обирається певний крок (точність заокруглення), і діапазон можливих значень розбивається з цим кроком на інтервали, кожному з яких відповідає бінарний розряд, який дорівнює 1, якщо значення попадає у відповідний інтервал і 0, якщо ні. Наприклад інтервал 0-100% і крок 0,5% дають $(100-0)/0,5-1=199$ інтервалів.
- Безперервні величини, що не обмежені фіксованим діапазоном, або чий розподіл у діапазоні можливих значень є суттєво нерівномірним, розбиваються медіанами на 2^n інтервалів, крайні з яких залишаються відкритими. Вибір *n* визначається за міркуваннями балансу між роздільною силою та зростанням розрядності вектору.

- Якщо потрібно окремо врахувати невизначене значення ознаки, для його представлення додається ще один бінарний розряд.

Таким чином, у більшості практичних випадків вхідні бінарні вектори є розрідженими.

В основі алгоритму JNBВ лежить випадкове проєктування зі зменшенням розмірності, що виконується шляхом множення на випадкову прямокутну матрицю зі значеннями в комірках ± 1 . Для відновлення бінарного характеру вихідних векторів, результат множення порівнюється з 0: якщо значення розряду невід'ємне, замінюємо його на 1, інакше – на 0. Далі застосовуємо NBC у перетвореному просторі.

Класифікація NBC відбувається за класичною формулою метода Баєса:

$$y = \underset{i=0}{\operatorname{argmax}}^{k-1} \frac{q_i}{1 - q_i} \prod_{j=0}^{n-1} \left(\frac{p_{ij}}{1 - p_{ij}} \right)^{2x_j - 1}; \quad (1)$$

де q_i – апіорно відомі ймовірності i -го класу (з k), що утворюють набір коригуючих коефіцієнтів, p_{ij} – експериментально визначені за вибіркою умовні ймовірності значення 1 для j -го елементу вхідного вектора (з n) для i -го класу, x_j – фактичне значення цього атрибуту вхідного вектора x (0 чи 1), а y – номер класу згідно прогнозу.

Нижче наведено опис тренування алгоритму навчання JNBВ зі вчителем для класифікатору на k класів (Алгоритм 1). Позначимо X тренувальний набір з d бінарних m -вимірних векторів ознак, представлений у формі прямокутної матриці $m \times d$. Відповідні d номерів класу (з можливими значеннями 0 чи 1 у бінарному випадку і від 0 до $k-1$ у випадку k класів) позначимо $(y_1, \dots, y_d)$. Випадкова матриця A розмірності $n \times m$ ($m > n$) складається з ± 1 .

Алгоритм 1. Навчання класифікатору JNBВ з фіксованими проєкціями

Вхід: X – тренувальний набір даних, матриця $m \times d$ ($x_{ij} \in \{0; 1\}$),

y – вектор класів довжини d ($y_i \in \{0; \dots k-1\}$),

A – матриця проєкції розмірності $m \times n$ ($a_{ij} \in \{-1; 1\}$)

Вихід: P – оцінка ймовірностей: матриця дійсних чисел розмірності $k \times n$ ($p_{ij} \in [0; 1]$)

function *TrainJNBВ* (X, y, A)

1: $Z := X \times A$ {отримуємо матрицю $d \times n$ }

2: $P := \text{zero}(\text{lengh}(y), \text{height}(A))$ {ініціалізуємо нулями матрицю $k \times n$ }

3: **for each** z_{ij} **in** Z **do** {розрахунок умовних ймовірностей 1 у перетвореному просторі}

4: **if** $z_{ij} \geq 0$ **then** $p_{ij} := p_{ij} + 1/d$ **end if**

5: **end for**

6: $\varepsilon := (1/d)/2$ {мінімальна ймовірність замість 0}

7: **for each** p_{sj} **in** P **do** {захист від нульової ймовірності}

8: **if** $p_{sj} = 0$ **then** $p_{sj} := \varepsilon$ **end if**

9: **if** $p_{sj} = 1$ **then** $p_{sj} := 1 - \varepsilon$ **end if**

10: **end for**

11: **return** P

Робоча модель складається з матриць A і P , де P – власно модель, а A – її гіперпараметри.

