

معالجة القيم المفقودة باستعمال طريقة تحليل المركبات

الرئيسية (PCA) و خرائط التنظيم الذاتي (SOM)

أ.م. د. قتيبة نبيل نايف / كلية الادارة والاقتصاد / جامعة بغداد
الباحث، بشرى رحيم جاسم

تاريخ التقديم: 2017/6/5

تاريخ القبول: 2017/10/31

المستخلص :

ان فكرة انجاز بحث حول البيانات غير التامة جاءت من ظروف بلدنا العزيز وما تعرض له من ويلات الحروب حيث أدى ذلك الى فقدان الكثير من البيانات المهمة وفي جميع نواحي الحياة الاقتصادية والطبيعية والصحية والعلمية الصرفة ... الخ. كما ان أسباب فقدان مختلفة ، منها ما يكون خارجاً عن ارادة المعينين او تكون بارادة المعينين اي يكون مخططاً لذلك بسبب الكلفة او المخاطرة او بسبب عدم توافر الإمكانيات للمعاينة. وان معالجة البيانات المفقودة في هذا البحث تمت باستخدام طريقة تحليل المركبات الرئيسية وتحليل المركبات الرئيسية الاحتمالية وذلك باستخدام المحاكاة، حيث تم اخذ متغيرات صحة الاطفال والمتغيرات التي تتأثر بها صحة الاطفال وهي الرضاعة وصحة الامهات وتحتوي متغير صحة الامهات على قيم مفقودة وتم معالجتها في برنامج (Matlab2015a) باستخدام طريقة تحليل المركبات الرئيسية وخرائط التنظيم الذاتي SOM حيث تم معالجة القيم المفقودة ومن ثم مقارنة الطرائق باستعمال جذر متوسط مربعات الخطأ وكانت افضل طريقة لمعالجة القيم المفقودة هي طريقة تحليل المركبات الرئيسية (PCA).

المصطلحات الرئيسية للبحث / مشكلة البيانات المفقودة، طرائق تقدير القيم المفقودة، تحليل المركبات الرئيسية (PCA) ، خرائط التنظيم الذاتي SOM.



مجلة العلوم
الاقتصادية والإدارية
العدد 104 المجلد 24
الصفحات 373-354

*البحث مستقل من رسالة ماجستير



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

المبحث الأول

1-1 المقدمة:

ان مشكلة البيانات المفقودة هي احدى مشاكل التحليل الاحصائي وهي مشكلة واقعية في الدراسات الإحصائية المختلفة ومن ضمن ذلك المسوحات والدراسات الميدانية وكذلك الدراسات الطبية كالاختبارات السريرية والدراسات الويبانية وغيرها الكثير. وبصورة عامة فإن اي مشاهدة مفقودة تشير الى ان هذه المشاهدة من المفترض ان تسجل بناءً على اسلوب المعاينة المخطط لها ولكن حدث الفشل في مشاهدتها. ولاسيما عندما يكون عدد القيم المفقودة كبير يؤثر في خصائص العينة المسحوبة من مجتمع الدراسة والذي يمكن ان يقود الى استنتاجات مضللة في تحليل البيانات . وفي الكثير من التحليلات الاحصائية وخاصة عند جمع البيانات نجد هناك مشكلة فقدان مشاهدات في بعض المتغيرات والتي يلجأ الباحثون الى تقديرها وفق طرائق خاصة للتقدير.

في هذا البحث قدمنا وسيلة جديدة لمعالجة القيم المفقودة في:

1- تحليل المركبات الرئيسية (PCA)(Principal Component Analysis)

2- تحليل المركبات الرئيسية الاحتمالية (probabilistic Principal Component Analysis) (PPCA)

وقد تم استخدام بيانات المسح الاقتصادي والاجتماعي في العراق MICS4 لعام 2011. وتم الاعتماد في بحثنا هذا على استبيان الاطفال والمرأة حيث يعتبر المسح العنفودي متعدد المؤشرات المصدر الرئيس للمعلومات عن وضع الاطفال حيث يوفر بيانات مؤشرات احصائية اساسية لقياس معدلات التنمية البشرية. ويعود المسح العنفودي متعدد المؤشرات اداة علمية ذات وجودة عالية لا يمكن الاستغناء عنها لتحديد وضع الاطفال والنساء.

2-1 مشكلة البحث:

يحدث فقدان البيانات بشكل واسع في المسح نتيجة لعدم استجابة بعض المستجيبين لبعض الاسئلة، وايضا قد يكون سبب فقدان بسبب عطل المعدات او تلف البيانات وتعتبر مشكلة فقد البيانات واقعاً لا بد من التعامل معه باسلوب علمي منهج بعيد عن الاخذ بالحلول السهلة (اللحذف) والتي قد لا تكون ملائمة لبعض الحالات.

