

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

هارون موسى بهار

عبدالهادي خليل أبو سعدة

جامعة الأزهر - غزة

تاريخ الاستلام

2018/10/15

تاريخ القبول

2019/1/29

ملخص:

لقد قمنا في هذه الدراسة بتحليل بيانات تتعلق بمرضى السكري، وعينة الدراسة عبارة 232 شخص مقسمين الى 172 مريض سكري و 60 شخص غير مريض بالسكري، حيث تم جمع هذه البيانات داخل المراكز الصحية والعيادات سواء كانت حكومية أو خاصة، وكانت العينة موزعة على الجنسين وتحديدًا الأشخاص البالغين التي تزيد أعمارهم عن 25 سنة. كما تم استخدام التحليل اللوجستي لبناء نموذج احصائي لتصنيف البيانات. والمعروف إن المستوى السليم للسكر في الدم بعد صوم ثماني ساعات يجب أن يكون أقل من 108 ملغم/ دل، بينما المستوى الحدودي هو 126 ملغم/ دل. أما إذا كان مستوى الجلوكوز في الدم لدى شخص ما 126 ملغم/ دل فما فوق، في فحصين أو أكثر، فعندئذ يتم تشخيص إصابة هذا الشخص بمرض السكري. وتأتي أهمية هذا البحث من أنه تمكن من بناء نموذج إحصائي يستطيع التنبؤ بحالات الإصابة بمرض السكري والذي من خلاله نستطيع تحديد أهم عوامل الخطر التي إذا ما توفرت لدى أي شخص كان احتمال إصابته بهذا المرض أكبر بكثير من غيره. وكانت خلاصة التحليل أننا حصلنا على نموذج بلغت دقته وفق جدول التصنيف الى (92.8%). وأهم عوامل الخطر التي ظهرت في النموذج هي: الضغط النفسي المرتفع، كمية الفواكه والخضروات التي يتناولها أسبوعياً، كمية اللحم المستهلكة أسبوعاً، المؤهل العلمي. وفي هذه الدراسة تم اختيار بعض أدوات التقييم الإحصائي لتقييم النموذج الذي تم الحصول عليه ولمعرفة مدى جودة التصنيف التي يحققها هذا النموذج، وهذه الطرق هي (leave-one-out cross validation, classification table and ROC curve) وقد أجريت جميع التحليلات باستخدام البرمجيات R ، SPSS.

الكلمات المفتاحية: التحليل اللوجستي، جدول التصنيف، منحنى ROC، نسبة الأرجحية، مرض السكري.

Abstract:

In this study, the two researchers analyzed data related to diabetes. The study sample consisted of 232 people divided into 172 diabetes patients and 60 non-diabetic patients. These data were collected at health centers and clinics, (governmental or private). The sample was distributed among male & female, particularly adults over 25 years. The logistic regression was used to construct the statistical model for data classification.

It is known that the proper level of sugar in the blood after fasting of eight hours should be less than 108 mg /dl, while the border level is 126 mg /dl. If a person's blood glucose level is 126 mg /dl or above, in two or more tests, then, he or she is diagnosed with diabetes.

The importance of this research is that, it was able to build a statistical model can predict the incidence of diabetes, which through we can identify the most important risk factors that if they are found in any person, the ability to affected in diabetes will be much higher than others. The summary of the analysis was the two researchers obtained a model its accuracy according to the classification table reached 92.8%.

The main risk factors in the model are: high psychological stress, weekly amount of meat, fruits and vegetables consumed per a week, scientific qualification. In this study, some statistical evaluation tools were selected to evaluate the model obtained and to determine the quality of the classification achieved by this model, and these methods are (leave-one-out cross validation, classification table and ROC curve)

All the analyzes done by using the software R, SPSS.

Keywords: Logistic regression, classification table, ROC curve, odds ratio, diabetic patients

مقدمة:

الانحدار بشكل عام هو التحليل الذي يختص بدراسة اعتماد متغير واحد يعرف بالمتغير التابع على متغير أو أكثر يعرف بالمتغير المستقل أو المتغيرات المستقلة، وذلك بغرض التصنيف أو التنبؤ. وبناء على ذلك فإن أسلوب الانحدار يستخدم للتوصل إلى نموذج رياضي يصف العلاقة الكمية بين المتغير التابع والمتغيرات المستقلة. ويعتبر الانحدار الخطي Liner Regression من أبسط وأهم تطبيقات الانحدار، حيث يشترط تحقيق بعض الافتراضات من أجل صحة تطبيق النموذج الخطي (Menard 2002) ومن ضمن الافتراضات ان يكون المتغير التابع متصلًا وغير محدود. لكن هناك العديد من الأوضاع والظروف في علم النفس والتربية والعلوم الاجتماعية وغيرها التي يكون فيها المتغير التابع نوعيًا. ففي هذه الحالة يتم استخدام طرق أخرى للانحدار وهي الانحدار اللوجستي، والتحليل التمييزي وغيرها، وتكمن أهمية تحليل الانحدار اللوجستي عند مقارنته بالأساليب الاحصائية الأخرى (الانحدار الخطي والتحليل التمييزي)، في أن الانحدار اللوجستي هو

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

أداة أكثر قوة لأنه يقدم إختباراً لمعنوية المعاملات، كما أنه يعطي الباحث فكرة عن مقدار تأثير المتغير المستقل في المتغير التابع النوعي ثنائي القيمة ، بالإضافة إلى ذلك ، فإن الانحدار اللوجستي يرتب تأثير المتغيرات المستقلة ، مما يسمح للباحث بالاستنتاج بأن متغيراً ما يعتبر أقوى من المتغير الآخر في فهم ظهور النتيجة، كما أن تحليل الانحدار اللوجستي يمكنه أن يتضمن المتغيرات المستقلة النوعية، كما أن من مزايا استخدام الانحدار اللوجستي هو أنه أقل حساسية تجاه الانحرافات عن التوزيع الطبيعي لمتغيرات الدراسة، كما أن الانحدار اللوجستي يستطيع أن يتجاوز العديد من الافتراضات المقيدة، لاستخدام طريقة المربعات الصغرى OLS في الانحدار الخطي، الأمر الذي يجعل في نهاية المطاف تحليل الانحدار اللوجستي الأسلوب الأفضل في حالة المتغير التابع الفئوي ثنائي القيمة (www.exeter.ac.uk). والانحدار اللوجستي عدة أنواع، إلا أن أكثرها شيوعاً هو تحليل الانحدار اللوجستي الثنائي Binary Logistic Regression الذي سنستخدمه في بحثنا هذا . ويوجد هناك نوع آخر من الانحدار اللوجستي وهو الانحدار اللوجستي المتعدد Multinomial Logistic Regression المستخدم في حالة كان المتغير التابع النوعي لديه أكثر من فئتين، كما يوجد نوع ثالث من الانحدار اللوجستي وهو الانحدار اللوجستي الترتيبي Ordinal Logistic Regression والذي يستخدم في الحالات التي يكون فيها المتغير التابع ترتيبياً.

مشكلة الدراسة:

ازداد معدل الإصابة بمرض السكري في الآونة الأخيرة بشكل ملفت للنظر على مستوى العالم، وتعد فلسطين وتحديداً قطاع غزة أحد المناطق العربية التي تعاني من انتشار المرض المزمن بين مواطنيها بحيث أظهرت بعض الإحصائيات في قطاع غزة أن هناك ارتفاع ملحوظ للإصابة بمرض السكري (وفقاً للمؤتمر الدولي حول اللاجئين ومرض السكري). ونظراً لانعدام الدراسات العربية التي تناولت الوقاية من السكري فإن هذه الدراسة تأتي لتحديد اهم عوامل الخطر للإصابة بمرض السكري.

منهجية الدراسة:

تم جمع البيانات من عينة عشوائية من المرضى الذين يعانون من أمراض السكري. وعينة أخرى من الأشخاص الذين لا يعانون من المرض، حيث تم جمع البيانات من خلال سجلات المرضى بالإضافة إلى استخدام الاستبانة. تم الاعتماد على نموذج الانحدار اللوجستي الثنائي كون ان المتغير التابع يتكون من فئتين فقط، وذلك بهدف تحديد أهم عوامل الخطر للإصابة بمرض السكري، ثم تم تطبيق بعض تقنيات التقييم من أجل معرفة مدى دقة النموذج الذي تم الحصول عليه، وهذه الطرق هي: (leave-one-out cross validation, classification table and ROC curve) وقد أجريت جميع التحليلات باستخدام البرمجيات R

الدراسات السابقة:

دراسة (غانم و الجاعوني: 2011) يتضمن هذا البحث دراسة أهم محددات لكفاية دخل الأسرة وتحليلها من وجهة نظر إحصائية، والتعرف على أهم المحددات المعنوية المؤثرة significant باستخدام تقنية الانحدار اللوجستي ثنائي الاستجابة Regression logistic وقد شملت عينة الدراسة 161 أسرة.

دراسة (Bhar: 2013) تهدف هذه الدراسة إلى اختيار أفضل نموذج إحصائي لتحديد أهم عوامل الخطر على مرضى شرايين القلب في قطاع غزة، حيث تم تحليل بيانات تتعلق بمرضى شرايين القلب في قطاع غزة ، وتم استخدام ثلاث طرق للتصنيف وهي: الانحدار اللوجستي، وتحليل التمايز، وتحليل الشبكات العصبية ، وكان أهم النتائج أن عدد مرات الزواج يقلل من احتمال الإصابة بمرض شرايين القلب، ثم ارتفاع ضغط الدم ثم التدخين ، وكانت هذه أهم العوامل التي تؤثر على مرض الشرايين.

