

استخدام المقدرات الحصينة في الدوال التمييزية

م.م. سري صباح كتيب
جامعة المأمون

أ.م.د. خلود يوسف خمو
كلية الإدارة والاقتصاد / جامعة بغداد

Use Robust estimators in discriminate functions

Assis. Lec. Sura sabah ktiteb
Uni. Of Al. Mamon

Assis. Proof. Dr. Khlood Yousef Hamo
College of Admin. & Eco. Baghdad Uni.

تاريخ قبول النشر ٢٠١٥/١١/٢٣

تاريخ استلام البحث ٢٠١٥/٦/١٥

المخلص:

إنّ دوال التمييز التقليدية قد درست من قبل العديد من الباحثين ووجدوا إنها أقلّ حصانة عند عدم تحقق بعض الفرضيات المتعلقة بدوال التمييز ولا سيما مع وجود القيم الشاذة، وقام الباحثون بالتركيز على مدى عشر سنوات على مقدرات حصينة كانت صعبة الحساب سابقاً لكن مع التطور في صناعة الحواسيب من الناحيتين المادية والبرمجية أمكن حساب مقدرات حصينة والتي تزودنا بأسلوب جديد في التعامل مع البيانات مقارنة مع المقدرات التقليدية، وكانت فكرة البحث استخدام مقدرات حصينة مقاومة لتأثير الشواذ كمقدر H الحصين، مقدر S الحصين ومقدر MCD الحصين كذلك تحصين احتمال خطأ التصنيف مع بيان تأثير الشواذ على نسبة خطأ التصنيف عند استخدام الطرائق التقليدية، ومن ضمن أهداف البحث مقارنة المقدرات للتعرف على أفضل مقدر والذي يعطي أقل احتمال لخطأ التصنيف ولا سيما مع تنوع نسب التلوّث وأحجام عينات مختلفة.

الكلمات المفتاحية: مقدرات حصينة ، دوال تمييزية.

Abstract:

The classical discriminate functions have been taught by many researchers, and they found that it is less robustness when some assumptions related with discriminate functions are not achieved specially with the outliers existence, thus the researchers for the last ten years concentrated on robust estimators which was difficult to compute before. But with the development in manufacturing computes from both hardware and software sides, complicated robust estimators became computable and it gives us a new way of dealing with the data compared to the classical estimators . So, the idea of the research is to use robust estimators which are resistant to the outlier influence like robust H estimator, robust S estimator and robust MCD estimator ,and also robust misclassification probability with showing outlier influence on the percentage of misclassification when using classical methods, some of the research aims are to compare estimators to find the best estimator which can give minimum probability of misclassification especially with the variety of contamination percentage and different sample sizes and the data contaminated.

Key words: estimator, MCD estimators ,misclassification ,robustness
Use Robust estimators in discriminate functions.

1 . المقدمة:

إنَّ التحليل المميز يصف المجتمعات من خلال الكشف عن الاختلافات الموجودة بين مفردات مجتمع معين وان مسألة تصنيف مفردة واحدة إلى أحد المجتمعات يدعى بأسلوب التمييز، وهناك استخدامان للتمييز الأول: وصف وتقدير البيانات من خلال تحديد المضامين التشخيصية للبيانات، والثاني التنبؤ والذي يزودنا بتقدير شامل لكفاءة قواعد التصنيف.

قد درست دوال التمييز التقليدية من قبل العديد من الباحثين ووجد أنها أقل حصانة عند عدم تحقق بعض الفرضيات المتعلقة بدوال التمييز بوجود القيم الشاذة، لذا قام الباحثون بالتركيز في عشر سنوات الأخيرة على مقدرات حصينة لتحسين دوال التمييز إذ تزودنا المقدرات الحصينة بأسلوب جديد في التعامل مع البيانات مقارنة مع المقدرات التقليدية المعروفة.

2.1 هدف البحث:

نظراً لإخفاق طرائق التحليل المميز التقليدية في تحقيق خواصها المثلى عند احتواء البيانات على نسب من الشواذ وبالتالي إخفاقها في الوصول على أقل احتمال لخطأ التصنيف، لذا كانت فكرة البحث استخدام مقدرات حصينة مقاومة لتأثير الشواذ ومن تلك المقدرات مقدر H الحصين، مقدر S الحصين ومقدر MCD الحصين.

وتم تحسين احتمال خطأ التصنيف والذي استخدم لأول مرة على مستوى القطر مع بيان تأثير الشواذ على نسب خطأ التصنيف عند استخدام الطرق التقليدية، ومن ضمن أهداف البحث مقارنة المقدرات للتعرف على أفضل مقدر والذي يعطي أقل احتمال لخطأ التصنيف لاسيما مع تنوع نسب التلوين وإحجام العينات المختلفة بإتباع أسلوب المحاكاة إذ تم تلوين البيانات بأسلوب لم يتطرق إليه أي بحث على مستوى القطر.

2. الجانب النظري:

1.2 مقدر Huber الحصين [5,7,8,12]

يعتمد هذا المقدر على موازنة المشاهدات لتقليل تأثير الشواذ وأن عائلة M تعتمد على تقديرات الأوساط الحسابية والتباينات الموزونة ومن هذه الطرائق طريقة Huber ويمكن توضيح الطريقة كما يلي:

1. تحسب مسافة مهنوبس لكل مشاهدة وكالاتي:

$$D(\underline{x}_i, \underline{x}) = [(\underline{x}_i - \underline{T}(\underline{x}))' S^{-1}(\underline{x})(\underline{x}_i - \underline{T}(\underline{x}))]^{1/2} \quad \dots (1)$$

وان

$$T(x) = \frac{1}{n} \sum_{i=1}^n x_i \quad \dots (2)$$

$$S(x) = \frac{1}{n} \sum_{i=1}^n (x_i - T(x))(x_i - T(x))' \quad \dots (3)$$

2. لتشذيب البيانات يعاد حساب المتوسطات ومصفوفة التباينات إذ تبدل $T(x)$ و $S(x)$ بأوزان تعتمد على d_i أي

$$T^*(x) = \frac{\sum w_i x_i}{\sum w_i} \quad \dots (4)$$

$$S^*(x) = \frac{\sum w_i (x_i - T^*(x))(x_i - T^*(x))'}{\sum w_i^2} \quad \dots (5)$$

وان

$$w_i = \begin{cases} 2d_i & \text{if } d_i > 2 \\ 1 & \text{if } d_i \leq 2 \end{cases}$$

ثم يعاد حساب الخطوة (2) بصورة تكرارية بالاعتماد على نتائج التكرار السابق ونتوقف عندما يكون الفرق بين تكرارين متعاقبين قليلاً وفق مستوى معين من الدقة، إذ يتم الحصول على بيانات مشذبة لكافة المجاميع، ويتم ضرب القيم بالتكرار الأخير بالمتغيرات كافة ولكافة المجاميع عندها يتم تطبيق الدالة التمييزية الخطية والتربيعية.

2.2 مقدار S الحصين:

هناك طرائق مختلفة لبناء قاعدة التمييز أي تحديد المشاهدة الجديدة x هل تنتمي إلى p_1 أو p_2 ؟ والطريقة الشائعة قاعدة التمييز الخطية لفشر Fisher's Linear Discriminant Rule والتي تدرج تحت الفرضية $\Sigma_1 = \Sigma_2 = \Sigma$ وان [3,11]

$$A(x) = x'\lambda - k \quad \dots (6)$$

إذ

$$\lambda = \Sigma^{-1}(\underline{\mu}_1 - \underline{\mu}_2) \quad \dots (7)$$

$$k = \left(\frac{\underline{\mu}_1 + \underline{\mu}_2}{2} \right) \lambda$$

وتؤشر $x \in R^p$ التي تأتي من المجتمع الأول إذا كان

$$A(x) > \ln \left(\frac{C_2 \pi_2}{C_1 \pi_1} \right) = \tau \quad \dots (8)$$

إذ C_1 و C_2 كلفة خطأ التصنيف للمجموعة (1) والمجموعة (2).