При програмній реалізації класифікації за побудованою моделлю (Алгоритм 2) зручнішою з т.з. захисту від переповнення є логарифмічна форма формули (1):

$$y = \underset{i=0}{\operatorname{argmax}}^{k-1} \left(\log \frac{q_i}{1 - q_i} + \sum_{j=0}^{n-1} \left((2x_j - 1) \log \frac{p_{ij}}{1 - p_{ij}} \right) \right). \quad (2)$$

Алгоритм 2. Робота навченого класифікатора JNBB з фіксованими проєкціями

Вхід: A – матриця проєкції розмірності $m \times n$ ($a_{ij} \in \{-1; 1\}$),
 P – оцінка ймовірностей за Алгоритмом 1: матриця розмірності $k \times n$ ($p_{ij} \in [0; 1]$),
 q – вектор апіорних ймовірностей класів довжини k ($q_i \in [0; 1]$),
 x – бінарний вектор атрибутів зразка довжини m ($q_i \in \{0; 1\}$)

Вихід: y – номер прогнозного класу ($y \in \{0; \dots k-1\}$),
 r_y – дійсне значення впевненості

function *RunJNBB* (A, P, x)

```

1:  $z := x \times A$  {стискаємо вектор проєкцією до розмірності  $n$ }
2:  $r := \mathbf{zero}(\mathbf{width}(q))$  {ініціалізуємо нулями вектор довжиною  $k$ }
3: for each  $r_i$  in  $r$  do {ініціалізація поправкою}
4:    $r_i := \log(q_i / (1 - q_i))$ 
5: end for
6: for each  $p_{ij}$  in  $P$  do
7:   if  $z_i \geq 0$  then
8:      $r_i := r_i + \log(p_{ij} / (1 - p_{ij}))$ 
9:   else
10:     $r_i := r_i - \log(p_{ij} / (1 - p_{ij}))$ 
11:   end if
12: end for
13:  $y := \operatorname{argmax}(r)$  {індекс максимального елементу вектора}
14: return  $y, r_y$ 
```

За умови наявності достатньої кількості зразків Алгоритм 1 можна доробити, передбачивши тренування гіперпараметрів. Наступний Алгоритм 3 виконує підбір кращого набору випадкових проєкцій (тобто оптимізацію матриці A) на основі відбору проєкцій з найбільшою роздільною здатністю, що обчислюється за наступною формулою:

$$d_j = \sum_{i=0}^{k-1} w_i \left| \frac{p_{ij}}{1 - p_{ij}} - \frac{1 - p_{ij}}{p_{ij}} \right|; \quad (3)$$

де w_i – апіорно призначені ваги класів. Регулювання ваг у формулі (3) дозволяє обирати між макро-оцінкою (коли всі w_i – рівні, а отже класи впливають однаково), мікро-оцінкою (коли $w_i = q_i$, тобто вага класу пропорційна його долі в генеральній сукупності), та проміжними варіантами балансу.

Алгоритм 3. Оптимізація матриці проєкцій JNBB

Вхід: X – тренувальний набір даних, матриця $m \times d$ ($x_{ij} \in \{0; 1\}$),
 y – вектор класів довжини d ($y_i \in \{0; \dots k-1\}$),
 n – розмір стиснутого простору,
 w – ваги роздільної здатності (вектор дійсних чисел довжини k),
 t – максимальне число ітерацій

Вихід: A – матриця проєкції розмірності $m \times n$ ($a_{ij} \in \{-1; 1\}$)