دراسة (Okasha and Abu Samra: 2013) تهدف هذه الدراسة إلى اختيار أفضل نموذج إحصائي للمرضى الذين يعانون من ارتفاع ضغط الدم في فلسطين ، من خلال المقارنة بين الشبكات العصبية وتحليل شجرة القرارات ونموذج الانحدار اللوجستي على مجموعة البيانات الحقيقية. تشير نتائج الدراسة إلى أن الشبكات العصبية الاصطناعية (ANN) قد تؤدي أداء أفضل من الطرق التقليدية باستخدام الانحدار اللوجستي أو شجرة القرارات، خاصة في حالة البيانات غير الخطية.


دراسة (Frank & other: 2001) وهي بعنوان الغذاء ونظام الحياه وخطر الإصابة بمرض السكري لدى النساء، وهدفت هذه الدراسة إلى التعرف إلى مدى ارتباط مرض السكري من النوع الثاني بالنظام الغذائي لدى أفراد الدراسة، وتوصلت الدراسة إلى أن زيادة الوزن هو أحد أهم المؤشرات في حدوث المرض بالإضافة إلى قلة التمارين الرياضية وسوء التغذية والتدخين واستخدام الكحول.

دراسة (Abo zeid & Kassb: 1992) وهي بعنوان مدى انتشار مرض السكري في المجتمعات القروية في جنوب السعودية وعلاقته بالرعاية الصحية المقدمة، وهدفت هذه الدراسة الى تقدير معدلات انتشار مرض السكري والتحكم فيه، وتوصلت الدراسة إلى تشخيص (57) حالة مرضية من مجتمع مكون من 1250 فردا مع أنهم لم يشملوا كلهم بالدراسة الفعلية للتعرف على مستوى السكر في الدم لديهم، كذلك وجد فروق بين السن والجنس فيما يخص الإصابة بمرض السكري.


مفهوم الانحدار اللوجستي: يعرف الانحدار اللوجستي بشكل عام، بأنه التحليل الذي يختص بدراسة العلاقة بين متغير واحد يعرف بالمتغير التابع (في حال كان المتغير التابع نوعي مكون من فئتين

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

Dichotomous – في هذه الحالة يسمى الانحدار اللوجستي الثنائي) ومتغير واحد أو أكثر يعرف بالمتغير المستقل او المتغيرات المستقلة (المفسرة) وذلك بغرض التقدير، أو التنبؤ. ويقوم نموذج الانحدار اللوجستي على فرض أساسي وهو أن المتغير التابع Y والذي نهتم بدراسته وهو متغير ثنائي يأخذ القيمة (1) باحتمال (P) والقيمة (0) باحتمال ($1-P$). ونلاحظ أن لوحة الانتشار للمتغير التابع عندما يكون نوعياً ثنائياً عبارة عن مجموعتين من النقاط المتوازية كما في الشكل (1) :




في هذه الحالة وعند القيام برسم أفضل خط مستقيم لتوفيق البيانات سيكون غير ملائم، والسبب هو ان الخط المستقيم سوف يأخذ قيمة أكبر من الواحد الصحيح وأقل من الصفر، إلا إذا كان الميل صفراً.




شكل (2) رسم أفضل خط مستقيم لتوفيق البيانات

ويرى (Pamplé,2000) بأن أحد الحلول لهذه المشكلة هي: اعتماد صيغة القمة والقاع ووفقاً لهذا المبدأ فإن هناك حدود للقيم المتنبئ بها بحيث ألا تتجاوز الواحد الصحيح، ولا تقل عن الصفر كما في الشكل: (3)




وبناء على ذلك فان توفيق البيانات في حالة المتغير التابع الثنائي لن يكون من خلال استخدام افضل خط مستقيم ولكن من خلال المنحنى اللوجستي والذي تقع قيمه بين الصفر والواحد والذي يأخذ شكل حرف ال S هو الأنسب لتوفيق هذه البيانات (Walker, 1998)، بواسطة (بابطين:1429هـ). وكذلك قال (Schmidt,2000) إن العلاقة الغير خطية الأكثر ملائمة هي المشابهة لحرف S ، بحيث تكون مستويان المنحنى محصورة بين الصفر والواحد ، وبحيث يمكن تقريبه على أنه مجموعة من الخطوط ذات الميول المخالفة وبحيث تكون الخطوط القريبة من الصفر والواحد الصحيح ذات ميول صغيرة جدا، في حين أن الخطوط في المنطقة الوسطى من المنحنى ذات ميول كبيرة، عند تمثيل تلك الخطوط بخط ناعم نحصل على منحنى على شكل حرف " S" كما في الشكل (4).



إن اعتماد الانحدار في الشكل السابق على المنحنى اللوجستي $P = \frac{e^{a+bx}}{1+e^{a+bx}}$ بدلا من الخط المستقيم $Y = a + b * x$ ، وهو الذي جعل هذا النوع من الانحدار يسمى بالانحدار

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة


اللوجستي (Walker, 1998). كما نلاحظ أن الشكل السابق يتحدد بقيم القمة والقاع ولا يتمثل بخط مستقيم، ويفرض تحديات جديدة يجب أخذها بعين الاعتبار، فمن تلك التحديات والمشكلات الجديدة التي تظهر طبيعة العلاقة غير الخطية بين المتغير التابع والمتغيرات المستقلة، فنلاحظ في الشكل (5): (Kleibum & Klein , 2002, p.6)



إن تأثير التغير بمقدار الوحدة الواحدة في المتغير المستقل على الاحتمال المتوقع للمتغير التابع وهو ما يسمى بميل المنحني - سوف يكون عند اقتراب المنحني من القمة أو القاع أقل منها في حالة الجزء الأوسط من المنحني (Walker:1998) وبناء على ما سبق فإن العلاقة غير الخطية بين المتغير التابع والمستقل في منطقة الوسط يمكن اعتبارها تقريباً للعلاقة الخطية لكن بدلاً من أن تستمر إلى أعلى أو إلى أدنى بشكل لا نهائي فإن هذه العلاقة غير الخطية تبدأ تدريجياً في الببط كلما اقتربنا من الصفر أو الواحد الصحيح، ونلاحظ أنه كلما اقتربت القيم أكثر فأكثر من الصفر أو الواحد، فإن الحاجة لإحداث تغير في قيمة P يتطلب تغيراً كبيراً في المتغير المستقل X مقارنة بما يحتاج إليه نفس القدر من التغير في P في منطقة وسط المنحني (Aldrich & Nelson :1984, p.32).

فعلى سبيل المثال لإحداث تغير في احتمال حدوث حدث ما من 0.95 إلى 0.96 يتطلب الأمر تغيراً في المتغير المستقل أكبر بكثير مما يتطلبه تغير الاحتمال من 0.45 إلى 0.46 ويكون المبدأ ببساطة هو أن نفس الإضافة التي تحدث في المتغير المستقل يكون لها أثر أقل على المتغير التابع في المنطقة القريبة من القمة أو القاع، وللحصول على قدر من الأثر بالقرب من منطقتي القمة والقاع مقارباً للأثر الحادث في منطقة الوسط من المنحني، فإنه لا بد من حدوث تغير أكبر في قيم المتغير أو المتغيرات المستقلة (Pampl, 2000). كما أن هناك مشكلة أخرى تنشأ من حدود

القمة والقاع عند محاولة توفيق البيانات وهي مشكلة خاصة الإضافة (Lea, 1997) (additivity) فكما يرى (CMH 2002) بأن هناك نوعين شائعين من النماذج الإحصائية وهما: النماذج الإضافية (additive)، والنماذج الضربية (multiplicative) ففي النموذج الجمعي يفترض أن المعاملات تؤثر في المتغير التابع عن طريق تغييره من خلال الإضافة أو الطرح ، ومثال ذلك زيادة الإنتاج بمقدار معين ، لكل ساعة عمل إضافية ، أما في النموذج الضربي ، فيفترض أن المعاملات تؤثر في المتغير التابع من خلال الضرب أو القسمة، ومثال ذلك زيادة عدد السكان بشكل مضاعف كلما زاد عدد السنوات مثال آخر: وهو زيادة الأرباح بشكل مضاعف كلما زاد رأس المال، إذ أن في النماذج الجمعية تكون التغيرات التي نراها في المتغير التابع بنفس المقدار والحجم، وبغض النظر عن مستوى المتغير المستقل، أما في النماذج الضربية فإن التغيرات المشاهدة في المتغير التابع يعتمد حجمها ومقدارها على مستوى المتغير المستقل، بحيث يكون تأثير المتغير المستقل على المتغير التابع ليس ثابتا لجميع مستويات المتغير التابع ، بل يكون عالي التأثير في المستويات المتوسطة من قيم المتغير التابع ، وضئيل التأثير عند طرفي قيم المتغير التابع (Pezzullo, 2003).