π_1 و π_2 الاحتمال السابق للمجتمع (1) والمجتمع (2) x تعود للمجتمع الأول p_1 .

وان $\pi_2 = 1 - \pi_1$ وفي حالة التطبيق فإن π_1, π_2, C_1, C_2 غير معروفة ولهذا توضع $\tau = 0$ وبإعادة كتابة (6).

$$A(x) = \frac{1}{2} [d_{\mu_2, \Sigma}^2(x) - d_{\mu_1, \Sigma}^2(x)] \quad \dots (9)$$

إذ

$$d_{\mu_j, \Sigma}^2(x) = (\underline{x} - \underline{\mu}_j)' \Sigma^{-1} (\underline{x} - \underline{\mu}_j) \quad \dots (10)$$

هي مسافة مهنوبس بين x و μ_j .

واضح ان التقدير التقليدي (متجه المتوسط ومصفوفة التباين المشترك المدمجة) تتأثر بقوة بالشواذ فيكون التقدير $A(x)$ غير حصين وقوة وتم تقليل تأثير الشواذ بواسطة مقدرات M للمتوسط والتباين المشترك لكل مجتمع، ولكن ضعف مقدر M هو في نقطة الانهيار Breakdown point والتي هي كسر عالي من الشواذ إذ المقدر يمكن أن يقاوم بضعف الأبعاد العالية، لذا تم استخدام مقدر ذو انهيار عالٍ يعتمد على مقدر أصغر قطع بيضوي فالعينة $x_1, \dots, x_n$ تعرف كثنائي (t_n, C_n) والتي تقلل محددة C تحت القيد الاتي:

$$\frac{1}{n} \sum_{i=1}^n \rho[\sqrt{(\underline{x}_i - t)' C^{-1} (\underline{x}_i - t)}] = b \quad \dots (11)$$

وتحت كل الأزواج الممكنة (t, C) إذ $t \in R^p$ و C هي مصفوفة متماثلة موجبة التحديد positive definite $p \times p$ ، والدالة ρ يجب أن تكون متماثلة مستقرة وغير متناقصة في الفترة $[0, \infty)$ ، ولها مشتقة مستمرة في عدد محدود من النقاط وان $\rho(0) = 0$ والثابت b يوضح بالشكل $E_{f_0}[\rho(\|Z\|)]$ حيث تمثل F_0 توزيع الأنموذج المركزي وللحصول على الاتساق عند التوزيع الطبيعي ناخذ $F_0 = N(0, I_p)$ ان الاختيار الشائع إلى ρ هو دالة Biweight:

$$\rho(u) = \min \left(\frac{u^2}{2} - \frac{u^4}{2c^2} + \frac{u^6}{6c^4}, \frac{c^2}{6} \right) \quad \dots (12)$$

إذ c ثابت يحقق قيمة مركزية لنقطة الانهيار ويسمى مقدر (Biweight estimator).

3.2 مقدر MCD الحصين: [6]

يعرف بأنه أصغر محددة تباين مشترك Minimum Covariance Determinant كمتوسط $\hat{\mu}_{j,0}$ ومصفوفة تباين مشترك $\hat{\Sigma}_{j,0}$ لـ h_j من المشاهدات من n_j والتي تكون مصفوفة التباين المشترك أقل ما يمكن إذ إن:

$$h_j > [(n_j + P + 1)/2] \quad \dots (13)$$

وان $n_j - h$ يجب أن تكون أقل من عدد الشواذ في z من المجتمعات وبسبب كون العدد غير معروف في كل مجموعة فتؤخذ:

$$h_j = [(n_j + P + 1) / 2] \approx 50\% \quad \dots (14)$$

ويوصى بأخذ $h_j \approx 0.75n_j$.

وبالاعتماد على التقديرات الأولية $\hat{\mu}_{j,0}$ و $S_{j,0}$ لكل مشاهدة x_{ij} وللمجموعة j تحسب المسافة الحصينة.

$$RD_{ij}^0 = \sqrt{(x_{ij} - \hat{\mu}_{j,0})' S_{j,0}^{-1} (x_{ij} - \hat{\mu}_{j,0})} \quad \dots (15)$$

ويعطي الوزن w_i كالآتي:

$$RD_{ij}^0 = \begin{cases} 1 & \text{if } RD_{ij}^0 \leq \sqrt{\chi^2_{p,0.975}} \\ 0 & \text{otherwise} \end{cases} \quad \dots (16)$$

ومن ثم نحصل على مقدر MCD للمجموعة j كمتوسط $\hat{\mu}_{j,MCD}$ ومصفوفة تباين مشترك $\hat{\Sigma}_{j,MCD}$ لملاحظات المجموعة j والتقديرات الحصينة للموقع والتشتت تسمح لنا برصف الشواذ في البيانات، وتعطي تقديرات أكثر حصانة لاحتمال خطأ التصنيف ثم تحسب لكل مشاهدة x_{ij} بالمجموعة j المسافة الحصينة النهائية كالآتي:

$$RD_{ij} = \sqrt{(x_{ij} - \hat{\mu}_{j,MCD})' \hat{\Sigma}_{j,MCD}^{-1} (x_{ij} - \hat{\mu}_{j,MCD})} \quad \dots (17)$$

وان x_{ij} قيمة شاذة إذا وفقط إذا $RD_{ij} > \sqrt{\chi^2_{p,0.975}}$ وبفرض ان $\tilde{n}_j$ تشير الى عدد غير الشواذ في المجموعة j وان $\tilde{n} = \sum_{j=1}^g \tilde{n}_j$ ويمكن تقدير احتمال خطأ التصنيف بحصانة كالآتي:

$$\hat{P}_j^R = \frac{\tilde{n}_j}{\tilde{n}} \quad \dots (18)$$

4.2 قواعد التمييز الخطية الحصينة: [6]

بإعطاء التقدير الحصين لمراكز المجموعة $\hat{\mu}_j$ ومصفوفة التباين المشترك $\hat{\Sigma}_j$ فإن قاعدة التمييز الخطية الحصينة (RLDR(Robust Linear Discriminant Rule) كالآتي:

تعيين x إلى π_k إذا:

$$\hat{d}_k^{RL}(x) > \hat{d}_j^{RL}(x), \quad \forall j=1, \dots, g, \quad j \neq k \quad \dots (19)$$

وإن:

$$\hat{d}_j^{RL}(x) = \hat{d}_j^{RL}(\underline{x}, \underline{\hat{\mu}}_j, \hat{\Sigma}_j) = \underline{\hat{\mu}}_j' \hat{\Sigma}_j^{-1} x - \frac{1}{2} \underline{\hat{\mu}}_j' \hat{\Sigma}_j^{-1} \underline{\hat{\mu}}_j + \ln(\hat{P}_j^R) \quad \dots (20)$$

وإن احتمال $\hat{P}_j^R$ يمكن أن يقدر كما في (18) وإلى $g=2$ فإن قاعدة التصنيف للصيغة (20) هي قاعدة التمييز لفشر للعينه يمكن أن توصف كالآتي:

$$\begin{cases} x \in \pi_1 & \text{if } (\underline{\hat{\mu}}_1 - \underline{\hat{\mu}}_2)' \hat{\Sigma}^{-1} (x - (\underline{\hat{\mu}}_1 + \underline{\hat{\mu}}_2)/2) > 0 \\ x \in \pi_2 & \text{otherwise} \end{cases}$$

ولبناء قاعدة التمييز الخطية الحصينة RLDR بعد أن ننظر إلى المقدرات الأولية لمتوسط المجاميع ومصفوفة التباين المشترك والتي يرمز لها بـ $\hat{\mu}_{j,0}$ و $\hat{\Sigma}_0$ وبالاعتماد على $\hat{d}_j^{RL}(x, \hat{\mu}_{j,0}, \hat{\Sigma}_0)$ فإن المسافة الحصينة.

$$RD_{ij}^0 = \sqrt{(x_{ij} - \hat{\mu}_{j,0})' \hat{\Sigma}_0^{-1} (x_{ij} - \hat{\mu}_{j,0})} \quad \dots (21)$$