function *FitJNBB* (X, y, n, w, t)

```

1:  $A := \text{random}(\text{width}(X), n, \{-1; 1\})$  {генеруємо випадкову матрицю  $m \times n$ }
2:  $P := \text{TrainJNBB}(X, y, A)$  {розраховуємо модель}
3: while  $t > 0$  do {основний цикл}
4:    $t := t - 1$  {зменшуємо кількість ітерацій до зупинки}
5:    $B := \text{random}(\text{width}(X), n, \{-1; 1\})$  {генеруємо випадкову матрицю  $m \times n$ }
6:    $Q := \text{TrainJNBB}(X, y, B)$  {розраховуємо модель}
7:    $d := \text{zero}(2*n, 3)$  {ініціалізуємо нулями матрицю розміром  $2n \times 3$ }
8:   for  $i$  from 0 to  $n-1$  do {заповнюємо матрицю роздільних здатностей}
9:      $d_{i0} := 1$  {номер матриці проєкцій, 1 значить  $A$ }
10:     $d_{i1} := i$  {номер рядка матриці проєкцій}
11:     $d_{i2} := \text{formila3}(P, w, i)$  {роздільна здатність за формулою (3)}
12:     $j := i+k$ 
13:     $d_{j0} := 0$  {номер матриці проєкцій, 0 значить  $B$ }
14:     $d_{j1} := i$  {номер рядка матриці проєкцій}
15:     $d_{j2} := \text{formila3}(Q, w, i)$  {роздільна здатність за формулою (3)}
16:   end for
17:    $d := \text{sortColumns}(d, [2, 0])$  {сортуємо стовпці за зростанням у рядках 2 і 0}
18:    $C := \text{zero}(A)$  {генеруємо нульову матрицю розміром як  $A$ ,  $m \times n$ }
19:    $z := 0$  {кількість заміненних стовпців}
20:   for  $i$  from 0 to  $n-1$  do {заповнюємо стовпці матриці  $C$ }
21:      $j := 2*n-i$ 
22:      $s := d_{j1}$  {номер стовпця для заміни}
23:     if  $d_{j0} = 1$  then {стовпець початкової матриці}
24:        $C_i^* := A_s^*$  {замінюємо  $i$ -й стовпець матриці  $C$  на  $s$ -й стовпець матриці  $A$ }
25:     else {стовпець нової випадкової матриці}
26:        $C_i^* := B_s^*$  {замінюємо  $i$ -й стовпець матриці  $C$  на  $s$ -й стовпець матриці  $B$ }
27:        $z := z + 1$  {збільшуємо кількість заміненних стовпців}
28:     end if
29:   end for
30:   if  $z = 0$  then break {вихід з циклу, якщо не вдалось нічого покращити}
31:    $A := C$ 
32: end while
33: return  $A$ 

```


Роздільна здатність d_j визначає, наскільки заміна 0 на 1 (чи навпаки) в j -му розряді стисненого простору впливає на результат класифікації, а отже наскільки корисним є j -й рядок матриці A .

Оптимізація гіперпараметрів полягає у заміні менш корисних рядків на більш корисні, тобто ті, де d_j більше. В Алгоритмі 3 модель будується для двох матриць гіперпараметрів: тієї, що оптимізується (A) та нової випадкової (B). В разі, якщо якісь рядки B є кращими за роздільною здатністю за якісь рядки матриці A , відбувається їх заміна. (Матриця C заповнюється найкращими стовпцями з A і B , а потім замінює A .) Операція повторюється з новими випадковими матрицями B , до досягнення умови зупинки. Умова зупинки може включати максимальну кількість ітерацій, певну кількість ітерацій, що не покращили матрицю A , тобто не призвели до заміни жодного рядка тощо. В описаній вище версії Алгоритму 3 передбачена кількість ітерацій T , але відсутність поліпшення на черговій ітерації призводить до виходу з циклу і зупинки подальшої оптимізації. Це – один з можливих варіантів: саме той, що ми реалізували і експериментально дослідили.

4 Експериментальне дослідження

У тестовому випробуванні ми використали деперсоналізований фрагмент бази даних «Ескулап» [6], де містяться тексти лікарських висновків з відомостями про анамнез, діагнози та призначене лікування. Всього було оброблено дані візитів протягом 2013-2023 років для 9544 пацієнтів, з яких у 4800 було виявлено ЦВХ (клас 2), а у 4744 – ні (клас 1).

Записи про візити пацієнтів піддали лематизації, тобто приведенню до нормальної граматичної форми: для іменників та прикметників це – однина чоловічого роду, для дієслів – невизначена форма тощо. Після чого підраховували частоту входження унікальних слів в обох класах, підраховували метрики r_1 та r_2 , відсортували слова описаним вище методом, прибрали ті, що зустрічаються рідко (менше ніж у 10 пацієнтів) та додали до слів коди діагнозів, які ставили пацієнтам протягом їх візитів. Отримали набір з 1436 слів, який став основою для побудови моделі методом Баєса.