(Kleibaum & Klein, 2002, p.6)

إن جميع النماذج الخطية هي نماذج جمعية (Pezzullo, 2003) . وإذا تم تمثيل الدالة الخطية جبريا على النحو التالي : $y = a + b * x$ ، فإن هذا يعني أنه لكل زيادة بمقدار وحدة واحدة في x ، سوف تزداد قيمة y بمقدار b من وحدة y ، وذلك أيًا كانت مستويات x أو y (Pezzullo, 2002)، لكن هذا النموذج الجمعي لا ينطبق في حال المتغيرات التابعة الثنائية، والسبب في ذلك أن المتغير التابع له حدود عليا ودنيا، وأن تأثير المتغير المستقل على المتغير التابع يقل جدا كلما اقتربت قيم المتغير التابع y من الحد الأعلى وهو الواحد الصحيح أو من الحد الأدنى وهو الصفر، كما هو موضح من الشكل (6). أما المشكلة الإحصائية لاستخدام تحليل

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

انحدار المربعات الدنيا في حالة توفيق البيانات ذات المتغيرات التابعة ثنائية القيمة، فهي تكمن في انتهاك افتراضات تحليل الانحدار الخطي واهمها افتراض: اعتدالية التوزيع (*normality*) وتجانس البيانات (*homoscedasticity*) ، حيث تنشأ هاتان المشكلتان بسبب الطبيعة الثنائية للمتغير التابع (*Fraas & Newman, 2003*) (*Cizek & Fitzgerald, 1999*). إن المتغير التابع Y في حالة المتغيرات التابعة ثنائية القيمة له قيمتان فقط، وبذلك فإن هناك قيمتين فقط للبواقي عند كل مستوى من مستويات X ، وإذا كان عند أي قيمة أو مستوى من مستويات x_i ، يكون الاحتمال المتوقع يساوي $b_0 + b_1 x_i$ ، فإن قيم البواقي ستكون على النحو التالي:

$$1 - (b_0 + b_1 x_i) \quad \text{وذلك عندما تكون } y_i \text{ تساوي الواحد الصحيح}$$

$$0 - (b_0 + b_1 x_i) \quad \text{وذلك عندما تكون } y_i \text{ تساوي صفر .}$$

حتى في المجتمع الاصلي، فإن توزيع الأخطاء لن يكون طبيعياً عند أي مستوى من مستويات X عندما يكون للتوزيع قيمتين فقط، وكما يرى (*Newsom, 2003*) فإن توزيع الأخطاء (البواقي) في مثل هذه الأوضاع من المحتمل، وبشكل كبير أن تتبع التوزيع اللوجستي (*logistic Distribution*) وليس التوزيع الطبيعي (*Normal Distribution*) .

معامل الترجيح Odds: أن معامل الترجيح odds هو عبارة عن طريقة للتعبير عن مدى احتمال حدوث شيء ما مقارنة باحتمال عدم حدوثه، (*Pamplé, 2000, p.12*)

الصيغة الرياضية لمعامل الترجيح يعطي فرصة أكبر لفهم العلاقة بين معامل الترجيح والاحتمالات:

$$O = \frac{p}{1-p}$$

حيث O هي معامل الترجيح ، P هي احتمال وقوع الحدث ، $(1-P)$ هي احتمال عدم وقوع الحدث.

تقدير وتفسير معاملات الانحدار اللوجستي:

من أجل تقدير معاملات الانحدار اللوجستي يتم اللجوء إلى طريقة الاحتمال الأعظم Method Likelihood Maximum ، التي تعتبر الطريقة الأكثر ملائمة لكافة النماذج الخطية وغير الخطية ، وتعرف طريقة الاحتمال الأعظم بأنها طريقة تكرارية Iterative تعتمد على تكرار العمليات الحسابية عدة مرات، حتى يتم الوصول إلى أفضل تقدير للمعاملات، والتي من خلالها يمكن تفسير البيانات المشاهدة . (*Newsom, 2003, 65*) .

1) طرق تقييم النموذج :

1.1 جدول التصنيف Classification Tables: إن استخدام جدول التصنيف يعتبر إحدى طرق فحص جودة مطابقة النموذج للبيانات ، وتعتمد هذه الطريقة على انشاء جدول يوضح عدد الحالات التي تمتلك الصفة المرغوب فيها أو الحالات التي لا تمتلك الصفة المرغوب فيها والتي تم تصنيفها بطريقة صحيحة أو بطريقة خاطئة (*Soderstrom & Leitner, 1997*) ، وتتطلب هذه

الطريقة الحصول على متغير تابع مشتق من النموذج من خلال تحديد نقطة قطع C ، ثم مقارنة الاحتمالات المتوقعة بتلك النقطة، بحيث إذا تجاوزت الاحتمالات المتوقعة نقطة القطع C أعطيت تلك الحالة تصنيفاً متوقعاً يساوي واحد، وما عدا ذلك فإن الحالة يعطى لها تصنيف متوقع يساوي الصفر، علماً بأنه غالباً ما تكون نقطة القطع C تساوي 0.5 (Frass & Newman, 2003) وتعتمد فكرة استخدام هذا التحليل على أن النموذج إذا قام بتوقع تصنيف الحالات بشكل صحيح اعتماد على معيار ما ، فإن ذلك يعطي برهاناً بأن النموذج يطابق البيانات المشاهدة (Ferrer & Wang, 1999) .

جدول (1) جدول التصنيف				
المجموع	التوقع		التصنيف	
	الموجب	السالب	الموجب	السالب
P= TP+FN	الموجب الصحيح TP	السالب الخاطئ FN	الموجب P	المشاهد
P'= FP+TN	الموجب الخاطئ FP	السالب الصحيح TN	السالب N	
N=TP+FN+FP+TN	Q= TP+FP	Q'= FN+TN	المجموع	

Sensitivity: ويرمز لها بالرمز SE ، وتعرف بأنها قيمة الاحتمال، بأن يكون التصنيف المتوقع موجباً للحالة التي تكون فعلاً موجبة وتحسب حسب المعادلة :

$$SE = \frac{TP}{TP+FN} = \frac{TP}{P}$$

Specificity: ويرمز له بالرمز SP، وتعرف بأنها قيمة احتمال، أو يكون التصنيف المتوقع سالباً للحالة التي تكون فعلاً سالبة، وتعطى حسب المعادلة

$$SP = \frac{TN}{FP+TN} = \frac{TN}{P'}$$

الدقة (accuracy): تعني قرب القيمة المقاسة من القيمة القياسية أو القيمة الفعلية، على سبيل المثال ، إذا كنت في المختبر تحصل على قياس للوزن يبلغ 3.2 كغ لمادة معينة ، لكن الوزن الفعلي أو المعروف هو 10 كغم ، فإن قياسك غير دقيق (not accurate). في هذه الحالة، لا يكون قياسك بالقرب من القيمة المعروفة.

ويمكن قياس الدقة (accuracy) من خلال العلاقة التالية: $Accuracy = \frac{TN+TP}{N}$

الضبط (Precision): تشير إلى قرب قياسات اثنين أو أكثر من بعضها البعض. باستخدام المثال أعلاه، إذا كنت تزن مادة معينة خمس مرات ، وتحصل على 3.2 كجم في كل مرة ، يكون القياس دقيقاً للغاية (very precise). الدقة أو الإحكام (Precision) مستقلة عن الدقة (accuracy).

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

يمكنك أن تكون دقيقًا جدًا (very precise) ولكن غير دقيق (accuracy). ، كما هو موضح أعلاه. يمكنك أيضًا أن تكون دقيقًا (accuracy) ولكن غير محكم (دقيق) (imprecise) .

$$\text{Precision} = \frac{TP}{TP+FP} \quad \text{يتم حسابها كالتالي:}$$

يتم احتساب معدل الخطأ (error rate) لكل التصنيفات حسب الصيغة التالية : Error

$$\text{Rate} = \frac{FN+FP}{N}$$

معدل الخطأ الموجب (The false positive rate) يتم حسابه كم خلال الصيغة: The false

$$\text{positive rate} = \frac{FP}{FP+TP}$$

نسبة التصنيف الصحيح Hit Ratio : وتعرف بأنها قيمة احتمال التصنيف الصحيح، كما أنها تعرف أيضًا بنسبة الكفاءة، وإذا كانت الكفاءة Efficiency ، والتي يرمز لها بالرمز EF وتعرف

$$EF = TP + TN \quad \text{بانها:}$$


فان نسبة التصنيف الصحيح أو ما يعرف بنسبة الكفاءة تساوي

$$\text{HitRatio} = \frac{EF}{\text{Total}} = \frac{(TP + TN)}{P + P'} = \frac{(TP + TN)}{(Q + Q')}$$

علمًا بأن جميع هذه المقاييس تتطلب قاعدة للتقرير واتخاذ القرار (أو ما يسمى ب threshold) لتصنيف نتائج الاختبار إما موجباً أو سالباً (Ferrer & Wang, 1999, Obuchowski, 2005). لكن كما يقول (Hosmer & Lemshow, 2000, p. 156) بأنه لسوء الحظ فإن هذا الوضع وهو استخدام هذا التحليل مبرهناً على مطابقة النموذج للبيانات قد لا يعمل دائماً ، حيث من السهل تصميم وضعية يكون فيها تحليل الانحدار اللوجستي صحيحاً ويطابق البيانات المشاهدة ، ومع ذلك يعطي تحليل جداول التصنيف نتائج سيئة وضعيفة ، إن سبب ذلك يعود إلى أن صحة التصنيف تعتمد على التوزيع الأصلي للمتغير التابع وحساسية التحليل لنسب أحجام مجموعتي العينة، حيث دائماً ما يفضل التحليل تصنيف الحالات لصالح المجموعة الأكبر حجماً، وهي حقيقة مستقلة عن وجود مطابقة النموذج، بمعنى أن دقة التصنيف أو عدمها لا يعكسان المعيار المفترض لجودة المطابقة ، وهو قرب أو بعد المسافات بين القيم المشاهدة والمتوقعة للنموذج، كما يلاحظ أنه إذا كانت هناك حالات كثيرة لها احتمالات تقترب من نقطة القطع فإن من المتوقع أن يكون مقدار سوء التصنيف كبير (Nichols, Orehovec & Ingold:1998; Soderstrom & Leitner:1998) ويرى (Ferrer & Wang: 1999) أن إحدى مميزات هذه الطريقة أنها تمكن الباحث من مقارنة نتائج التحليل لأسلوبين إحصائيين مختلفين تماماً، كما هو الحال في مقارنة نتائج تحليل الانحدار

اللوجستي مع نتائج التحليل التمييزي، وذلك لأن كلا الأسلوبين يعيطان جدول التصنيف نفسه والذي يمكن من خلالهما إجراء المقارنة.

