

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

(وَأَنْزَلَ اللَّهُ عَلَيْكَ الْكِتَابَ
وَالْحِكْمَةَ وَعَلَّمَكَ مَا لَمْ تَكُنْ
تَعْلَمُ وَكَانَ فَضْلُ اللَّهِ عَلَيْكَ
عَظِيمًا) (سورة النساء الآية 113)

شكر وتقدير

بعد الشكر والحمد لله العلى القدير أود أن أتوجه بالشكر والتقدير لأستاذى الفاضل ا د/أسامة عبد العزيز حسين لإشرافه على الرسالة وعلى ما قدمه لى من عون ونصائح قيمة ،فلولا توفيق الله ثم دعمه المستمر لى ما كان يتسنى لى أن أنتهى من الرسالة فجزاه الله عنى خير الجزاء .

وأود أن أعبر عن عميق شكرى وتقديرى لأستاذى الفاضل ا د/محمد على محمد أحمد والذى كان له فضل السبق فى توجيهى لموضوع الرسالة من البداية ، وكذلك تفضله بالإشتراك فى لجنة الحكم على الرسالة رغم مشاغله الكثيرة مما يفيد الباحث من مناقشاته العلمية المتميزة .

كما أتقدم بجزيل الشكر والتقدير والإمتنان للأستاذ د/ عبدالرؤوف عبد الرحمن لتكبدته عناء قراءة الرسالة وتفضله بقبول الإشتراك فى لجنة الحكم رغم مشاغله الكثيرة فله منى كل الشكر والتقدير

كما يشكر الباحث إ.د. على هادى على تعاونه فى توفير البرامج الاحصائية التنفيذية التى تم إستخدامها فى التطبيق العملى للدراسة .

كما أود أن أشكر جميع أساتذتى الأجلاء فى قسم الإحصاء لما تعلمته منهم من خلق وعلم ، وأخص بالشكر ا د/ امتثال محمد حسن لدعمها المعنوى المستمر لى طوال فترة إعداد الرسالة ، كما أشكر أساتذتى الذين نهلت من علمهم وأخلاقهم الكثير ا د/عادل حلاوة ، و ا د/عبدالمرضى حامد عزام ، ولا يفوتنى أن أذكر الراحل د/ يحيى سعد زغلول رحمه الله وأسكنه فسيح جناته.

وأخيراً أقدم عميق شكرى إلى زملائى فى قسم الاحصاء على تشجيعهم وحسن تعاونهم فجزى الله الجميع عنى كل الخير.

إهداء

إلى روح أبي رحمه الله وإلى أمي رمز العطاء

براً وإحساناً

إلى زوجتي رمز التضحية

مودعة ورحمة

إلى أبنائي يوسف وبلال وجنى

رعايةً وحباً

إلى أساتذتي رموز العلم والأخلاق

تقديراً وعرفاناً

لجنة المناقشة والحكم على الرسالة :

١ . د / عبد الرؤوف عبد الحمن عبد الواحد

أستاذ الإحصاء بكلية التجارة – جامعة طنطا
رئيساً

١ . د / محمد على محمد أحمد

أستاذ الإحصاء ووكيل الكلية لشئون التعليم والطلاب – كلية
التجارة – جامعة الأسكندرية

عضواً

د / أسامة عبد العزيز حسين

أستاذ الإحصاء المساعد
كلية التجارة – جامعة الأسكندرية

مشرفاً وعضواً

دراسة مقارنة لبعض الطرق المتينة للكشف
عن المشاهدات الشاذة فى نماذج الانحدار الخطى

A Comparative Study of Some Robust Outliers Diagnostics in Linear Regression Models

لنيل درجة الماجستير فى الإحصاء التطبيقى

مقدمة من الطالب / أحمد صدقى محمد الديب
المعيد بقسم الإحصاء و الرياضة والتأمين

إشراف

د/محمد توفيق قفشير
مدرس بقسم الإحصاء والرياضة والتأمين
كلية التجارة - جامعة الإسكندرية

د/ أسامة عبد العزيز حسين
أستاذ م بقسم الإحصاء والرياضة والتأمين
كلية التجارة - جامعة الإسكندرية