ولكل مشاهدة في المجموعة j نفرض

$$w_{ij} = \begin{cases} 1 & \text{if } RD_{ij}^0 \leq \sqrt{\chi_{p,0.975}^2} \\ 0 & \text{otherwise} \end{cases}$$

وللحصول على تقديرات التباين المشترك الأولية $\hat{\Sigma}_0$ هناك ثلاث طرق مختلفة وهي:

الطريقة الأولى [3,6]

طبقت لأول مرة من قبل Chork & Rousseeuw (1992) باستخدام مقدر MVE و Croux & Dehon (2001) باستخدام مقدر S فبعد الحصول على تقديرات MCD وهي $\hat{\mu}_{j,MCD}$ و $\hat{\Sigma}_{j,MCD}$ لكل مجموعة فإن مصفوفة التباين المشترك المدمجة PCOV هي:

$$\Sigma_{PCOV} = \frac{\sum_{j=1}^g n_j \hat{\Sigma}_{j,MCD}}{\sum_{j=1}^g n_j} \quad \dots (22)$$

الطريقة الثانية: [5,7,8,12]

فكرتها تعتمد على دمج المشاهدات POBS من دون مصفوفة التباين المشترك للمجموعة وهي تحديث للطريقة المعطاة من قبل He & Fung (2000) والذين استخدموا مقدر S لدالة التمييز الخطية الحصينة ففي حالة العينتين $x_{11}, x_{21}, \dots, x_{n1,1}, x_{12}, x_{22}, \dots, x_{n2,2}$ ومن مجتمعين متوسطهما μ_1 و μ_2 ومصفوفة التباين المشترك Σ .

أولاً: نقدر μ_1 و μ_2 كتقدير الموقع للمجموعتين باستخدام مقدر MCD ذات الأوزان المعادة.

ثانياً: تدمج مراكز المشاهدات لتصبح بالشكل Z's كالآتي:

$$(z_1, \dots, z_{n1+n2}) = (x_{11} - \hat{\mu}_1, \dots, x_{n1,1} - \hat{\mu}_1, x_{12} - \hat{\mu}_2, \dots, x_{n2,2} - \hat{\mu}_2)$$

ثالثاً: نقدر مصفوفة التباين Σ باستخدام مقدر MCD ذات الأوزان المعادة لـ Z's التقدير الجديد لـ μ_1 يصبح $\hat{\mu}_1 + \hat{\delta}$ وكذلك لـ μ_2 يصبح $\hat{\mu}_2 + \hat{\delta}$ تتجز هذه الخطوات التكرارية عدة مرات، لكن في حالة مقدر MCD يتطلب خطوات إضافية لتحسين النتائج.

الطريقة الثالثة: [4]

فكرتها هي دمج مقدرات الطريقتين السابقتين وتهدف إلى إيجاد تقريب سريع لأصغر محددة تباين مشترك داخل المجموعة MWCD والمقاسة من قبل McLachlan & Hawkins (1997) بدلا من تطبيق النسب التجريبية لكل مجموعة، بفرض إيجاد h من المشاهدات خارج مجموعة البيانات ذات حجم n بحيث إن عينة مصفوفة التباين المشترك داخل المجاميع المدمجة $\hat{\Sigma}_H$ لها أقل محددة وإن:

$$\delta_{ij} = \begin{cases} 1 & \text{if } x_{ij} \in H \\ 0 & \text{if } x_{ij} \notin H \end{cases} \quad \dots (23)$$

5.2 قواعد التمييز التربيعية الحصينة: [6]

قاعدة التمييز التربيعية الحصينة RQDR Robust Quadratic Discriminant Rule تكون بوضع x إلى π_k إذا:

$$\hat{d}_k^{RQ}(x) > \hat{d}_j^{RQ}(x) \quad \forall j=1, \dots, g \neq k \quad \dots (24)$$

وإن

$$\hat{d}_j^{RQ} = -\frac{1}{2} \ln |\hat{\Sigma}_{j,MCD}| - \frac{1}{2} (x - \hat{\mu}_{j,MCD})' \hat{\Sigma}_{j,MCD}^{-1} (x - \hat{\mu}_{j,MCD}) + \ln(\hat{P}_j^R) \quad \dots (25)$$

6.2 احتمال خطأ التصنيف:

6.2.1 طريقة التعويض: [9]

افرض إن التمييز يعتمد على مصفوفة البيانات X لـ n_j والتي تأتي من المجتمع z وإذا كانت قاعدة التمييز معرفة بواسطة مناطق التوزيع R_i ويفرض أن n_{ij} عدد المفردات في $\prod_i$ والتي تقع في R_i بحيث إن $\sum_i n_{ij}$ فإن تقدير احتمال خطأ التصنيف يكون:

$$\hat{P}_{ij} = \frac{n_{ij}}{n_j} \quad \dots (26)$$

6.2.2 طريقة Jack-Knifing U لـ

المشكلة في طريقة التعويض هي نفس المشاهدات تستخدم لتعريف قاعدة التمييز Discriminant Rule والحكم على دقتها وإحدى الطرائق لتجنب هذه المشكلة هي طريقة U لـ Jack-Knifing وتعرف كالاتي:

افرض أن $r=1, \dots, n$ و x_r هو أول n_1 من الأسطر للمصفوفة X والتي تمثل المجتمع الأول $\prod_1$ ولكل r افرض أن $R_1^{(r)}, \dots, R_g^{(r)}$ تعرف كمناطق لبعض قواعد التمييز والتي تعتمد

على مصفوفة $(n-1) \times p$ والتي تحصل عليها بحذف السطر r^{th} من X فإن x_r يمكن أن نحكم عليها على أساس القاعدة وهي غير مشتقة من X_r .

إذا رمزنا n^*_{i1} عدد مفردات $n_1 \perp R_i^{(r)} \ni x_r$ ، فإن:

$$P^*_{i1} = n_{i1} / n_i \quad \dots (27)$$

وهو تقدير لاحتمال خطأ التصنيف وبواسطة تكرار الإجراء لبقية المجتمعات $j=1, \dots, g$ نحصل على تقدير p^*_{ij} ، وهذه الطريقة تقود لتقدير معول عليه لاحتمال خطأ التصنيف مقارنة مع الطريقتين السابقتين.

7.2 اختبارات التمييز: [2,10]

7.2.1 اختبار المتغيرات ذات القوة التمييزية المعنوية والتي تتبع أقل خطأ تصنيف:

هناك عدة أساليب منها الاختيار المتدرج Stepwise Selection وفيها يكون اختيار دالة التمييز القياسي لمعنوية الفرق بين متوسطات المجاميع تعميم متعدد المتغيرات لمقياس Wilk's Lambda أحادي المتغير وبأخذ التباينات المشتركة بنظر الاعتبار إذ يوفر مقياس Wilk's Lambda متعدد المتغيرات و P من المتغيرات.

$$\hat{P} = |W_{pp}| / |T_{pp}| \quad \dots (28)$$

وإن:

W : مصفوفة مجموع مربعات الانحرافات داخل المجاميع.

T : مصفوفة مجموع مربعات الانحرافات الكلية وتكون إحصائية F المناظرة المستندة على أساس هذا المقياس كالآتي:

$$F(\hat{P}) = [1 - \hat{P}] [n - P - 1] / \hat{P} P \quad \dots (29)$$

والتي تتوزع $F_{1, n-p-1}$. وعلى أساس هذه الاحصائية هناك اساليب متدرجة تستخدم لاختيار المجموعة الجزئية J من المتغيرات منها الاختيار بالحذف الشرطي، الاختيار المتقدم Forward Selection، الاختيار التراجعي Backward Selection وطريقة الاختيار الكامل All possible selection.

2-7-2 اختبار دالة التمييز بعد حذف المتغيرات غير التمييزية:

ومن هذه الاختبارات

أ. اختبار تساوي المجموعات:

وهناك عدة صيغ للاختبار منها مقياس مربع كاي إذ إن:

$$\chi^2 = -[n - 1 - 1/2(p + g)] \log \hat{e} \quad \dots (30)$$

والذي يتوزع تقريباً مربع كاي بدرجة حرية $p(g-1)$.