1.2 تحليل منحني ROC: إن تمثيل (1-الدقة) في مقابل الحساسية لجميع نقاط القطع فإن ذلك يعطي شكلاً في غاية الأهمية في تقييم النموذج وهو ما يسمى منحني خاصية تشغيل المستقبل Receiver Operation Characteristic والمعروف اختصاراً بمنحني ROC كما في الشكل التالي (Westin,2005:Chatellier,1998)



لقد بدأ استخدام منحني ROC خلال الحرب العالمية الثانية اعتماداً على نظرية النقاط الإشارات، والتي توضح كيفية النقاط المشغل المستقبل إشارات الرادار عند وجود التشويشات، وهي ترسم احتمال التعرف على الإشارة الصحيحة (sensitivity) والإشارة الخاطئة (1-specificity) على المدى الكلي لنقاط القطع الممكنة (Fawcett,2005 & Ting,2004) ويبدأ منحني ROC بالإحداثي (0,0) المقابل لنقطة القطع للحالات السالبة، أما الطرف الآخر فإن الإحداثي (1,1) يقابل نقطة القطع للقرار بأن جميع الحالات موجبة. أما الخط الذي يصل بين النقطتين (0,0) و(1,1) فيسمى بقطر الصدفة Chance Diagonal، وهو يمثل منحني ROC لاختبار التصنيف الذي ليس له قدرة على التمييز بين الحالات الموجبة والحالات السالبة. ولكن عندما يكون المنحني واقعا أعلى من قطر الصدفة فإن هذا يعني أن النموذج له قدرة تصنيفية وتميزية بين الحالات الموجبة والسالبة، وكلما ابتعد المنحني عن قطر الصدفة، نحو الجهة اليسرى وإلى الأعلى كلما زادت قدرة النموذج على التصنيف (Obuchowski,2005). وتعطى المساحة تحت المنحني ROC والتي تتراوح ما بين الصفر والواحد صحيح مقياساً لمدى قدرة النموذج على التصنيف بين الحالات التي تمتلك السمة موضع الدراسة، أو الفحص والحالات التي لا تمتلك هذه السمة، وهي أي المساحة تحت

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

المنحنى ROC تعتبر من أفضل مقاييس دقة التصنيف (Hosmer&Lemshow,2000; Bradle,1997).

1.3 تقنيات التحقق المتقاطع (Cross Validation Techniques):

يعد التحقق من المتقاطع (Cross Validation) أحد الإجراءات العامة المستخدمة في بناء النماذج الإحصائية. ويمكن استخدامه لاتخاذ قرار بشأن النموذج الإحصائي وذلك يشمل نماذج السلاسل الزمنية ونماذج الانحدار ونماذج توزيع المزيج ونماذج التمييز (Chernick-2008). تعد عملية التحقق المتقاطع طريقة إحصائية للتقييم والمقارنة، وذلك من خلال تقسيم البيانات إلى جزأين: يتم استخدام أحدهما لتقدير المعلمات أو تدريب النموذج والقسم الآخر يستخدم للتحقق من صحة النموذج واختباره. يتم إجراء التحقق من الصحة بطرق مختلفة.

في هذا البحث سوف نقوم بتطبيق (Leave-One-Out Cross-Validation)

التحقق من صحة التدفقات المتقاطعة (Leave-One-Out Cross-Validation) (LOOCV): يعتبر التحقق من صحة التدفقات المتقاطعة (LOOCV) حالة خاصة من التحقق المتقاطع k-fold حيث k يساوي عدد أجزاء البيانات، وبعبارة أخرى يتم استخدام جميع البيانات تقريباً باستثناء جزء واحد للتدريب ويتم اختبار النموذج المقدر على هذا الجزء من البيانات المتبقي والذي لم يدخل في بناء النموذج. من المعروف أن دقة النموذج المقدر باستخدام LOOCV غير متحيزة تقريباً، ولكنها ذات تباين عالٍ، مما يؤدي إلى تقديرات غير موثوقة (Efron، 1983). لا يزال يستخدم على نطاق واسع عندما تكون البيانات المتوفرة نادرة للغاية، خاصة في مجال المعلوماتية الحيوية حيث تتوفر عشرات البيانات فقط. يمكن تطبيق التحقق المتقاطع لملائمة النموذج عدد n من المرات، في كل مرة يتم استبعاد بعض المشاهدات وبعد ذلك يتم اختبار النموذج لتقدير معالم النموذج أو التنبؤ بالملاحظات التي تم استبعادها في كل مرة، وهذا يوفر اختباراً عادلاً من خلال اختبار مشاهدات لا تستخدم في ملائمة النموذج، كما أنه فعال في استخدام البيانات لملائمة النموذج نظراً لأنه في كل مرة يتم استخدام (n - 1) من المشاهدات في الملاءمة النموذج. نسبة النجاح (Hit ratio) هي النسبة المئوية للحالات (الأفراد ، المستجيبون ، الشركات ، إلخ) والتي تم تصنيفها بشكل صحيح حسب النموذج. يتم حسابه على أنه عدد الكائنات في قطر مصفوفة التصنيف مقسوماً على العدد الكلي (n). تُعرف نسبة النجاح أيضاً باسم النسبة المئوية للأجسام المصنفة بشكل صحيح (Hair et al. 2009).

2) التحليل الإحصائي للبيانات:

مقدمة : وقد تم اختيار مجموعة من الأشخاص الذين يراجعون العيادات الطبية سواء كانت هذه العيادات حكومية أو خاصة أو هي تابعة لوكالة الغوث وتشغيل اللاجئين ، تم الحصول على بعض

التحليلات التي أجراها الأشخاص المراجعين لهذه العيادات وتم تعيين استبانة ملحقه بهذه البيانات لنفس الأشخاص، حيث كان الاهتمام حول ما إذا كان هؤلاء الأشخاص مصابون أو غير مصابين بمرض السكري، هذا المتغير تم الاعتماد عليه على اعتبار أنه متغير تابع يتكون من فئتين هما مريض أو غير مريض، بحيث أن الفئة كانت تستهدف الأشخاص الذين كانت أعمارهم تزيد عن 25 سنة (البالغين) وخضعوا لفحص، وكانت النتيجة إما مصاب أو غير مصاب بمرض السكري.

2.1 مجتمع الدراسة: الفئة المستهدفة هم المرضى الذين يراجعون العيادات الطبية أو المراكز الصحية سواء كانت هذه المراكز حكومية أو خاصة أو حتى تتبع لوكالة الغوث وتشغيل اللاجئين والذين تزيد أعمارهم عن 25 سنة وذلك خلال العام 2017

2.2 العينة: تم أخذ عينة مكونة من 232 شخص مقسمين الى 172 مريض سكري و 60 غير مريض بالسكري حيث تم جمع هذه البيانات داخل المراكز الصحية والعيادات سواء كانت حكومة أو خاصة وقد تم تقسيم المرضى إلى مجموعتين (مريض/غير مريض) وفقاً لنتيجة الاختبار، فحص السكر في الدم، وكانت العينة موزعة على الجنسين وتحديدًا الأشخاص البالغين التي تزيد أعمارهم عن 25 سنة.

2.3 وصف البيانات: جدول (2) يحتوي على بعض الإحصاءات الوطنية للمتغيرات الكمية في الدراسة، حيث كان الوسط creatinine للمرضى يساوي 0.91 ولغير المرضى 0.80، ومتوسط Uric Acid للمرضى يساوي 4.55 ولغير المرضى يساوي 3.81، ومتوسط كرات الدم الحمراء HGB يساوي 13.4 ولغير المرضى يساوي 16.0، بينما متوسط مؤشر كتلة الجسم BMI للمرضى يساوي 33.12 ولغير المرضى 29.85، ومتوسط urea للمرضى يساوي 34.1 ولغير المرضى 28.33، وأن متوسط العمر للمرضى 56.9 سنة ولغير المرضى 47.6 سنة، ومتوسط الوزن للمرضى يساوي 84.8 كجم ولغير المرضى 77.9 كجم، ومتوسط HDL للمرضى يساوي 55.7 ولغير المرضى 44.4، ومتوسط LDL للمرضى يساوي 117.16، ولغير المرضى 111.3، كما نلاحظ أن متوسط الطول للمرضى يساوي 162.2 سم، ولغير المرضى 164.4 سم . كما نجد أن متوسط Cholesterol للمرضى يساوي 199.6 ولغير المرضى فإن المتوسط 189.6، الجدول التالي يوضح هذه النتائج:

جدول (2) يوضح الإحصاءات الوصفية للمتغيرات الكمية للبيانات						
المتغير	فئات المتغير	N	Mini	Max	Mean	Std. Deviation
Creatinine	مريض	172	0.68	3.10	0.91	0.31
	غير	60	0.71	1.07	0.80	0.09