قائمة محتويات الدراسة

دراسة مقارنة لبعض الطرق المتينة للكشف عن المشاهدات الشاذة في

نماذج الانحدار الخطي

رقم الصفحة	<u>الفصل الاول : مقدمة</u>
١	١-١ تمهيد
٢	٢-١ مشكلة الدراسة
3	٣-١ هدف الدراسة
4	٤-١ أهمية الدراسة
5	٥-١ خطة الدراسة
	<u>الفصل الثاني : إكتشاف المشاهدات البعيدة عن مركز البيانات</u>
8	مقدمة
8	١-٢ هيكل وإفتراضات النموذج
10	٢-2 أنواع المشاهدات
12	٣-٢ طرق إكتشاف المشاهدات البعيدة عن مركز البيانات
12	١-٣-٢ المقاييس التقليدية لإكتشاف المشاهدات البعيدة عن مركز البيانات
12	١-٣-٢-١ العناصر القطرية للمصفوفة المقدرة (Diagonal Elements of Hat) (Matrix)
14	٢-١-٣-٢ مسافة ماهالانوبيس (Mahalanobis Distance)
16	٢-٣-٢ المفاهيم والمعايير المستخدمة في المقارنة بين أساليب الانحدار المتين
16	١- نقطة الإنكسار (Breakdown Point)
17	٢- مفهوم الكفاءة النسبية لمقدر الانحدار المتين (Relative Efficiency)
17	٣- مفهوم التأثير المحدود (Bounded Influence Concept)

19	4- مفهوم إمكانية التحويل (Equivariance)
20	5- القدرة الحسابية (Computability)
21	2-4 المقدرات المتينة للموقع والمقياس (Robust Estimators for Location and Scale)
21	2-4-1 مقدرات M للموقع والمقياس (M-estimators of Location and Scale)
22	2-4-2 مقدرات الحجم الأدنى للقطع الناقص (Minimum Volume Ellipsoid, MVE) للموقع والمقياس
25	2-4-3 مقدرات أدنى محدد للتغاير (Minimum Covariance Determinant, MCD) للموقع والمقياس
26	2-4-4 المسافات المتينة باستخدام الخوارزم السريع لطريقة أدنى محدد للتغاير (Fast-MCD Algorithm)
28	2-4-5 مسافة باكون (BACON Distance , BD)
32	2-4-6 المسافات المتينة 2006 (Robust Distance 2006 , RD06)
35	2-5 مقارنة بين طرق إكتشاف المشاهدات البعيدة عن مركز البيانات
35	2-5-1 القابلية للحساب عملياً (Comulational Practicality)
36	2-5-2 إمكانية التحويل (Equivariance)
37	<u>الفصل الثالث : إكتشاف المشاهدات الشاذة والمشاهدات المؤثرة</u>
	<u>مقدمة</u>
37	3-1 المقاييس التقليدية لتحديد المشاهدات الشاذة
39	3-2 الصعوبات التي تواجه الطرق التقليدية لإكتشاف المشاهدات الشاذة
40	3-3 الطرق غير المباشرة لإكتشاف المشاهدات الشاذة
41	3-3-1 طرق الإنحدار ذات قيمة الإنكسار العالية
41	(1) طريقة أدنى قيمة مطلقة (Least Absolute Values, LAV)

42	٢) طريقة وسيط المربعات الأدنى (Least Median of Squares,LMS)
43	٣) طريقة المربعات المشذبة الصغرى (Least Trimmed of Squares,LTS)
44	٣-2 الطرق ذات الكفاءة العالية (High Efficiency Methods)
45	١) طريقة مقدرات M (M-estimators)
46	٢) طريقة تقدير M العامة (GM)
47	٣) طريقة تقدير MM (MM-Estimation)
51	٣-٤ الطرق المباشرة لإكتشاف المشاهدات الشاذة
51	٣-٤-1 الأعمال المبكرة لإكتشاف المشاهدات الشاذة المتعددة
52	٣-٤-2 طريقة (Hadi and Simonoff,HS93&HS97)
53	٣-4-3 طريقة (Chatterjee and Machler1997 , CM97)
55	٣-4-4 طريقة المربعات الصغرى المعاد ترجيحها تكراريا 2001 (Iteratively Reweighted Least Squares Method ,IRWLS01)
57	٣-٤-5 طريقة المربعات الصغرى المعاد ترجيحها تكراريا 2006 (Iteratively Reweighted Least Squares Method ,IRWLS06)
60	٣-٥ إكتشاف المشاهدات المؤثرة (Detection of Influential Observations)
62	٣-٦ مقاييس إكتشاف المشاهدات المؤثرة
62	٣-٦-1 مسافة كوك (Cook's Distance)
62	٣-٦-2 مسافة كوك المعدلة (Modified Cook's Distance)
63	٣-٦-3 الفروق فى القيم الموفقة (DFITS)
63	٣-٦-4 التأثير على معامل إنحدار واحد (DFBETAS)
64	٣-٦-5 نسبة التغير (COVRATIO)
66	<u>الفصل الرابع : الدراسة التطبيقية لإكتشاف المشاهدات البعيدة عن المركز</u>
	٤-١ مقارنة أداء طرق إكتشاف المشاهدات البعيدة عن مركز البيانات فى مجموعات البيانات