Кожному пацієнту у відповідність ставився 1436-вимірний бінарний вектор, де 1 у певному розряді позначала наявність відповідного слова у лікарських записах пацієнта. Таким чином, ми отримали 9544 розріджених бінарних вектора. Вибірку поділили на тренувальну/тестову у відношенні 75/25 та виконали навчання з оцінкою точності (*accuracy*) [6]. Для порівняння на цих самих підвбірках ми виконували поряд з власною реалізацією JNBВ реалізації NBC, Chow-Liu та TAN з бібліотек Scikit-learn і pyagrum. З метою зменшення впливу випадковості, ми зробили 4 експерименти з різними розбиттями і усереднили отримані параметри. Для JNBВ без підбору гіперпараметрів, щоб оцінити вплив вибору матриці A , ми виконували тести на 500 випадкових матрицях.

Результати експериментів наведені на рис.1 і 2. Значення точності JNBВ без підбору матриці A (Алгоритмом 1) представлені у вигляді бокс-плотів на рис. 1. Помаранчевий графік демонструє останній прогін Алгоритму 1 з випадково згенерованою матрицею A . Чорний графік показує точність за Алгоритмом 3. Емпіричним шляхом визначили, що достатньо зробити 4 ітерації навчання ($T=4$). Логарифмічна шкала на рис. 2 обрана для зручності порівняння часу виконання алгоритмів, що сильно відрізняється за масштабом.





РИС.1. Результати експерименту: точність.

РИС. 2. Результати експерименту: час роботи (JNBV – з навчанням, $T=4$).

З Рис. 1 видно, що на малих розмірностях моделі (що є цільовими для нашого дослідження), приблизно до 90 параметрів, навіть JNBV з випадковою матрицею демонструє стабільно кращі результати за класичні алгоритми. Це пояснюється використанням інформації з менш інформативних атрибутів, які класичні алгоритми відкидають. Тренування гіперпараметрів стійко підвищує точність за рахунок відбраковування невдалих проєкцій.

Рис. 2 демонструє перевагу JNBV з тренуванням гіперпараметрів порівняно з Chow-Liu і TAN також у продуктивності. Причому відставання від NBC із зростанням розмірності моделі є повільнішим, ніж у інших алгоритмів.

5 Висновки

Запропонований алгоритм Jumbled Naïve Bayes Booster (Перемішуючий наївний байєсів підсилювач) дозволяє значно зменшити розмірність і позбутись залежності між атрибутами для застосування методу Байєса, що є важливим для запобігання перенавчання при класифікації на коротких навчальних вибірках з багатьма малоінформативними атрибутами. Природна паралельність і відносно мала обчислювальна складність навчання та застосування моделей (тотожна складності наївного методу Байєса з додатковим множенням розрідженого бінарного вектора на цілочисельну матрицю) також є сильними сторонами цього алгоритму.

Нааявність даних

Відкриті коди програм і дані, на яких проводились експерименти, доступні за посиланням <https://github.com/Ivan-Denkov/Jumbled-NBC>.

Список посилань

1. C. Chow, C. Liu. Approximating discrete probability distributions with dependence trees. IEEE Trans. on Inform. Theory. 1968, 14(3), p. 462–467 DOI: <https://doi.org/10.1109/TIT.1968.1054142>
2. N. Friedman, D. Geiger, M. Goldszmidt. Bayesian Network Classifiers. Machine Learning. 1997, 29, p. 131–163. DOI: <https://doi.org/10.1023/A:1007465528199>
3. F.R. Dastjerdi, L. Cai. Augmenting Naïve Bayes Classifiers with k-Tree Topology. Mathematics. 2025, 13, 2185. DOI: <https://doi.org/10.3390/math13132185>
4. C. Wan, A. A. Freitas. Hierarchical Dependency Constrained Tree Augmented Naïve Bayes Classifiers for Hierarchical Feature Spaces. ArXiv, 2022. DOI: <https://doi.org/10.48550/arXiv.2202.04105>
5. Y. Bai, M. Bain. Optimizing weighted lazy learning and Naïve Bayes classification using differential evolution algorithm. Journal of Ambient Intelligence and Humanized Computing. 2022, 13(6), p. 3005–3024. DOI: <https://doi.org/10.1007/s12652-021-03135-7>
6. Празднікова М.О., Денков І.Д. Модель прогнозування цереброваскулярних хвороб. Проблеми керування та інформатики, 2026, №1, с. 34–48. DOI: <https://doi.org/10.34229/1028-0979-2026-1-3>
7. Bishop C. M. Pattern Recognition and Machine Learning. New York : Springer, 2006. 738 p.