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

					مريض	
0.27	0.88	3.10	0.68	232	الكلية	
1.49	4.55	12.00	2.90	172	مريض	Uric acid
0.98	3.81	6.40	1.70	60	غير مريض	
1.41	4.36	12.00	1.70	232	الكلية	
1.67	13.41	16.70	9.01	172	مريض	
16.00	16.00	16.00	16.0	16.00	غير مريض	HGB
1.76	13.23	16.70	9.01	232	الكلية	
10.70	33.12	73.60	16.6	172	مريض	
6.37	29.85	48.50	21.2	60	غير مريض	
9.86	32.28	73.60	16.6	232	الكلية	BMI
18.99	34.10	170	21	172	مريض	
5.10	28.33	43	21	60	غير مريض	
16.73	32.61	170	21	232	الكلية	
24.44	55.69	185	36	172	مريض	Urea
3.13	49.40	54	42	60	غير مريض	
21.27	54.06	185	36	232	الكلية	
8.72	56.93	78	31	172	مريض	
9.53	47.57	72	35	60	غير مريض	HDL
9.82	54.51	78	31	232	الكلية	
16.79	84.84	125	50	172	مريض	
12.12	77.90	95	50	60	غير مريض	
15.98	83.04	125	50	232	الكلية	الوزن
39.41	117.16	252	1	172	مريض	
						LDL

هارون بهار ، عبدالهادي أبو سعدة

غير مريض	60	71	198	111.33	30.20
الكلية	232	1	252	115.66	37.27
مريض	172	120	195	162.22	14.00
غير مريض	60	135	185	164.40	11.72
الكلية	232	120	195	162.78	13.46
مريض	172	141	330	199.63	36.98
غير مريض	60	147	261	189.60	27.90
الكلية	232	141	330	197.03	35.08

الجدول رقم (3) يوضح بعض الإحصاءات الوصفية للمتغيرات الفئوية التي تم جمعها من أفراد الدراسة، حيث يوضح الجدول أن 44.2% من المرضى كن من الإناث و55.8% كانوا من الذكور، وأن 83.7% من المرضى كانوا يعانون من الضغط النفسي المرتفع، وأن 16.3% لم يعانون من الضغط النفسي المرتفع، 75.6% من المرضى لا يوجد لديهم خطة غذائية ، وأن 24.4% كان لديهم خطة غذائية، كما نجد أيضا أن 56.4% من المرضى يستهلكون اللحوم مرة في الأسبوع، وأن 43.6% من المرضى يستهلكون اللحوم أكثر من مرة خلال الأسبوع، 27.9% من المرضى يستهلكون الخضروات والفواكه مرة خلال الأسبوع وأن 72.1% يستهلكون الخضروات والفواكه أكثر من مرة خلال الأسبوع ، 91.9% من المرضى لا يعانون من الفشل الكلوي، وأن 8.1% كانوا يعانون من الفشل الكلوي، 91.9% من المرضى لا يعانون من ارتفاع ضغط الدم ، وأن 8.1% كانوا يعانون من ارتفاع ضغط الدم، 75.6% من المرضى ليسوا مدخنين وأن 24.4% كانوا مدخنين، 84.9% من المرضى لا يحملون مؤهل جامعي و 15.1% يحملون مؤهل جامعي.

2.3% من المرضى كانوا من محافظة خانيونس 1.2% كانوا من الوسطى، وأن 46.5% كانوا من محافظة غزة، وأن 50% كانوا من محافظة الشمال، والجدول التالي يوضح النتائج السابقة.

جدول (3) يوضح الإحصاءات الوصفية للمتغيرات الكمية للبيانات			
الاسم المتغير	الفئة	مريض	غير مريض
		n=172	n=60
الجنس	انثى	44.2	53.3
	ذكر	55.8	46.7

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

56.7	16.3	لا يوجد	الضغط النفسي المرتفع
43.3	83.7	يوجد	
46.7	75.6	لا يوجد	يوجد لديه خطه غذائيه
53.3	24.4	يوجد	
66.7	56.4	مرة واحدة	استهلاك اللحوم فى الأسبوع
33.3	43.6	اكتر من مرة	
3.3	27.9	مرة واحدة	كمية استهلاك الخضروات والفواكه اسبوعيا
96.7	72.1	اكتر من مرة	
96.7	91.9	لا يوجد	فشل كلوي
3.3	8.1	يوجد	
96.7	91.9	لا يوجد	ارتفاع ضغط الدم
3.3	8.1	يوجد	
80.0	75.6	لا	مدخن
20.0	24.4	نعم	
60.0	84.9	لا	التعليم الجامعي
40.0	15.1	نعم	
0	0	رفع	المحافظة
43.3	2.3	خانيونس	
23.4	1.2	الوسطى	
13.3	46.5	غزة	
20	50	الشمال	

في الاقسام التالية سوف نتطرق الى الانحدار اللوجستي لإيجاد نموذج التنبؤ الخاص ببيانات مرضى السكري، ثم نقوم بعد ذلك بتقييم دقة النموذج الذي تم الحصول عليه باستخدام الانحدار اللوجستي باستخدام ثلاث طرق للتقييم وهي جدول التصنيف، ومنحنى ROC وكذلك validation cross وذلك باستخدام برنامج الإحصاء (R) لتقييم دقة النموذج المتحصل عليه.

2.4 نموذج الانحدار اللوجستي الثنائي لبيانات مرضى السكري

2.4.1 أهم المتغيرات في نموذج الانحدار اللوجستي للبيانات

لقد تم الحصول على البيانات الخاصة بمرض السكري من خلال مسح إجرائى في قطاع غزة في العام 2017 على المراكز الصحية والطبية العاملة في قطاع غزة، وتحديدأ المرضى المراجعين والذين يتلقون الخدمات الصحية في هذه المراكز، حيث تم التركيز على المرضى الذين يعانون من

مرض السكري، بمعنى تم تصنيف المرضى على أساس مريض سكري أو غير مريض سكري، وتم استخدام هذا المتغير كمتغير تابع في التحليل، حيث تم عرض مجموعة من المتغيرات المستقلة في الجدول (3.2 / 3.1) وقد خضع كل متغير من هذه المتغيرات إلى عملية ترميز معينة لضمان ملائمة هذه المتغيرات للتحليل، فقد تم ترميز المتغير التابع إلى (1،0) أي (مريض / غير مريض) كما تم ترميز المتغيرات المستقلة الثنائية التفرع (1،0) ، بالإضافة إلى المتغيرات الرقمية التي تحتوي على النموذج ويعد الانحدار اللوجستي بشكل عام طريقة لنمذجة الحالات التي فيها المتغير التابع ثنائي الاستجابة أي مكون من فئتين (0 ، 1)، في حين يمكن أن تكون المتغيرات المستقلة الداخلة في النموذج ثنائية أو أكثر من ثنائية وقد تكون أيضا متغيرات كمية ، وهذا ما تحقق في هذه البيانات الأمر الذي أجاز استخدام الانحدار اللوجستي لبناء النموذج الخاص، بتحديد أهم عوامل الخطر على مرضى السكري في قطاع غزة. حيث تم من خلال هذا الأسلوب الإحصائي بناء نموذج جيد في تحديد أهم عوامل الخطر التي إن وجدت يصاب المريض بداء السكري، وأهم هذه العوامل كانت حسب المعادلة التالية:

$$\log it [p(Y=1)] = \ln \left[\frac{p(Y=1)}{1-p(Y=1)} \right] = -27.7 + 0.262 X_1 + 2.945 X_2 - 0.425 X_3 + 0.167 X_4 - 2.226 X_5 + 0.705 X_6 + 1.705 X_7$$

جدول (4) المتغيرات الهامة في النموذج	
Y	المتغير التابع مرض السكري (مريض / غير مريض)
X1	ضغط الدم المنخفض
X2	الضغط النفسي المرتفع
X3	كمية استهلاك الخضروات والفواكه أسبوعيا
X4	العمر
X5	المؤهل العلمي
X6	استهلاك اللحوم في الأسبوع
X7	وجود خطة غذائية

3) عوامل الخطر على مرضى السكري:

تم استخدام نموذج الانحدار اللوجستي الثنائي، والذي تم شرحه في فقرة سابقة حيث كان هذا النموذج مناسباً لبيانات مرضى السكري على اعتبار أن المتغير التابع يتكون من فئتين وهما: (مريض / غير مريض). الجدول (5) يوضح معاملات النموذج مع الخطأ المعياري ونسب الأرجحية لعوامل الخطر على مرضى السكري.