ب. اختبار تساوي مصفوفة التباين والتباين المشترك:

إنَّ احصائية الاختبار

$$M = \sum_{i=1}^g n_i \ln|S| - \sum_{i=1}^g n_i \ln|S_i| \quad \dots (31)$$

وقد اثبت Box إذا ضرب M في ثابت C^{-1} والذي يساوي:

$$C^{-1} 1 - \frac{2p^2 + 3p + 1}{6(p+1)(g-1)} \left[\sum_{i=1}^g \frac{1}{n_i} - \frac{1}{\sum_{i=1}^g n_i} \right] \quad \dots (32)$$

فإننا نحصل على مقياس Box's M والذي يتوزع تقريباً مربع كاي بدرجة حرية $(g-1)(p-1)/2$.

3. الجانب التجريبي:

وهنا تم محاكاة حالات مختلفة فالمحاكاة هي تقليد الواقع العملي بحيث نقوم بتوظيف أو تكوين نماذج يظهر فيها عدد كبير من الحالات الافتراضية لتكون نتائج التحليل أكثر شمولية وتعميم وقد كثر الاستعانة بها بسبب التطور الحاصل في صناعة الحواسيب من الناحيتين المادية (Hardware) والبرمجية (Software).

وغالباً ما يتم اللجوء لأسلوب المحاكاة للتأكد من صحة جانب تطبيقي موجود أصلاً أو لصعوبة الحصول على بيانات توفر معلومات دقيقة عن ظاهرة معينة أو عندما يصعب إثبات البرهان الرياضي بشكل نظري لبيان أفضلية طرائق تقدير معينة على حساب أخرى. وللمحاكاة مرونة في اختيار أحجام العينات العشوائية المفترض بها تمثل مجتمع الدراسة وكذلك القدرة على التنوع بالأخطاء العشوائية وتنوع حالات التلوّث في البيانات وأيضاً القدرة على إجراء التجربة لعدد كبير من المرات بهدف التوصل على نتائج يعول عليها.

3.1 توليد المتغيرات والمتغيرات المستخدمة:

تم تنفيذ تجارب المحاكاة إذ تم استخدام أحجام عينات صغيرة، متوسطة، وكبيرة وكالاتي $n=40$, $n=60$, $n=100$ وكل حجم عينة هو المجموع الكلي لمفردات مجتمعين بحيث إنَّ مفردات المجتمع الأول تساوي مفردات المجتمع الثاني وبواقع (27) تجربة وبتكرار (1000) لكل تجربة ولكل حالة تم أخذ ثلاثة أحجام من المتغيرات التوضيحية وهي ثلاثة وستة وتسعة ولحالة التوزيع الطبيعي للخطأ العشوائي للحالة النظيفة clean بالإضافة لحالة تلوّث البيانات بقيم شاذة وبنسبتي تلوّث 10% و 20% وتم الاعتماد على الإمكانية العالية لبرنامج MATLAB إذ تم إجراء عدة خطوات للحصول على البيانات وكما يلي:

1. تم توليد البيانات بالشكل النظيف (غير الملوث) للمجتمع الأول والمجتمع الثاني استعانة بالدالة المكتبية Rand والتي تعمل على توليد خلايا من الأرقام العشوائية والتي تتوزع توزيعاً طبيعياً بمتوسط 0 وتباين $\sigma^2 = 1$ ، ومن ثم تحويل البيانات من التوزيع $N(0,1)$ الى التوزيع $N(\mu,1)$ من خلال العلاقة $X=Z+\mu$ وبهذه الطريقة تم توليد بيانات المجتمع الأول بتوزيع $N(-1,1)$ وللمجتمع الثاني بتوزيع $N(1,1)$ ومن ثم توليد متجه واحد بعد إعطاء ترميز للمجتمع الأول الرقم (1) والمجتمع الثاني (2) لكي يمثل هذا المتجه المتغير y وبالتالي حصلنا على مصفوفة ذات عدة أبعاد إذ يمثل عدد صفوفها (n_1+n_2) وإن n_1, n_2 تمثل قيم العينة للمجتمع الأول والثاني على التوالي أما أعمدتها فتتمثل عدد المتغيرات X 's والتي تم أخذها بعدة حالات هي الأولى: تم أخذ ثلاثة متغيرات والثانية: ستة متغيرات والثالثة: تسعة متغيرات أما العمود الأخير فيمثل المتغيرات المعتمدة y_1, y_2 إذ إن y_1 يتراوح عددها من $(1, \dots, n_1)$ و y_2 من $(n_1+1, \dots, n_1+n_2)$.

2. توليد المتغيرات بالشكل الملوث إذ تم إتباع أسلوب توليد متغيرات التوزيع الطبيعي نفسه لتوليد البيانات النظيفة بمتوسط μ وتباين 1 وتم استقطاع جزء من البيانات بنسبة 10% و 20% والتي تمثل نسب التلوث ولكل حجم عينة وللمجتمع الأول والثاني باستخدام نفس دالة التوليد Randn لكن يكون توزيع الشواذ للمجتمع الأول $N(9,1)$ والمجتمع الثاني $N(-9,1)$ وتوجد ثلاث حالات للتلويث التي تمثل تأثير الشواذ Outliers وهي كالآتي:

الحالة الأولى: التلويث باستخدام متوسطات غير متساوية ومصفوفات تباين مشترك متساوية Unequal Means and Equal Covariance's Matrices إذ المجتمعات لها نفس مصفوفة التباين المشترك لكن متوسطات مختلفة بسبب تساوي مصفوفات التباين المشترك مع ملاحظة انه في حالة تساوي مصفوفات التباين المشترك القيم النظرية للاحتمال الكلي لخطأ التصنيف للقاعدة التربيعية هو نفسه للقاعدة الخطية ولحالة التلويث بالشواذ المقدرات الحصينة هي الأفضل بشكل واضح.

الحالة الثانية: التلويث باستخدام مصفوفات التباين المشترك غير المتساوية ومتوسطات Equal Means and Unequal Covariance Matrices بفرض أن المجتمعات لها نفس المتوسط لكن مصفوفات التباين المشترك مختلفة، وفي حالة تساوي المتوسطات وعدم تساوي مصفوفات التباين المشترك يلاحظ بأنه هناك فروقات بين التحليل المميز الخطي والتربيعي ويكون الأخير هو الأفضل بسبب الطريقة الخطية تفترض تساوي مصفوفة التباين المشترك.

الحالة الثالثة: التلويت باستخدام متوسطات ومصفوفات التباين المشترك غير متساوية Unequal Means and Unequal Covariance Matrices) إذ يفترض المجتمعات لها متوسطات مختلفة ومصفوفات تباين مشترك مختلفة وهذه الحالة هي الأكثر أنموذجية (مثالية).

3.2 البرمجيات Software:

تم تنفيذ تجارب المحاكاة بكتابة برنامج في نظام Matlab والخاصة بمقدرات H الحصينة، إذ يعد من البرامج ذات الإمكانية المتقدمة في الجوانب الإحصائية والرياضية والهندسية حيث يوظف الأدوات بشكل مستقيم لبرمجة متقدمة جداً إذ امتازت طرائق التقدير الحصينة بدرجة من التعقيد كالحاجة إلى لغة برمجة متقدمة Matlab.

3.3 سير عملية المحاكاة:

1. تجري عملية تغذية برنامج المحاكاة بالمدخلات التي حددت.
2. يجري توليد البيانات وفقاً للحالات المفترضة في الخطوة (1) ووفقاً لبرنامج فرعية ثم ترسل البيانات المولدة إلى البرنامج الرئيسي.
3. تم تطبيق الطرائق غير الحصينة المتمثلة بالدالة المميزة الخطية (LDF) والدالة المميزة التربيعية (QDF).
4. تم تطبيق المقدرات الحصينة وهي مقدار H الحصين، مقدار S الحصين ومقدار MCD الحصين على الدالة المميزة الخطية والتربيعية.
5. تم الاعتماد على حساب معيار احتمال خطأ التصنيف في عملية المقارنة بين الطرائق غير الحصينة والحصينة وتم التفضيل بين المقدرات وفق معيار أقل احتمال خطأ تصنيف.