69	Air data -١
70	Aircraft data -٢
71	Buxton data -٣
72	Delivery data -٤
73	Education data -٥
75	Hawkins data -٦
76	Salinity data -٧
77	Stackloss data -٨
78	Stars data -٩
79	Two Systems data -١٠
81	الفصل الخامس : الدراسة التطبيقية لإكتشاف المشاهدات الشاذة و المشاهدات المؤثرة
82	١ -٥ معايير تقويم أداء طرق إكتشاف المشاهدات الشاذة
82	١-١-٥ معدل الخطأ فى تحديد المشاهدات الشاذة (, Outliers Error Rate)
	(OER
82	٢-١-٥ معدل الخطأ فى تحديد المشاهدات الجيدة (, Inliers Error Rate)
	(IER
	٢-٥ مقارنة أداء طرق الانحدار المتين فى إكتشاف المشاهدات الشاذة من حيث
	• القدرة على إكتشاف المشاهدات الشاذة (Detection Capability,DC)
	• معدل الخطأ فى تحديد المشاهدات الشاذة (OER)
	• معدل الخطأ فى تحديد المشاهدات الجيدة (IER)
	• معدل الإنذار الخطأ (False Alarm Rate,FR)
	• الأشكال البيانية التشخيصية (Diagnostic Plots)
84	٣-٥ طرق التحليل ذو المرحلتين (البواقى - المسافة)
	1- طريقة LMS - MVE
	2- طريقة LTS – MCD

	3- طريقة IRWLS01 – BACON	4- طريقة IRWLS06 – RD06
88	Stackloss data - ١	
92	Aircraft data - ٢	
96	Delivery data - ٣	
100	Salinity data - ٤	
104	Two Systems data - ٥	
108	Stars data - ٦	
112	Education data - ٧	
116	Hawkins data - ٨	
120	Buxton data - ٩	
124	Air data - ١٠	
126	٥- ٤ مقارنة أداء طرق إكتشاف المشاهدات المؤثرة قبل وبعد الترجيح:	
126	• مسافة كوك (Cook's Distance)	
126	• فروق القيم الموفقة (DFFITS)	
128	• مسافة كوك المعاد ترجيحها (Reweighted Cook's Distance)	
130	• فروق القيم الموفقة المعاد ترجيحها (Reweighted DFFITS)	
132	▪ مقارنة أداء مقياس الفروق فى القيم الموفقة قبل وبعد الترجيح	
134	▪ مقارنة أداء مسافة كوك قبل وبعد الترجيح	
	<u>الفصل السادس : الاستنتاجات العامة والتوصيات</u>	
135	٦- ١ الاستنتاجات العامة	
144	٦- ٢ التوصيات	
145	جدول النتائج الكلية	
146	مراجع الدراسة	
	ملاحق الدراسة	
155	ملحق (١) الأشكال البيانية لمقاييس إكتشاف المشاهدات البعيدة عن مركز البيانات	
173	ملحق (٢) الأشكال البيانية للطرق غير المباشرة لإكتشاف المشاهدات الشاذة	
190	ملحق (٣) الأشكال البيانية للطرق المباشرة لإكتشاف المشاهدات الشاذة	