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

جدول (5) معاملات النموذج المقدر والخطأ المعياري ونسبة الاحرجية					
EXP(B)	SIG	Z-VALUE	STD	B	
0	0.00	-5.269	5.252	-27.67	الثابت
1.3	0.00	4.865	0.054	0.245	ضغط الدم المنخفض
19.1	0.00	4.665	0.631	2.942	الضغط النفسي المرتفع
0.65	0.00	-3.716	0.114	-0.425	كمية استهلاك الخضروات والفواكه اسبوعيا
1.18	0.00	4.884	0.034	0.167	العمر
0.107	0.001	-3.461	0.643	-2.226	المؤهل
2.02	0.03	2.157	0.326	0.704	استهلاك اللحوم في الأسبوع
1.82	0.003	-2.883	0.591	1.705	يوجد لديه خطة غذائية

يوضح الجدول السابق، نتائج التحليل اللوجستي الثنائي حيث احتوى النموذج على أهم عوامل الخطر، على مرضى السكري، كذلك يوضح الجدول السابق (Odds Ratio) لكل عامل من عوامل الخطر لمرضى السكري، حيث نلاحظ أنه كلما ابتعدت قيمة (OR) عن الواحد الصحيح سواء بالزيادة أو النقصان كان هناك تأثير واضح لهذه المتغيرات المستقلة على المتغير التابع، حيث أظهر الجدول السابق أن متغير (الضغط النفسي المرتفع) كان له تأثير قوي جداً على مرضى السكري حيث يعتبر أهم عوامل الخطر على مرضى السكري حيث كانت قيمة (sig=0.0) وقيمة (OR=19.1)، وهذا يعني أن الشخص الذي يتعرض للضغط النفسي المرتفع، معرض للإصابة بمرض السكري 19 ضعفا مقارنة بالشخص الذي لا يعاني من هذا الضغط النفسي، في حين أن العامل الثاني كان (التعلم الجامعي) حيث كانت قيمة (sig=0.001) وقيمة (OR=0.107) وهذا يعني أن الشخص الذي يحمل مؤهلاً جامعياً معرض للإصابة بمرض السكري (9.3) مرة عن الشخص الذي لا يحمل مؤهل جامعي. في حين يوضح الجدول السابق أيضاً أن العامل الثالث من حيث الأهمية هو (استهلاك اللحوم في الأسبوع) حيث كانت قيمة sig=0.000 وقيمة OR=2.02 وهذا يعني أن الشخص الذي يستهلك اللحوم أكثر من مرة في الأسبوع، معرض للإصابة بمرض السكري 2.02 مرة عن الشخص الذي يستهلك اللحوم مرة واحدة خلال الأسبوع. في حين أن العامل الرابع كان (يوجد لديه خطة غذائية) حيث كانت قيمة sig=0.003 وقيمة OR=1.82 بمعنى أن الشخص الذي لا يوجد لديه خطة غذائية معرض للإصابة بمرض السكري بمقدار 1.8 عن الشخص الذي لديه خطة غذائية. في حين أن العامل الخامس كان (كمية استهلاك الخضروات والفواكه أسبوعياً) حيث نجد أن قيمته المعنوية sig=0.00، وقيمة OR= 0.65 بمعنى أن الشخص الذي يستهلك الخضروات

والفواكه مرة واحدة في الأسبوع معرض للإصابة بمرض السكري بمقدار (1.5) عن الشخص الذي يستهلك الخضروات والفواكه أكثر من مرة أسبوعياً. كذلك يوضح الجدول السابق أن ارتفاع ضغط الدم المنخفض كان العامل السادس من عوامل الخطر حيث كانت قيمة $\text{sig}=0.00$ قيمة $\text{OR}=1.3$. في حين أن العمر كان كذلك عامل الخطر السابع، والذي يؤثر على مريض السكري حيث كانت قيمة $\text{sig}=0.00$ وقيمة $\text{OR}=1.18$ وهو أقل عوامل الخطر تأثيراً على مريض السكري. وبالتالي يمكن ترتيب عوامل الخطر كالتالي من حيث الأهمية كالتالي: (الضغط النفسي المرتفع، التعليم الجامعي، استهلاك اللحوم في الأسبوع، يوجد لديه خطة غذائية، كمية استهلاك الخضروات والفواكه أسبوعياً، ضغط الدم المنخفض، العمر).

4. جدول التصنيف:

4.1- جدول التصنيف للنموذج المبدئي:

جدول (6) التصنيف في ظل عدم وجود المتغيرات المستقلة (لنموذج المبدئي)			
النسبة الصحيحة	غير مريض	مريض	
0.0	0.0	172	مريض
100	0.0	60	غير مريض
74.1	النسبة الكلية		

يوضح الجدول (6) نتائج جدول التصنيف وذلك في ظل عدم وجود أي من المتغيرات المستقلة في النموذج حيث نلاحظ من الجدول أن نسبة التصنيف الصحيح كانت 74.1%، وهذا يعطي معلومات عن النموذج المبدئي الذي لا يحتوي على أي من المتغيرات المستقلة، وفي ظل هذا التصنيف باننا سوف نحصل على نموذج انحدار مكون من الجزء الثابت فقط في النموذج والذي يساوي $y=1.053$ وهذا النموذج الذي يتم بناءً عليه التصنيف والذي في المجمل حصل على تصنيف بنسبة 74.1%.

4.2- جدول التصنيف للنموذج النهائي:

يوضح الجدول التالي التصنيف للنموذج النهائي، ويمكن مقارنة النتائج الخاصة بهذا الجدول رقم (7) مع النتائج التي حصلت عليها من الجدول رقم (6) وذلك لإظهار نسبة التحسن التي تحققت نتيجة إضافة المتغيرات المستقلة للنموذج النهائي حيث أن هذا النموذج أظهر أن نسبة التصنيف الصحيح بلغت 90.5% هذا يمثل تحسناً كبيراً وواضحاً مقارنةً بجدول التصنيف المبدئي والذي أظهر نسبة 74.1%. حيث تمثل الأعمدة في جدول التصنيف (7) القيم المتوقعة للمتغير التابع، في حين تمثل الصفوف قيمة المشاهدة الفعلية للمتغير التابع حيث يتضح من الجدول أن 94.2% من الحالات تم تصنيفهم مرضى وهم مرضى، وأن 80% من الحالات تم تصنيفهم غير مرضى وهم غير مرضى، في حين كانت النسبة الإجمالية للتصنيف الصحيح حوالي 90.5% وهذا يعني أن النموذج الذي حصلنا عليه جيد في التنبؤ بحالات مرضى السكري حيث أظهر النموذج تحسن من

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

74.1% في النموذج المبدئي إلى 90.5% في النموذج النهائي الذي يحتوي على المتغيرات المستقلة في النموذج.

جدول رقم (7) التصنيف للنموذج النهائي الذي يحتوي على المتغيرات المستقلة				
النسبة المئوية للتصنيف الصحيح	التوقع			التصنيف
	المجموع	غير مريض	مريض	
94.50%	172 P	10 FP	162 TP	مريض P
80%	60 P'	48 TN	12 FN	غير مريض N
90.50%	232 N	58 FP+TN	174 TP+FN	المجموع

ومن النتائج التي حصلنا عليها في جدول التصنيف رقم (7) يمكن الحصول على الجدول التالي


جدول رقم (8) يوضح الحساسية، معدل الدقة ومعدل الخطأ وكذلك المساحة تحت المنحنى							
النموذج	Sensitivity	Specifity	Accuracy	False Positive	Error Rate	precision	Area Roc
الانحدار اللوجستي	0.931	0.80	0.905	0.058	0.095	0.942	0.957

يتضح من الجدول (8) السابق أن النموذج نجح في التنبؤ بشكل صحيح بمن يعانون من مرض السكري بنسبة 94.2% ، في حين أن أولئك الذين لا يعانون من مرض السكري كانت بنسبة 80% ، بينما كان المعدل الإجمالي للتنبؤ الصحيح في النموذج النهائي، (التصنيف الصحيح) بلغ نسبة 90.5% ، مما يؤكد أن النموذج حاز على دقة عالية ويمكن الاعتماد عليها في التصنيف ، بمعنى أن نموذج الانحدار اللوجستي استطاع أن يصنف هذه الحالات بمعدل الدقة 90.5%، وهذا يدل على جودة النموذج، كذلك نلاحظ أن معدل الخطأ في التصنيف بلغ كان بنسبة 9.5%، في حين بلغت حساسية النموذج اللوجستي 94.2%، وهو ما يعني أنه عندما نقوم بإجراء اختبار تشخيصي للمرض عن طريق هذا النموذج الذي حصلنا عليه من خلال الانحدار اللوجستي فإننا سوف نحصل على 94.2% من فرصة التنبؤ بشكل صحيح عن حالة المريض بالسكري، بمعنى أن 94.2% من مرضى السكري سيتم تصنيفهم بمرضى السكري. في حين أن نسبة الغير مرضى بالسكري، وصنفوا

كذلك (غير المرضى) كانت حوالي 80%، في حين كان معدل الخطأ الإيجابي 5.8% بمعنى أن يكون غير المريض بالسكري، ويصنف أنه مريض وبلغت هذه النسبة حوالي 5.8%.
كما يمكن ملاحظة أن المساحة تحت منحنى Roc Curve بلغت حوالي 95.7% وهي نسبة جيد جداً وتعني أن النموذج استطاع أن يصنف الحالات المرضية والغير المرضية بشكل جيد ويمكن الاعتماد عليه في التصنيف.

5-منحنى Roc Curve لتقييم النموذج:

منحنى Roc Curve هو عبارة عن تقنية لتنظيم واختيار التصنيفات بناءً على أدائها بحيث عندما يصبح التصنيف أكثر حساسية فإنه سوف يحدد نسبة أكبر من التصنيفات الإيجابية الحقيقية التي سوف نعتد عليها في بناء النموذج اللوجستي، وعندما يصبح النموذج أكثر دقة، أي عندما تكون عدد التصنيفات الصحيحة كبير، مقارنة بعدد التصنيفات الخاطئة، ونستخدم هذه التقنية Roc في تقييم جودة النموذج لكي نستطيع الاعتماد عليه في عملية التصنيف.
ومن المعروف المساحة تحت المنحنى ROC تساوي الواحد الصحيح، بمعنى كلما زادت المساحة تحت المنحنى ROC والتي تتراوح ما بين الصفر والواحد صحيح كلما كان هناك قدرة أكبر للنموذج على التصنيف بين الحالات المرضية والغير مرضية.
والشكل التالي يوضح المساحة تحت منحنى ROC والذي تم بناءً على نموذج الانحدار اللوجستي الثنائي.



حيث يوضح الشكل السابق أن المساحة تحت منحنى ROC للنموذج الذي تم توقيفه تساوي (95.7) عند مستوى دلالة (0.05) وهذا يعني أن النموذج يساعد على التنبؤ بتصنيف حالات المتغير التابع أكثر مما تفعله الصدفة.