3.4 مناقشة نتائج المحاكاة:

1. الحالة الطبيعية:

تم توليد البيانات وفقاً للحالة الطبيعية (clean) ومن ثم طبقت الطرائق غير الحصينة والحصينة عليها وتمثل الجداول (1) و (2) و (3) نتائج تحليل الطرائق التمييزية للبيانات المولدة النظيفة للدوال المميزة الخطية والتربيعية للمقدر التقليدي، مقدار H الحصين، مقدار S الحصين، مقدار MCD الحصين. أما الجدول رقم (10) فيمثل احتمال خطأ التصنيف للبيانات المولدة النظيفة والدوال المميزة الخطية والتربيعية للمقدر التقليدي، مقدار H الحصين، مقدار S الحصين، مقدار MCD الحصين، يلاحظ وعند استخدام المتغيرات $p=3$ ، $p=6$ ، $p=9$ ولأحجام العينات $n=40$ ، $n=60$ ، $n=100$ ان مقدار MCD الحصين وللدالتين الخطية والتربيعية هو الأفضل يليه من حيث الأفضلية مقدار S الحصين ثم مقدار H الحصين، وبشكل عام عند احتساب معيار احتمال خطأ التصنيف ولأحجام

العينات المختلفة وباختلاف عدد المتغيرات التوضيحية يلاحظ أن الدالة المميزة التربيعية باستخدام مقدار MCD الحصين أعطت أقل احتمال لخطأ التصنيف.

2. حالة تلويث البيانات:

تم توليد البيانات وفقاً لنسب التلويث المعتمدة 10% و 20% وتم تطبيق الطرائق غير الحصينة والحصينة عليها وتمثل الجداول (4) و (5) و (6) و (7) و (8) و (9) نتائج تحليل الطرائق التمييزية للبيانات الملوثة للدوال المميزة الخطية والتربيعية التقليدية، مقدار H الحصين، مقدار S الحصين.

أما الجداول رقم (11) و (12) فتتمثل احتمال خطأ التصنيف للبيانات الملوثة بنسبتي تلويث 10% و 20% وعند استخدام المتغيرات $p=6$ ، $p=9$ ولأحجام العينات $n=40$ و $n=60$ و $n=100$ ولحالة نسبة التلويث 10% و 20% يلاحظ بأن مقدار MCD الحصين وللدالتين الخطية والتربيعية هو الأفضل يليه من حيث الأفضلية مقدار S الحصين ثم مقدار H الحصين. وبشكل عام عند احتساب معيار احتمال خطأ التصنيف ولأحجام العينات المختلفة باختلاف عدد المتغيرات التوضيحية يلاحظ أن الدالة المميزة التربيعية باستخدام مقدار MCD الحصين أعطت أقل احتمال لخطأ التصنيف.

جدول رقم (1)

نتائج تحليل الطرائق التمييزية للبيانات المولدة النظيفة

المعاملات	حجم العينة وعدد المتغيرات	LDF	QDF	LH	QH	LS	QS
constant	(40,3)	-0.2334	0.4190	-0.2262	-0.521	-0.2743	0.6118
Var1		-1.4402	-1.5854	-3.7155	-3.715	-2.0353	-2.1725
Var2		-2.5745	-2.6395	-2.5176	-2.7760	-2.8493	-2.9076
Var3		-1.8152	-2.0192	-2.7185	-1.5710	-1.7534	-1.9763
constant	(40,6)	-1.6842	-1.2415	-1.0051	-1.0810	-1.6623	-1.3836
Var1		-2.2342	-2.5108	-3.5781	-2.6016	-2.3703	-2.599
Var2		-1.7982	-1.5865	-1.9351	-1.860	-1.9156	-1.7018
Var3		-0.5036	-0.6622	-1.2202	0.7613	-0.5853	-0.7335
Var4		-2.2861	-2.6588	-3.7106	-2.3827	-2.3934	-2.7827
Var5		-3.4652	-3.989	-3.6500	-4.5012	-3.7775	-4.3102
Var6		-4.21	-4.0477	-5.3162	-4.2251	-4.5734	-4.3924
constant	(40,9)	1.6126	-15.617	-1.7251	-11.424	1.6506	-17.795
Var1		-4.8584	-6.4061	-6.521	-4.631	-5.0007	-6.5211
Var2		-10.423	-16.589	-2.317	-15.791	-10.476	-17.604
Var3		-7.7244	-12.922	-5.617	-17.8443	-7.5965	-13.632
Var4		-10.338	-18.192	-7.3210	-22.2085	-10.482	-19.102
Var5		-1.6677	-3.0638	-3.7151	-5.0137	-1.6738	-3.1198
Var6		-6.4563	-9.6417	-5.5431	-10.5112	-6.2513	-9.6147
Var7		-2.2634	-3.9932	-3.1774	-4.5391	-2.457	-4.689
Var8		-6.6953	-9.3689	-5.1173	-5.3077	-6.6657	-9.7006
Var9		-6.3971	-12.488	-7.3838	-7.8903	-6.3537	-13.383

جدول رقم (2)

نتائج تحليل الطرائق التمييزية للبيانات المولدة النظيفة

QS	LS	QH	LH	QDF	LDF	حجم العينة و عدد المتغيرات	المعاملات
0.9638	0.5355	0.6471	0.8891	0.7733	0.4729	(60,3)	Constant
-1.0048	-0.7228	-1.7865	-0.0521	-1.1897	-0.8655		Var1
-2.3226	-2.0671	-2.709	-3.8171	-2.1453	-2.0184		Var2
-3.0537	-2.7058	-4.3177	-2.5171	-2.8556	-2.5962		Var3
-1.796	-1.9247	-1.1298	-1.1960	-1.7513	-1.8802	(60,6)	constant
-2.7523	-2.4366	-2.9842	-3.0946	-2.6378	-2.3437		Var1
-3.4852	-3.6971	-4.5866	-2.1844	-3.1795	-3.4026		Var2
-0.4292	-0.7006	-2.1877	-2.3027	-0.4156	-0.6265		Var3
-2.8	-2.307	-1.599	-1.0717	-2.7682	-2.3904		Var4
-2.2722	-2.0307	-3.551	-2.2119	-2.3963	-2.1943		Var5
-4.6176	-4.3633	-6.3470	-3.0324	-4.37	-4.1529		Var6
-0.9404	-0.10912	-0.0691	-1.2801	-0.9987	-0.1354	(60,9)	constant
-4.0746	-3.4741	-3.884	-1.8700	-4.1152	-3.5156		Var1
-0.2018	-0.7815	-0.3261	-0.3086	-0.2865	-0.8376		Var2
-0.9049	-1.5011	-0.0968	-1.4634	-0.9482	-1.532		Var3
-0.7686	-1.5189	-0.6094	-1.9446	-0.7145	-1.4216		Var4
-4.0636	-3.1853	-4.7137	-3.1648	-4.0158	-3.1573		Var5
-0.9169	-0.9019	-0.9987	-0.1652	-0.7995	-0.7635		Var6
-3.0442	-1.9658	-4.2195	-1.550	-3.0309	-1.9513		Var7
-4.925	-3.6621	-3.7363	-1.0637	-4.753	-3.5868		Var8
-3.1233	-2.2832	-2.7581	-1.1159	-3.0106	-2.2232		Var9

جدول رقم (3)