قائمة جداول الدراسة

رقم الصفحة	عنوان الجدول	رقم الجدول
67	جدول نقاط القطع (Cutoff Points) المستخدمة في طرق إكتشاف المشاهدات البعيدة عن مركز البيانات	(1 – 4)
68	جدول المقارنة بين طرق إكتشاف المشاهدات البعيدة عن مركز البيانات لمجموعات البيانات المستخدمة في الدراسة	(2 – 4)
86	جدول نسب المشاهدات الشاذة الحقيقية ونسب المشاهدات العادية مرتبة وفقاً لعدد المشاهدات الكلي لمجموعات البيانات	(1 – 5)
٨٧ ، ٨٨	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Stackloss)	(2 – 5)
90	تصنيف المشاهدات الموجودة في مجموعة بيانات (StackLoss) وفقاً لطرق التحليل ذو المرحلتين (البواقي - المسافة)	(3 – 5)
91 ، 92	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Aircraft)	(4 – 5)
94	تصنيف المشاهدات الموجودة في مجموعة بيانات (Aircraft) وفقاً لطرق التحليل ذو المرحلتين (البواقي - المسافة)	(5 – 5)
95-97	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Delivery)	(6 – 5)
98	تصنيف المشاهدات الموجودة في مجموعة بيانات (Delivery) وفقاً لطرق التحليل ذو المرحلتين (البواقي - المسافة)	(7 – 5)
99-101	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Salinity)	(8 – 5)
102	تصنيف المشاهدات الموجودة في مجموعة بيانات (Salinity) وفقاً لطرق التحليل ذو المرحلتين (البواقي - المسافة)	(9 – 5)
103-105	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Two Systems)	(10 – 5)

رقم الصفحة	عنوان الجدول	رقم الجدول
107	تصنيف المشاهدات الموجودة في مجموعة بيانات (Two systems) وفقاً لطرق التحليل ذو المرحلتين (البواقى-المسافة)	(11 – 5)
107-109	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Stars)	(12 – 5)
110	تصنيف المشاهدات الموجودة في مجموعة بيانات (Stars) وفقاً لطرق التحليل ذو المرحلتين (البواقى - المسافة)	(13 – 5)
111-113	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Education)	(14 – 5)
114	تصنيف المشاهدات الموجودة في مجموعة بيانات (Education) وفقاً لطرق التحليل ذو المرحلتين (البواقى - المسافة)	(15 – 5)
115,116	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Hawkins)	(16 – 5)
811	تصنيف المشاهدات الموجودة في مجموعة بيانات (Hawkins) وفقاً لطرق التحليل ذو المرحلتين (البواقى - المسافة)	(17 – 5)
119-121	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Buxton)	(18 – 5)
122	تصنيف المشاهدات الموجودة في مجموعة بيانات (Buxton) وفقاً لطرق التحليل ذو المرحلتين (البواقى - المسافة)	(19 – 5)
123-125	جدول معدلات الأخطاء في تحديد المشاهدات الشاذة (OER) ومعدلات الأخطاء في تحديد المشاهدات الجيدة (IER) في مجموعة بيانات (Air)	(20 – 5)
612	تصنيف المشاهدات الموجودة في مجموعة بيانات (Air Quality) وفقاً لطرق التحليل ذو المرحلتين (البواقى -المسافة)	(21 – 5)
812	جدول المشاهدات المؤثرة قبل وبعد الترجيح بالأوزان في مجموعات البيانات	(22 – 5)
137,138	جدول ترتيب طرق إكتشاف المشاهدات الشاذة وفقاً لمعايير (OER , IER)	(1 – 6)
141,142	جدول النتائج الكلية لطرق إكتشاف المشاهدات الشاذة	(2 – 6)