فهذه المشكلة تقوينا الى التعريف بها والطرق الممكنة لمعالجتها بحسب نوع وكمية القيم المفقودة ومن المهم ان نسأل لماذا القيم مفقودة وهذا ممكن ان يساعدنا في ايجاد حل لهذه المشكلة ونتم معالجة القيم المفقودة باستعمال تحليل المركبات الرئيسية وتحليل المركبات الرئيسية الاحتمالية باستخدام خوارزمية التعويض (imputation algorithm) مع اجراء مقارنة بين اسلوبي التحليل.

3-1 هدف البحث:

يهدف البحث الى تقدير القيم المفقودة في تحليل المركبات الرئيسية وخرائط التنظيم الذاتي مع اجراء مقارنة بين اسلوبي التحليل وتطبيقاتها على بيانات المسح ومقارنتها ومعرفة افضل طريقة لمعالجتها.



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

المبحث الثاني/الجانب النظري

2-المفاهيم الأساسية لخرائط التنظيم الذاتي

1- الطوبولوجيا(**Topology**): هي أحد فروع علم الرياضيات الذي يهتم بدراسة تركيب ومكونات وخصائص جميع الفضاءات المختلفة، بحيث تبقى هذه الخصائص متشابهة تحت عملية التشكيل المتصلة (Smooth) دون أن تقوم بعملية تمزيق او يترك فتحات في الانتقال من أحدهما إلى الآخر وبالعكس ايضاً[10:p1:10].

2- الشبكات العصبية (**Neural Net works**): وهي من أهم مجالات الذكاء الاصطناعي حيث أنها تعكس تطوراً ملماوساً وهاماً في طريقة التفكير الإنساني، وإن فكرة الشبكات العصبية تدور حولمحاكاة العقل البشري باستخدام الحاسوب الآلي. حيث أن عملية المحاكاة تتم عن طريق حل المشاكل التي تواجهها، وذلك باتباع عمليات التعلم الذاتي والتي تعتمد على الخبرات المختزنة في الشبكة التي تحقق أفضل النتائج.[p1:12]

3-نموذج خليط جاووس(**Gaussian Mixture Model**): هو دالة كثافة احتمالية معلمية متمثلة بمجموع أوزان كثافات مركبات جاووس. ونموذج خليط جاووس(GGMS) عادة ما يستخدم كنموذج معلمى من التوزيع الاحتمالي للقياسات المستمرة. ونموذج خليط جاووس(GGM) يقدر المعلمات من بيانات التدريب باستخدام خوارزمية تعظيم التوقع EM المتكررة او تقدير الحد الأعلى اللاحق (MAP) من نموذج سابق مدرب جيداً. ونموذج خليط جاووس هو مجموع الأوزان M من مركبات كثافات جاووس تعطى بواسطة المعادلة الآتية:

$$P(Y/\lambda) = \sum_{i=1}^N w_i g(Y/\mu_i, \Sigma_i) \dots \quad (1.2)$$

حيث Y هي D من الابعاد المستمرة، قيم بيانات المتوجه، w_i , $i=1 \dots N$ ، هو خليط من الأوزان $g(Y/\mu_i, \Sigma_i)$ هي مركبات كثافات جاووس. كل مركبة كثافة هي D من متغيرات دالة Gaussian () وكما موضح في النموذج الآتي:

$$g(Y/\mu_i, \Sigma_i) = \frac{1}{(2\pi)^{D/2} / \Sigma_i^{1/2}} \exp \left\{ -\frac{1}{2} (Y-\mu_i)' \sum_{i=1}^{-1} (Y-\mu_i) \right\} \dots \quad (2.2)$$

حيث ان Σ_i هي مصفوفة التباين المشترك [29:p1:29]

2-مشكلة البيانات المفقودة Missing Data Problem

تنشأ البيانات المفقودة في المسوحات من اسباب عديدة و مختلفة ، فقد تكون نتيجة لعدم استجابة الاشخاص لبعض الاسئلة او بعض الاشخاص لا يمكن الاتصال بهم، وايضا قد يكون سبب فقدان بسبب عطل المعدات او تلف البيانات و لقد شهدت مشكلة البيانات المفقودة اهتماماً ملحوظاً في السنوات الاخيرة، ومع تطور السريع لأجهزة الحاسوب في معالجة العمليات أصبح تطوير طرائق تحليل البيانات المفقودة ممكناً نظرياً وعلى الرغم من ذلك مازال الكثير منها بحاجة للتطوير ويعاني من مشاكل عديدة ، حيث تم استعمال طريقة تحليل المركبات الرئيسية وتحليل المركبات الرئيسية الاحتمالية بهدف ايجاد افضل طريقة ملائمة لتقدير القيمة المفقودة. وفي هذا المبحث سوف يتم عرض انماط البيانات المفقودة والية البيانات المفقودة.

1.2.2 أنماط البيانات المفقودة Patterns of Missing Data

ان الطرائق الإحصائية المستخدمة لمعالجة مشكلة فقدان البيانات تعتمد على نمط البيانات المفقودة. وعليه فإن أنماط البيانات المفقودة تقسم على قسمين الأولى منها يكون ضمن الأنماط الخاصة Special Patterns والثانية ضمن النمط العام General Pattern.