نتائج تحليل الطرائق التمييزية للبيانات المولدة النظيفة

QS	LS	QH	LH	QDF	LDF	حجم العينة و عدد المتغيرات	المعاملات
0.26663	0.500	0.307	0.1935	0.2013	0.0611	(100,3)	constant
-1.4238	-1.5401	-1.674	-1.1157	-1.3824	-1.4981		Var1
-1.6054	-1.4069	-2.6703	-2.761	-1.6569	-1.4083		Var2
-1.6976	-1.5939	-2.501	-2.1682	-1.7384	-1.6135		Var3
1.6073	-0.7016	0.6229	0.26452	1.43	0.6755	(100,6)	constant
-2.6305	-2.4718	-3.5431	-2.2836	-2.7438	-2.5621		Var1
-1.5073	-1.592	-2.4538	-2.1413	-1.458	-1.5492		Var2
-3.1856	-3.1127	-3.3614	-2.2285	-2.761	-2.6681		Var3
-2.3849	-2.2535	-3.3321	-3.6003	-2.2363	-2.1271		Var4
-2.9859	-2.9505	-2.7733	-2.5497	-2.8861	-2.8763		Var5
-2.6971	-2.7359	-2.66	-2.8573	-2.7505	-2.7395		Var6
-0.8183	0.6788	0.5539	0.4550	-1.1008	0.3731	(100,9)	constant
-3.6913	-2.4312	-3.37	-2.8792	-2.976	-2.4469		Var1
-2.8301	-3.1844	-3.8534	-2.5503	-3.2512	-3.0545		Var2
-3.1125	-2.7716	-3.6753	-3.8206	-2.5210	-2.77		Var3
-2.4866	-1.8889	-2.156	-2.8044	-2.3852	-1.8005		Var4
-2.919	-2.5823	-3.4320	-2.7006	-2.7996	-2.5315		Var5
-2.462	-1.8082	-2.17	-1.4527	-2.5094	-1.8101		Var6
-2.4824	-2.2638	-2.8426	-2.2723	-3.1855	-2.2648		Var7
-3.3905	-2.1476	-2.9826	-3.0642	-2.8705	-2.1714		Var8
-2.9612	-2.6647	-2.1248	-2.3346	-3.7035	-2.5801		Var9

جدول رقم (4)

نتائج تحليل الطرائق التمييزية للبيانات المولدة الملوثة ونسبة تلويث 10%

المعاملات	حجم العينة و عدد المتغيرات	LDF	QDF	LH	QH	LS	QS
constant	(40,3)	-0.0135	-0.2674	-0.9461	-0.8251	-0.1144	-0.4952
Var1		0.0722	0.0183	-2.6221	-1.362	-1.2754	-1.1897
Var2		-0.1013	0.1955	-1.7743	-2.3017	-0.8740	-1.4317
Var3		0.0437	-0.1520	-2.2122	-3.7425	-0.5543	-1.4409
constant	(40,6)	0.0013	0.6387	0.6106	1.2986	0.1662	0.6326
Var1		0.0627	0.2841	-1.7253	-0.253	-0.0812	0.2635
Var2		-0.1513	-0.0392	-2.7972	-0.5796	-0.3853	-0.2156
Var3		-0.3497	-0.5212	-0.8622	-0.8292	-0.2032	-0.5376
Var4		-0.1970	-0.5010	-1.3625	-0.0705	-0.0487	-0.4695
Var5		0.2991	0.4604	-2.5959	0.0961	0.1394	0.5181
Var6		0.3131	0.344	-2.2692	0.4618	0.2347	0.3646
constant	(40,9)	0.3971	0.8977	0.351	0.3631	0.2973	0.8623
Var1		-0.1608	-0.3027	-0.0641	-0.5822	-0.1164	-0.3191
Var2		0.4386	0.8161	-2.7796	-0.4376	0.3623	0.7998
Var3		-0.5599	-1.0423	-3.8421	-0.83729	-0.4454	-1.1527
Var4		0.3605	-0.2035	0.9594	-0.7007	0.2254	-0.1625
Var5		-0.8524	-1.5145	-2.6096	0.6789	-0.6878	-1.5652
Var6		0.3135	1.2898	-1.3677	0.0981	0.3516	1.3632
Var7		0.9251	1.9752	-2.5920	0.943	0.6177	2.028
Var8		1.2141	1.8106	0.5809	0.6301	0.9378	1.7676
Var9		-1.5605	-2.6086	0.4355	0.2702	-1.2649	-2.5701

جدول رقم (5)

نتائج تحليل الطرائق التمييزية للبيانات المولدة الملوثة ونسبة تلويث 10%

المعاملات	حجم العينة و عدد المتغيرات	LDF	QDF	LH	QH	LS	QS
constant	(60,3)	-0.0482	0.2338	0.0105	0.241	0.0608	0.3225
Var1		0.3153	0.3005	-2.539	-1.9333	-1.4518	-1.4581
Var2		-0.0802	-0.0685	-1.8482	-2.6601	-1.1602	-1.2268
Var3		-0.2184	-0.2246	-2.9825	-1.5482	-1.8665	-1.9124
constant	(60,6)	-0.1083	-0.2029	-0.2828	-2.2173	-0.2789	-3.3543
Var1		0.0197	0.1182	-2.5504	0.270	0.0567	-1.4128
Var2		-0.2281	-0.2366	-0.8271	-0.2821	-0.3282	-1.6151
Var3		-0.0994	0.0331	-0.0444	-0.3680	-0.0518	-0.7433
Var4		0.0082	0.0451	-0.6746	-0.01213	-0.0802	-1.0007
Var5		0.1025	-0.0885	-0.095	0.2924	0.0052	-0.8691
Var6		0.2046	0.1450	-0.7513	0.0053	0.0815	-1.7295
constant	(60,9)	-0.0526	0.103	0.0087	-0.1293	-0.0366	0.0953
Var1		0.0282	0.1493	0.2525	0.2106	0.0156	0.1452
Var2		-0.1233	-0.2171	-0.1808	-0.8152	-0.1237	-0.2235
Var3		-0.3434	-0.3906	-0.1765	-0.636	-0.3226	-0.3771
Var4		0.2258	0.2225	-0.2513	0.677	0.1966	0.1920
Var5		0.0042	-0.0517	-0.0059	0.0297	-0.0064	-0.0869
Var6		-0.0837	-0.1362	-0.1492	-0.7461	-0.1093	-0.1621
Var7		0.1065	0.2535	0.2553	-0.0261	0.1011	0.2389
Var8		0.1406	0.1433	0.4630	-0.2177	0.1547	0.1233
Var9		0.0214	0.1716	0.5465	-0.2362	0.0245	0.0615

جدول رقم (6)

نتائج تحليل الطرائق التمييزية للبيانات المولدة الملوثة ونسبة تلويث 10%

المعاملات	حجم العينة و عدد المتغيرات	LDF	QDF	LH	QH	LS	QS
constant	(100,3)	-0.0324	-0.2002	-0.2301	-0.5971	-0.4309	-0.0862
Var1		0.0996	0.0721	-0.5560	-0.8531	-0.9280	-0.9784
Var2		-0.1395	-0.13	-1.2655	-1.638	-2.0557	-2.105
Var3		0.0237	0.0331	-1.1479	-1.666	-1.7719	-1.8401
constant	(100,6)	-0.0389	-0.1556	0.543	0.7956	0.1823	0.7066
Var1		-0.0039	-0.0225	-1.5364	-1.3233	-2.0338	-2.1788
Var2		0.3399	0.4339	-1.97	-2.735	-1.0248	-0.9713
Var3		-0.0960	-0.0058	-1.0721	-1.815	-1.9256	-2.039
Var4		0.1029	-0.1835	-1.323	-1.766	-1.8009	-2.1914
Var5		0.2977	0.2777	-1.3477	-2.7389	-1.0474	-1.2093
Var6		-0.4676	-0.5493	-1.3425	-1.4957	-1.3511	-1.4537
constant	(100,9)	0.0399	0.0007	-0.0709	0.5909	0.0187	-0.0431
Var1		0.2717	0.3446	0.1353	0.5242	0.2725	0.3194
Var2		0.2575	0.2556	0.2693	0.665	0.2401	0.2387
Var3		-0.1859	-0.2911	-0.1641	-0.97	-0.2007	-0.3072
Var4		-0.3568	-0.3527	-0.6215	-0.4791	-0.3706	-0.3594
Var5		-0.2739	-0.3854	-0.3852	-0.61	-0.254	-0.3512
Var6		0.1137	0.1362	-0.4910	-0.049	0.0787	0.1037
Var7		-0.0899	-0.1153	0.0105	-0.0535	-0.0807	-0.1100
Var8		0.2037	0.2796	0.001	-0.6465	0.1978	0.2648
Var9		0.0883	0.1583	0.4635	0.9941	0.0985	0.1836