وخلاصة ما سبق: أن نمذجة المتغيرات الخاصة بمرضى السكري وتصنيفهم إلى مرضى وغير مرضى باستخدام تحليل الانحدار اللوجستي الثنائي أعطي نموذجاً ملائماً ومطابقاً للبيانات المشاهدة

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

بدرجة تفوق بكثير على الصدفة وهي 50% ، حيث يمكن الاعتماد على هذا النموذج من أجل الاستدلال الاحصائي للتعرف على احتمال أن يكون المريض مصاب أو غير مصاب بمرض السكري ومن ثم تصنيفها بناء على نتائج هذا النموذج.

6-طريقة leave-one-out cross-validation

وفقا لهذه التقنية تم توليد 1000 عينة عشوائية بدون استبدال أو إرجاع كما هو موضح لنا في الإطار النظري للدراسة، وقد أدرجت 7متغيرات في النموذج حيث كان النموذج مناسب لتصنيف ويمكن الاعتماد عليه في تصنيف الحالات المرضية، المصابة بمرض السكري وفي النهاية تم تقييم المشاهدات المتوقعة وتم الحصول على معدل التصنيف الصحيح للمشاهدات المتوقعة و تم الحصول على جدول تصنيف النتائج وكذلك الدقة والجدول التالي يوضح التصنيف باستخدام leave-one-out cross-validation

جدول (9) التصنيف للنموذج اللوجستي باستخدام leave-one-out cross-validation				
النسبة المئوية للتصنيف الصحيح	التوقع			التصنيف
	المجموع	غير مريض	مريض	
94.50%	752 P	41 FP	711 TP	مريض P
68.5	248 P'	170 TN	78 FN	غير مريض N
88.10%	1000 N	211 FP+TN	789 TP+FN	المجموع

يمكن أن نستنتج من الجدول (9) أن الدقة المقدره لنموذج الانحدار اللوجستي لمن يعانون من مرض السكري هو 90.1% ، في حين أن أولئك الذين لم يعانون من مرض السكري كانت نسبة الدقة لديهم 80.6% وأن التنبؤ الصحيح للتصنيف العام والصحيح هو 88.1% ، مما يؤكد دقة التصنيف باستخدام نموذج الانحدار اللوجستي ، كما يمكن أن نستنتج من الجدول السابق أن معدل الخطأ في التصنيف يساوي 11.9%، في حين أن حساسية النموذج اللوجستي بلغت 90.1% وهو ما يعني أنه عندما تقوم باختبار تشخيص لمرضى السكري المصابين بالمرض فإن هناك فرصة 90.1% للتنبؤ الصحيح عن حالة المريض. كما يمكن نستنتج أيضا أن الدقة الخاصة بغير المصابين

بمرضى السكري (specificity) بلغت 80.6%، وهذا يعني أن عندما نقوم بإجراء اختبار لتشخيص المرضى غير المصابين بمرض السكري فإن نسبة التنبؤ بصحة هذه الحالة بلغ 80.6%، بينما نلاحظ أن المعدل الإيجابي the true positive rate والذي يقيم مدى نجاح طريقة cross-validation في الكشف عن مرضى السكري المصابين بالمرض حيث بلغت هذه النسبة 90.1% والجدول التالي يوضح بعض الإحصاءات الخاصة بأداء النموذج، مثل الدقة والحساسية والتي حصلنا عليها من الجدول السابق:

جدول (10) يوضح الحساسية، معدل الدقة ومعدل الخطأ للنموذج اللوجستي باستخدام cross-validation						
error rate	fals positive rate	precision	Accuracy	Specificity	sensitivity	
0.119	0.054	0.945	0.881	0.806	0.901	L R

7-مقاييس جودة النموذج:

والآن وبعد الحصول على النموذج اللوجستي في الفقرة السابقة، لا بد وأن نتحقق من افتراضات النموذج، ومدى ملائمة النموذج لعملية التصنيف، وبالتالي فإن إحدى الطرق للكشف عن مدى ملائمة النموذج هي من خلال اختبار likelihood-ratio-test، وبعض الاختبارات الأخرى التي من خلالها يمكن قياس مدى جودة النموذج، الذي تم الحصول عليه، حيث تقيم هذه الاختبارات حسن وملائمة النموذج الذي يصف متغير الاستجابة (التابع)، وبين الجدول التالي نتائج اختبار (χ^2 / Nagelkerke R square / $-2\log\text{likelihood}$ / Cox & Snell R square) وكل هذه الاختبارات تشير إلى أنه لا يوجد دليل على عدم ملائمة النموذج، وقدرته على تصنيف فئات المتغير التابع والذي يمثل (المريض، وغير المريض) لمرضى السكري، والجدول التالي يوضح نتائج هذه الاختبارات.

جدول (11) يوضح اختبارات جودة النموذج					
Sig.	Chi-square	Nagelkerke R Square	Cox & Snell R Square	-2 Log likelihood	Step
0.816	4.432	0.727	0.495	106.521 ^a	1

يوضح الجدول السابق نتائج اختبار هوسمر، وليمشو للتحقق من افتراضات النموذج ومدى ملائمة النموذج، حيث يتضح في الجدول أن قيمة اختبار (chi square) تساوي 4.432 وقيمة

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

$\text{sig}=0.816$ وهذا يعني أننا لا نستطيع رفض الفرضية الصفرية والقائلة بعدم وجود علاقة بين المتغير التابع والمتغيرات المستقلة الذي دخلت النموذج، بمعنى أن المتغيرات المستقلة كانت مهمة في النموذج، أي أن النموذج مناسب لتمثيل العلاقة بين المتغير التابع والمتغيرات المستقلة. كما توفر قيمة $\text{Cox \& Snell R Square}$ ، $\text{Nagelkerke R Square}$ مؤشراً على مقدار التباين في المتغير التابع الذي يفسره النموذج حيث تتراوح قيمة هذين المؤشرين ما بين (0,1) وهذا يعني أن هتين القيمتين 0.495، 0.727 تشير إلى أن 49.5% و 72.7% من التباين في المتغير التابع يفسر من خلال مجموعة المتغيرات المستقلة التي دخلت النموذج، كما يوضح الجدول أن القيمة ($-\log=106.52$) تقيس مدى قدرة النموذج على التنبؤ وكلما قلت قيمة هذا الاختبار كلما كان النموذج أكثر دقة في عملية التنبؤ.

وبشكل عام فإن المؤشرات السابق في النموذج تشير الى أن النموذج له قدرة عالية في التنبؤ بالفئة الصحيحة المرضية وغير المرضية لكل حالة.

النتائج والتوصيات:

أهم النتائج:

تبين من خلال تحليل البيانات الخاصة بمرضى السكري أن أهم عوامل الخطر على مرضى السكري كانت مرتبة حسب درجة تأثيرها على مرضى السكري وهي كالتالية مرتبة حسب الأهمية: الضغط النفسي المرتفع وحصل على المرتبة الأولى من حيث التأثير على مرضى السكري، التعلم الجامعي وحصل على المرتبة الثانية من حيث درجة التأثير، في حين كمية استهلاك اللحوم في الأسبوع حصل على المرتبة الثالثة، يليه هل يوجد خطة غذائية لدى الشخص وحصل هذا المتغير على المرتبة الرابعة، كذلك كمية استهلاك الخضروات والفواكه المستهلكة أسبوعياً حصلت على المرتبة الخامسة من ناحية التأثير على مرضى السكري، في حين أن ضغط الدم المنخفض كان له أثر واضح على مرضى السكري، حيث حصل على المرتبة السادسة من حيث الأهمية، وأخيراً كان متغير العمر أحد عوامل الخطر التي تكون لها آثار على مرضى السكري. وفي المجمل استطعنا الحصول على أهم العوامل الخطر على مرضى السكري وذلك من خلال استخدام نموذج الانحدار اللوجيستي الثنائي حيث أعطى هذا النموذج نتائج جيد جداً في التنبؤ بحالة المريض المصاب بمرض السكري، كما تم استخدام ثلاث طرق إحصائية متطورة للتأكد من ملائمة هذا النموذج لتصنيف البيانات الخاصة بمرض السكري. وكانت النتائج قوية وتدعم استخدام النموذج اللوجيستي في تحليل هذه البيانات والحصول على نتائج ذات مدلولات قوية. حيث كانت المساحة تحت منحنى ROC تساوي (95.7%) وفي حين أن جدول التصنيف كانت نسبة التصنيف الصحيحة تساوي (90.5%)، في حين أن جدول Cross validation أعطى نسبة تصنيف صحيحة تساوي (88.1%) وهذه

المؤشرات تدعم الرأي القائل بأن الانحدار اللوجستي جيد في تصنيف الحالات المرضية والغير مرضية، الخاصة بمرض السكري الخاصة ببيانات مرضى السكري في قطاع غزة. والنموذج النهائي الذي حصلنا عليه كان حسب المعادلة التالية.

$$\log it [p(Y=1)] = \ln \left[\frac{p(Y=1)}{1-P(Y=1)} \right] = -27.7 + 0.262 X_1 + 2.945 X_2 - 0.425 X_3 + 0.167 X_4 - 2.226 X_5 + 0.705 X_6 + 1.705 X_7$$

Y	مرضى السكري (مريض/غير مريض) المتغير التابع
X1	ضغط الدم المنخفض
X2	الضغط النفسي المرتفع
X3	كمية استهلاك الخضروات والفواكه اسبوعيا
X4	العمر
X5	المؤهل
X6	استهلاك اللحوم في الأسبوع
X7	يوجد لديه خطة غذائية