**قائمة الأشكال البيانية المستخدمة في مقاييس إكتشاف
المشاهدات البعيدة عن مركز البيانات (ملحق رقم ١)**

رقم الصفحة	عنوان الشكل البياني	رقم الشكل البياني
١٥٥	<u>Air quality</u>:Index plot of leverage values h_{ii}	شكل (١-٤)
١٥٥	Index plot of Mahalanobis Distance MD	شكل (٢-٤)
١٥٥	Index plot of Robust Distance RD (using MCD)	شكل (٣-٤)
١٥٥	Scatter plot of Mahalanobis Distance versus Robust Distance	شكل (٤-٤)
١٥٦	Index plot of BACON Distance BD	شكل (٥-٤)
١٥٦	Index plot of Robust Distance(RD06)	شكل (٦-٤)
١٥٦	<u>Aircraft</u> :Index plot of leverage values h_{ii}	شكل (٧-٤)
١٥٦	Index plot of Mahalanobis Distance MD	شكل (٨-٤)
١٥٧	Index plot of Robust Distance RD (using MCD)	شكل (٩-٤)
١٥٧	Scatter plot of Mahalanobis Distance versus Robust Distance	شكل (١٠-٤)
١٥٧	Index plot of BACON Distance BD	شكل (١١-٤)
١٥٧	Index plot of Robust Distance(RD06)	شكل (١٢-٤)
١٥٨	D-D plot for <u>Air quality</u>	شكل (١٣-٤)
١٥٨	D-D plot for <u>Aircraft</u>	شكل (١٤-٤)
١٥٨	<u>Buxton</u>:Index plot of leverage values h_{ii}	شكل (١٥-٤)

رقم الصفحة	عنوان الشكل البياني	رقم الشكل البياني
١٥٨	Index plot of Mahalanobis Distance MD	شكل (١٦-٤)
١٥٩	Index plot of Robust Distance RD (using MCD)	شكل (١٧-٤)
١٥٩	Scatter plot of Mahalanobis Distance versus Robust Distance	شكل (١٨-٤)
١٥٩	Index plot of BACON Distance BD	شكل (١٩-٤)
١٥٩	Index plot of Robust Distance(RD06)	شكل (٢٠-٤)
١٦٠	<u>Delivery</u> :Index plot of leverage values h_{ii}	شكل (٢١-٤)
١٦٠	Index plot of Mahalanobis Distance MD	شكل (٢٢-٤)
١٦٠	Index plot of Robust Distance RD (using MCD)	شكل (٢٣-٤)
١٦٠	Scatter plot of Mahalanobis Distance versus Robust Distance	شكل (٢٤-٤)
١٦١	Index plot of BACON Distance BD	شكل (٢٥-٤)
١٦١	Index plot of Robust Distance(RD06)	شكل (٢٦-٤)
١٦١	D-D plot for <u>Buxton</u>	شكل (٢٧-٤)
١٦١	D-D plot for <u>Delivery</u>	شكل (٢٨-٤)
١٦٢	<u>Education</u> : Index plot of leverage values h_{ii}	شكل (٢٩-٤)
١٦٢	Index plot of Mahalanobis Distance MD	شكل (٣٠-٤)
١٦٢	Index plot of Robust Distance RD (using MCD)	شكل (٣١-٤)
١٦٢	Scatter plot of Mahalanobis Distance versus Robust Distance	شكل (٣٢-٤)

رقم الصفحة	عنوان الشكل البياني	رقم الشكل البياني
١٦٣	Index plot of BACON Distance BD	شكل (٣٣-٤)
١٦٣	Index plot of Robust Distance(RD06)	شكل (٣٤-٤)
١٦٣	<u>Hawkins</u> :Index plot of leverage values h_{ii}	شكل (٣٥-٤)
١٦٣	Index plot of Mahalanobis Distance MD	شكل (٣٦-٤)
١٦٤	Index plot of Robust Distance RD (using MCD)	شكل (٣٧-٤)
١٦٤	Scatter plot of Mahalanobis Distance versus Robust Distance	شكل (٣٨-٤)
١٦٤	Index plot of BACON Distance BD	شكل (٣٩-٤)
١٦٤	Index plot of Robust Distance(RD06)	شكل (٤٠-٤)
١٦٥	D-D plot for <u>Education</u>	شكل (٤١-٤)
١٦٥	D-D plot for <u>Hawkins</u>	شكل (٤٢-٤)
١٦٥	<u>Salinity</u> : Index plot of leverage values h_{ii}	شكل (٤٣-٤)
١٦٥	Index plot of Mahalanobis Distance MD	شكل (٤٤-٤)
١٦٦	Index plot of Robust Distance RD (using MCD)	شكل (٤٥-٤)
١٦٦	Scatter plot of Mahalanobis Distance versus Robust Distance	شكل (٤٦-٤)
١٦٦	Index plot of BACON Distance BD	شكل (٤٧-٤)
١٦٦	Index plot of Robust Distance(RD06)	شكل (٤٨-٤)
١٦٧	<u>Stackloss</u> :Index plot of leverage values h_{ii}	شكل (٤٩-٤)