جدول رقم (7)

نتائج تحليل الطرائق التمييزية للبيانات المولدة الملوثة ونسبة تلويث 20%

المعاملات	حجم العينة و عدد المتغيرات	LDF	QDF	LH	QH	LS	QS
constant	(40,3)	-0.0482	0.2338	0.0105	0.241	0.0608	0.3225
Var1		0.3153	0.3005	-2.539	-1.9333	-1.4518	-1.4581
Var2		-0.0802	-0.0685	-1.8482	-2.6601	-1.1602	-1.2268
Var3		-0.2184	-0.2246	-2.9825	-1.5482	-1.8665	-1.9124
constant	(40,6)	-0.1083	-0.2029	-0.2828	-2.2173	-0.2789	-3.3543
Var1		0.0197	0.1182	-2.5504	0.270	0.0567	-1.4128
Var2		-0.2281	-0.2366	-0.8271	-0.2821	-0.3282	-1.6151
Var3		-0.0994	0.0331	-0.0444	-0.3680	-0.0518	-0.7433
Var4		0.0082	0.0451	-0.6746	-0.01213	-0.0802	-1.0007
Var5		0.1025	-0.0885	-0.095	0.2924	0.0052	-0.8691
Var6		0.2046	0.1450	-0.7513	0.0053	0.0815	-1.7295
constant	(40,9)	-0.0526	0.103	0.0087	-0.1293	-0.0366	0.0953
Var1		0.0282	0.1493	0.2525	0.2106	0.0156	0.1452
Var2		-0.1233	-0.2171	-0.1808	-0.8152	-0.1237	-0.2235
Var3		-0.3434	-0.3906	-0.1765	-0.636	-0.3226	-0.3771
Var4		0.2258	0.2225	-0.2513	0.677	0.1966	0.1920
Var5		0.0042	-0.0517	-0.0059	0.0297	-0.0064	-0.0869
Var6		-0.0837	-0.1362	-0.1492	-0.7461	-0.1093	-0.1621
Var7		0.1065	0.2535	0.2553	-0.0261	0.1011	0.2389
Var8		0.1406	0.1433	0.4630	-0.2177	0.1547	0.1233
Var9		0.0214	0.1716	0.5465	-0.2362	0.0245	0.0615

جدول رقم (8)

نتائج تحليل الطرائق التمييزية للبيانات المولدة الملوثة ونسبة تلويث 20%

المعاملات	حجم العينة و عدد المتغيرات	LDF	QDF	LH	QH	LS	QS
constant	(60,3)	0.0041	-0.3145	0.1029	0.0194	0.0344	-0.2169
Var1		0.2538	0.3049	0.4720	0.2463	0.2063	0.2306
Var2		0.0432	0.0462	0.2563	0.0127	0.0446	0.0509
Var3		-0.1730	-0.2274	-0.2468	-0.1598	-0.1929	-0.2350
constant	(60,6)	0.0228	-0.2582	0.2703	0.0173	0.0136	-0.2629
Var1		0.4983	0.6459	0.4705	0.5462	0.5303	0.6959
Var2		-0.2530	-0.3856	-0.3194	-0.4399	-0.2737	-0.4102
Var3		-0.2902	-0.2614	-0.3855	-0.6396	-0.3062	-0.2588
Var4		0.1535	0.1794	0.1928	0.2725	0.1941	0.2322
Var5		-0.2430	-0.2731	-0.840	-0.2033	-0.2711	-0.3387
Var6		0.237	0.2273	-0.0579	-0.2589	0.2131	0.1922
constant	(60,9)	0.0328	0.0738	0.3274	0.0454	0.0107	0.0464
Var1		-0.3586	-0.4174	-0.1163	-0.4622	-0.3498	-0.3933
Var2		0.0680	0.1221	0.0039	0.3265	0.0073	0.0586
Var3		0.5776	0.6493	0.4421	0.1175	0.5914	0.6651
Var4		0.6388	0.8703	0.7753	0.4260	0.6360	0.8636
Var5		-0.0341	-0.1139	-0.1075	-0.0012	-0.0774	-0.1732
Var6		-0.1025	-0.3518	-0.0967	-0.2005	-0.0562	-0.2848
Var7		-0.2317	-0.2704	-0.4722	-0.273	-0.2295	-0.2557
Var8		-0.2673	-0.3794	-0.4026	-0.4695	-0.2354	-0.3710
Var9		-0.1806	-0.0205	-0.1276	-0.5224	-0.1943	-0.0372

جدول رقم (9)

نتائج تحليل الطرائق التمييزية للبيانات المولدة الملوثة ونسبة تلويث 20%

المعاملات	حجم العينة و عدد المتغيرات	LDF	QDF	LH	QH	LS	QS
constant	(100,3)	-0.0550	-0.2717	-0.0409	-0.433	-0.0543	-0.1994
Var1		-0.2531	-0.2016	-0.1765	-0.3929	-0.2294	-0.1768
Var2		0.1297	0.0250	-0.0459	0.262	0.1566	0.0635
Var3		0.2420	0.3027	-0.5535	0.5592	0.1412	0.1873
constant	(100,6)	-0.0607	0.2889	1.3111	-0.1284	-0.0337	0.3007
Var1		0.2620	0.3918	0.0164	0.1465	0.2231	0.3623
Var2		0.1484	0.1461	0.2536	0.7326	0.1599	0.1573
Var3		0.1221	0.1257	0.4320	0.3821	0.1607	0.1670
Var4		-0.1772	-0.1650	-0.2467	-0.0278	-0.1604	-0.1462
Var5		0.0441	-0.0068	-0.0030	-0.2088	0.0606	0.0111
Var6		-0.2707	-0.3446	-0.7876	-0.2471	-0.3289	-0.4171
constant	(100,9)	0.1216	0.2878	0.21341	0.2059	0.1093	0.2798
Var1		0.3305	0.2681	0.7795	0.4477	0.3072	0.2558
Var2		0.1200	-0.0573	-0.1226	-0.828	-0.0917	-0.0187
Var3		0.4797	0.5731	-0.370	-0.4264	0.4831	0.5652
Var4		-0.0125	-0.0499	-0.2675	-0.1456	-0.0103	-0.0727
Var5		-0.2628	-0.1854	-0.1500	-0.1729	-0.2973	-0.2103
Var6		-0.3845	-0.5282	-0.4763	-0.553	-0.4073	-0.5510
Var7		-0.2237	-0.2448	0.3528	0.8207	-0.2014	-0.2063
Var8		0.1877	0.209	0.1929	0.6134	0.1798	0.1941
Var9		0.1477	0.1891	0.3379	0.3519	0.1644	0.1977

جدول رقم (10)

احتمال خطأ التصنيف للبيانات المولدة النظيفة

حجم العينة	LDF	QDF	LH	QH	LS	QS	LMCD	QMCD
(40,3)	0.35	0.1536	0.1155	0.0921	0.05	0.05	0	0
(40,6)	0.3216	0.1733	0.0971	0.06	0	0	0	0
(40,9)	0.382	0.2210	0.0962	0.0513	0	0	0	0
(60,3)	0.3911	0.1503	0.11	0.0982	0.05	0.05	0.05	0.0196
(60,6)	0.2916	0.1325	0.1215	0.0731	0	0	0	0
(60,9)	0.3119	0.0919	0.1425	0.0651	0	0	0.0102	0
(100,3)	0.3713	0.0812	0.0913	0.0522	0.07	0.07	0.0218	0.0121
(100,6)	0.3151	0.1161	0.100	0.0791	0.01	0.01	0	0
(100,9)	0.2860	0.1251	0.1113	0.0971	0.0321	0.0422	0.0175	0.0199