التوصيات:

من النتائج السابقة يمكن أن نسرده بعض التوصيات الخاصة بمرضى السكري:

1. تقليل الضغط النفسي المرتفع، حيث أثبتت الدراسة أنه أحد أهم الأسباب التي تؤدي إلى مرض السكري، وقد يصنف الضغط النفسي المرتفع في المستقبل إلى السبب الرئيسي الغير مباشر للوفاة في فلسطين، نتيجة ما يترتب عليه من أعراض أو أمراض كثيرة، تؤدي في نهاية المطاف إلى الوفاة.
2. نوصي وزارة الصحة بالاهتمام بالجانب النفسي لجميع المرضى وخصوصاً مرضى السكري لما لهذا المرض من أثر فتاك وقتال والذي قد يعتبر القاتل الرئيس في المستقبل.
3. تنظم ضغط الدم، اتخاذ كافة السبل للحيلولة دون عدم انتظامه وتحديدأ ضغط الدم المنخفض لما له من أثر كبير على زيادة نسبة الإصابة بمرض السكري.
4. زيادة استهلاك الخضروات والفواكه حيث أثبتت هذه الدراسة أن الزيادة من كمية استهلاك الفواكه والخضروات تؤثر بشكل إيجابي على تقليل نسبة الإصابة بمرض السكري.
5. الحد من استهلاك اللحوم حيث أن زيادة استهلاك اللحوم يؤثر سلباً على زيادة معدل الإصابة بمرض السكري.
6. نوصي بوضع خطة غذائية مناسبة لمرضى السكري لما لذلك من آثار إيجابية على الحد من الإصابة بمرض السكري.

استخدام الانحدار اللوجستي لتحديد اهم عوامل الخطر على مرضى السكري في قطاع غزة

7. ننصح الشباب بمتابعة دراستها الجامعية حيث أن ذلك يزيد من توعيتهم بمخاطر مرض السكري وبالتالي المحافظة على صحتهم الأمر الذي ينعكس إيجابياً على الحد من الإصابة بهذا المرض.
8. نوصي وزارة الصحة بتوفير قاعدة بيانات الكترونية جيدة لجميع المرضى والمصابين بالأمراض وكذلك المراجعين حيث يمكن استخدامها في مجال البحث، وإعطاء أهمية كبيرة لمرض السكري.
9. نوصي وزارة الصحة بتأسيس مستشفى للطبيب النفسي والاكلينيكي والتدخل المبكر لمعالجة المرضى الذين من المتوقع إصابتهم بأمراض مختلفة نتيجة الضغط النفسي لتلافي ذلك في المستقبل.
10. نوصي الباحثين بإجراء المزيد من الأبحاث حول مرض السكر للمساعدة في تحديد كل عوامل الخطورة المسببة لمرض السكر واستخدام طرق إحصائية أخرى غير الانحدار اللوجستي الثنائي وكذلك تضمين متغيرات أخرى لها علاقة بمرض السكر.

المراجع :

أولاً- المراجع العربية:

بابطين، عادل بن احمد بن حسن(1429 هـ): الانحدار اللوجستي وكيفية استخدامه في بناء نماذج التنبؤ للبيانات ذات المتغيرات التابعة الثنائية القيمة. بحث مقدم للحصول على درجة الدكتوراة - تخصص احصاء وبحوث .

غانم، عدنان و الجاعوني، فريد خليل (2011): " استخدام تقنية الانحدار اللوجستي ثنائي الاستجابة في دراسة أهم المحددات الاقتصادية والاجتماعية لكفاية دخل الأسرة "دراسة تطبيقية على عينة عشوائية من الأسر في محافظة دمشق " ، قسم الاحصاء التطبيقي ، كلية الاقتصاد ، جامعة دمشق ، مجلة جامعة دمشق للعلوم الاقتصادية والقانونية- المجلد 27 -العدد الأول-2011

المؤتمر الدولي حول اللاجئين ومرض السكري ،(2017)، البحر الميت، الاردن

https://www.unrwa.org/sites/default/files/content/resources/declaration_of_the_international_conference_on_refugees_and_diabetes_-_arabic.pdf.

ثانياً- المراجع الأجنبية:

Abu-Zeid,H.&Kassab,A.(1992). Prevalence & health care features of hypoglycemia in semiurban- rural communities in southern SaudiArabia, Journal of Diabetes Care, 15.

Aldrich, John H. & Nelson, Forrest D.(1984). Linear probability, Logit, and Probit Models. Sage University Paper series on Quantitative Applications in the Social Scienies. No.07-045. Beverly Halls, CA: Sage.

Bhar, Haroun Musa (2013). The Use of Classification Methods to Identify the Most Important Risk Factors for Cardiovascular Patients in the Gaza Strip, thesis Submitted in Partial Fulfillment of Requirements for the Degree of M.Sc. of Statistics.

Chatellier, Gilles (1998). Logistic Regression Model: Conditions Required for Stability of Prediction. Medical Informatics Department, Broussais Hospital, Paris, France.

Cizek, Gregory J & Fitzgeraid, Shawn M. (1999). Methods, Plainly Speaking: An Introduction to Logistic regression. Measurement & Evaluation in Cunseling and Development. Vol. 31, janu, 1999.

- CMH(2002). The Concepts behind the Logistic Regression Model. Children's Mrecy Hospitals & Clinics. Pediatric Research. Available at: <http://www.cmh.edu/stats/model/logistic-concepts.asp>.
- Fawcett, Tom (2005). An Introduction to ROC Analysis. Pattern Recognition Letters. No.27,2006,861-874.
- Frank,B. (2001). Diet, life style & risk of the type 2 diabetes mellitus in women. The New England Journal of medicine,797-790 .(11) 345 .
- Fraas, Jojan W. & Newman Isadore (2003). Ordinary Least Squares Regression, Discriminant Analysis, and Logistic Regression: Question Researchers and Practitioners Should address When Selecting an Analytic Technique. Paper Presented at the Annual Meeting of the Education Research Association (Hilton Heal Island, GA, February 26- March 1, 2003).
- Ferrer, Alvaro J. Arce & Wang Lin (1999). Comparing the Classification Accuracy among Nonparametric, Parametric Discriminant Analysis and Logistic Regression Methods. Paper Presented at the Annual Meeting of the American Educational Research Association (Montreal, Quebec, Canada, April 19-23,1999).
- Hosmer, David W. & Lemeshow, Stanley (2000). Applied Logistic Regression. 2nd edition. New York: Johnson Wiley & Sons, Inc.
- Kleibbaum, David & Klein, Mitchel(2002). Logistic Regression: a Self-learning Teext. USA: Springer.
- Lea, Stephen(1997). Multivariate Analysis II: Manifest Variables Analysis. Topic 4: Logistic Regression and Discriminant Analysis. University of EXETER, Department of Psychology. Revised 11th March, 1997. available at: www.exeter.ac.uk/~SEGLea/multivare2/diclogi.html.
- Menard, Scott(2002). Applied Logistic Regression Analysis.2nd edition. Sage University Paper series on Quantitative Applications in the Social Sciencies. No.07-106. Beverly Halls, CA:Sage.
- Newsom (2003). Data Analsis II: Logistic Regression , Fall 2003, available at: http://www.upa.pdx.edu/IOA/newsom/da2/ho_logistic.pdf.
- Nichols, Jerry L.; Orehovec, Paul M.; Ingold, Scott et al (1998). Using Logistic Regression to Identify New "At-Risk" Freshmen. Journal of Marketing for Higher Education, Vol a(1) 1998. The Haworth Press, Inc. PP. 25-37.

- Obuchowski, Nancy A. (2005). Fundamentals of Clinical Research for Radiologists ROC Analysis. American Roentgen Ray Society. No.184, February 2005, 364-372.
- Okasha, Mahmoud K. & Abu Samra, Ashraf I. (2013). "Classification Methods for Hypertension Patients' Data in Palestine"; Proceedings of the 25th Annual International Conference on Statistics and Modeling in Human and Social Sciences; Department of Statistics; Faculty of Economics and Political Science; Cairo University; Cairo, Egypt; March 25-28, 2013.
- Pamphlet, Fred C. (2000). Logistic Regression Primer. Sage University Paper series on Quantitative Applications in the Social Sciences. No.07-132. Beverly Hills, CA: Sage.
- Pezullo, John C. (2003). Logistic Regression. (Revised at 11/18/2003) Available at: <http://members.aol.com/jonp71/logistic.html>.
- Poston, Duley L. (2004). Sociological Research: Quantitative Methods (Lecture notes, Lecture 7). Spring 2004.
- Schmidt, Amy Elizabeth (2000). An Approximation of A Hierarchical Logistic Regression Model Used to Establish the Predictive Validity of Scores on A Nursing Licensure Exam. Educational and Psychological Measurement, Vol.60, No.3, June 2000, 463-478.
- Soderstrom, Irina R. & Leitner, Dennis W. (1997). The Effects of Base Rate, Selection Ratio, Sample Size, and Reliability of Predictors on Predictive Efficiency Indices Associated with Logistic Regression Models. Paper Presented at the Annual Meeting of the Mid-Western Educational Research Association (Chicago, IL, October 15-18, 1997).
- Walker, Marilyn D. (1998). Discriminant Function Analysis. Lesson 8.
- Westin, Lena Kallin (2005). Receiver Operating Characteristic (ROC) Analysis Evaluating Discriminative Efforts Among Decision Support Systems. ISSN-0348-0542.
- www.exeter.ac.uk