جدول رقم (11)

احتمال خطأ التصنيف للبيانات الملوثة ولنسبة تلويث 10%

حجم العينة	LDF	QDF	LH	QH	LS	QS	LMCD	QMCD
(40,3)	0.525	0.3963	0.3651	0.2616	0.15	0.1	0.0571	0.0313
(40,6)	0.4770	0.3910	0.3866	0.2711	0.25	0.25	0.0007	0
(40,9)	0.376	0.2271	0.215	0.1351	0.15	0.0761	0.001	0
(60,3)	0.4166	0.3839	0.3768	0.2533	0.1167	0.1167	0.0130	0
(60,6)	0.4	0.3461	0.2715	0.2278	0.1571	0.05	0.005	0
(60,9)	0.5	0.3833	0.3305	0.2715	0.4836	0.25	0.0171	0
(100,3)	0.45	0.51	0.2915	0.2209	0.12	0.09	0.0153	0
(100,6)	0.4421	0.327	0.2511	0.1355	0.1	0.1	0	0.0121
(100,9)	0.48	0.3617	0.2151	0.1173	0.22	0.0931	0.0151	0

جدول رقم (9)

احتمال خطأ التصنيف للبيانات الملوثة ولنسبة تلويث 20%

حجم العينة	LDF	QDF	LH	QH	LS	QS	LMCD	QMCD
(40,3)	0.6	0.395	0.2916	0.2662	0.375	0.225	0.0938	0.0625
(40,6)	0.525	0.325	0.3351	0.2152	0.225	0.1352	0	0
(40,9)	0.5547	0.2851	0.2793	0.1601	0.275	0.1	0.0563	0.0294
(60,3)	0.4667	0.45	0.3357	0.2273	0.2333	0.1620	0.0417	0.0417
(60,6)	0.425	0.35	0.3323	0.3062	0.2572	0.2166	0	0
(60,9)	0.4468	0.3785	0.319	0.2263	0.3333	0.13333	0.01553	0.008
(100,3)	0.4937	0.44	0.3321	0.2415	0.4113	0.2261	0.0389	0.0506
(100,6)	0.43	0.3651	0.3718	0.2153	0.2811	0.1475	0.003	0
(100,9)	0.49	0.43	0.3210	0.2759	0.3365	0.24	0.009	0

الاستنتاجات والتوصيات

الاستنتاجات:

- في ضوء تحليل تجارب المحاكاة تم التوصل للاستنتاجات التالية:
1. عند توليد البيانات النظرية والملوثة ولجميع نسب التلوين ومختلف المتغيرات التوضيحية، وقد لوحظ أن مقدر MCD حقق نتائج كفاءة بدرجة عالية إذ أعطى أقل احتمال لخطأ التصنيف وللدالة التربيعية QMCD تليها الدالة الخطية LMCD، يليه مقدر S الحصين ثم مقدر H الحصين، كما ان مقدر MCD الحصين أعطى وحالات عديدة احتمال خطأ تصنيف صفر وهذا يعكس خصائص المقدر الجيد وهي نقطة الانهيار العالية، الحصانة العالية، الكفاءة الإحصائية العالية.
 2. أعطت دالة التمييز الخطية والتربيعية التقليديتين أعلى نسبة لخطأ التصنيف مما يتطلب عدم استخدامهم في حال احتواء البيانات على قيم شاذة أي أن الشواذ لها تأثير كبير على قاعدة التمييز الخطية LDR وقاعدة التمييز التربيعية QDR.
 3. أعطى مقدر S الحصين نتائج أقل كفاءة بالمقارنة مع مقدر MCD الحصين فضلاً عن أن خوارزمية مقدر S احتاجت وقت حساب أطول مقارنة مع خوارزمية مقدر MCD.
 4. إن قواعد التمييز التقليدية LDR و QDR في حالة البيانات النظرية ابرزت كفاءتها لجميع حجوم العينات في حين اخفقت وبشكل واضح لحالة البيانات الملوثة.
 5. ان قواعد التمييز بالاعتماد على مقدر MCD الحصين أنجزت بكفاءة عالية ولمجموعة البيانات الصغيرة والمتوسطة والكبيرة.
 6. أثبتت الطريقة الثانية لتقدير التباين المشترك الأولي $\hat{\Sigma}_0$ والخاصة بمقدر MCD الحصين كفاءة عالية علماً بأن هذه الطريقة هي تحديث لطريقة He & Fung (2000).

التوصيات:

- بناءً على ما تم التوصل إليه البحث من استنتاجات نقترح بالتوصيات الآتية:
1. نوصي باستخدام مقدر MCD الحصين بقوة لما يمتاز به من تحقيق نقطة انهيار عالية، حصانة عالية وكفاءة إحصائية عالية كما إن المسافة الحصينة باستخدام مقدر MCD هي أكثر دقة من الاعتماد على مقدرات أخرى مثل MVE.
 2. نظراً للمعوقات في حساب مقدر MCD الحصين بقوة لاسيما مع زيادة عدد المتغيرات التوضيحية من تلك المعوقات وقت الحساب لذلك نقترح تطبيق خوارزمية FAST-MCD التي تختزل وقت حساب خوارزمية MCD.

3. نوصي باستخدام مقدر MCD الحصين بقوة في حالة تعدد المجتمعات (أكثر من مجتمعين) ليقارن مع مقدرات حصينة أخرى وبيان كفاءته.
4. نوصي باستخدام الحالة الثانية والثالثة الخاصة بحالات التلوّث في حالة توليد البيانات الملوثة ومقارنتها مع الحالة الأولى عند تطبيق الطرق التقليدية والحصينة لمعرفة الفرق في النتائج.
5. نوصي بتطبيق الطريقتين الأولى والثالثة والخاصة بتقدير التباين المشترك الأولي $\hat{\Sigma}_0$ لمقدر MCD الحصين ومقارنة النتائج مع الطريقة الثانية للبيانات إن كان هناك تقارباً أو اختلافاً في النتائج.
6. اعتماد طرائق أخرى للكشف عن الشواذ بشكل أولي ولكل نقطة بيانات كمسافة مهنلوس الحصينة.

المصادر

أولاً: العربية

- النداوي، سري صباح، (2008) "مقارنة بعض المقدرات الحصينة في الدوال التمييزية مع تطبيق عملي" رسالة ماجستير في الإحصاء، كلية الإدارة والاقتصاد، جامعة بغداد.

ثانياً: الأجنبية

1. Alvin, C. Rencher, (1996), "Methods of Multivariate Analysis", John Wiley & Sons.
2. Croux, C., Dehon, C., (2001). "Robust Linear Discriminant Analysis Using S-Estimator", The Canadian Journal of Statistics, vol. 29, 1-18.
3. Hawkins, D. M., Mclachlan, G. J., (1997), "High Breakdown Linear Discriminant Analysis", JASA, Vol. 92, 136-143.
4. Hubert, P. J., (1981), "Robust Statistics", John Wiley & Sons.
5. Hubert, M., Driessen, K. V., (2004), "Fast and Robust Discriminant Analysis", Computational Statistics and Data Analysis, Vol. 45, 301-320.
6. Lanchenbruch, P., A., Sneemger, C., & Rev, L. T., (1973), "Robustness of Linear and Quadratic Discriminant Function to certain types of non – normality", Comm. Stat., Vol. 1.
7. Launer, R. L. & Wilkinson, G. N., (1979), "Robustness in Statistics". Academic Press, new York.
8. Mardia, K. V. & Kent, J. T., Bibby, J. M., (1979), "Multivariate Analysis" Academic press inc (London) Ltd.
9. Norusis, M., (1986), "SPSS/PC for the IBM PC/XT/AT", Chicago.
11. Ruppert, D., (1992), "Computing S-Estimators for regression and Multivariate Location /Dispersion", American Statistical Association, Vol 1, no., 3, 253-270.
12. Wilcox, R. R., (1997), "introduction to Robust estimation and Hypothesis Testing", Academic Press, New York.