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

1.1.2.2 النمط الأول: Pattern of Univariate Missing Data

وهو ابسط حالة من حالات البيانات غير التامة والتي تكون فيها المتغيرات جميعها تامة المشاهدة عدا متغير واحد يعني من فقدان في بيانته، و بعد هذا النوع من الأنماط الخاصة، والشكل (1.1) يوضح النمط الاول [p.p18:4]

الشكل (1.1) نمط فقدان البيانات لاحد المتغيرات

$\underline{Y_1}$	$\underline{Y_2}$	$\underline{Y_3}$...	$\underline{Y_N}$

2.1.2.2 النمط الثاني : النمط المرتب أو المترافق

Monotone or Nested Missing Data

في هذا النمط من البيانات غير التامة ترتيب المتغيرات بحيث يكون المتغير الذي يحتوي على اكبر عدد من الحالات البيانات هو أول المتغيرات ثم يأتي المتغير الذي يحتوي العدد الثاني اكبر عدد من الحالات المفقودة وهكذا بالنسبة لباقي المتغيرات . و من الممكن ترتيب المتغيرات بالاتجاه المعاكس كما موضح في الشكل(1.2)

: [p.p234:1]

الشكل (1.2) النمط المرتب او المترافق

$\underline{Y_1}$	$\underline{Y_2}$	$\underline{Y_3}$...	$\underline{Y_N}$

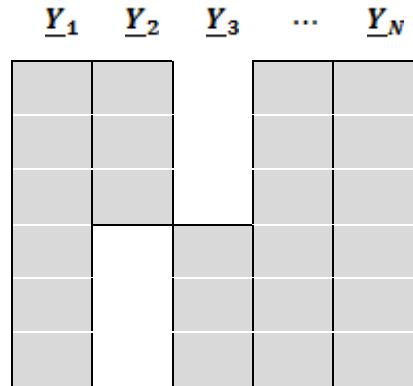
3.1.2.2 النمط الثالث : Missing Data with Unidentified Parameters

ويسمى بنمط فقدان البيانات في حالة عدم تطابق المعلم ، ويحدث هذا النمط عند دمج او توليف عينتين، و بعد هذا النمط آخر الأنماط الخاصة، والشكل (1.3) يبين هذا النمط من البيانات غير التامة [p.p19:4]:



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

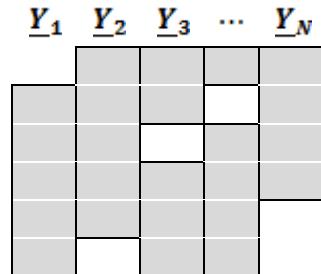
الشكل (1.3) نمط فقدان البيانات في حالة عدم تطابق المعالم



4.1.2.2 النمط الرابع : النمط العام General Pattern

في هذا النمط فقدان البيانات هو فقدان عشوائي أي انه لا يوجد نمط معين لفقدان البيانات، والشكل (1.4) يبين هذا النمط من البيانات غير التامة [p.p234:1].

الشكل (1.4) النمط العام للبيانات المفقودة



2.2.2.آلية البيانات المفقودة Missing Data Mechanisms

تختلف الطرائق الاحصائية الخاصة بتحليل البيانات غير التامة في فرضياتها حول الآلية التي تؤدي إلى فقدان البيانات .وان فهم هذه الآلية وتحديد طبيعتها يساعد كثيرا في اختيار الطريقة المناسبة للتحليل بل يعد المدخل لتشخيص الطريقة التي تقرب نتائجها من الأمثلية للبيانات المدروسة . وفي الادبيات الاحصائية تم تبني الاليات الآتية من انماط فقدان:

1- فقدان البيانات تماماً بشكل عشوائي

Missing Completely At Random(MCAR)

تفقد البيانات بشكل عشوائي تام (MCAR) اذا كان سبب فقدان مستقلا عن القيمة المفقودة نفسها وعن قيم المتغيرات الأخرى في العينة.

2- فقدان البيانات بشكل عشوائي

Missing At Random (MAR)

تفقد البيانات بشكل عشوائي اذا كان سبب فقدان له علاقة بقيم المتغيرات الأخرى فقط ومستقل عن القيمة المفقودة .



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

3- فقدان البيانات بشكل غير عشوائي

Missing Not At Random(Not MAR)

سبب فقدان ناتج عن القيمة المفقودة نفسها ومستقل عن قيم المتغيرات الأخرى فالبيانات هنا لا تفقد بشكل عشوائي (Not MAR) عند تحليل هذا النوع من البيانات يجب اخذ آلية فقدان بنظر الاعتبار. اما في حالة (MAR) و (MCAR) يمكن ان تهمل آلية التوزيع [7]. [p.p413:7]

ويمكن التعبير عن آلية فقدان رياضياً وذلك من خلال التوزيع الخاص بها والمقترح من قبل Rubin (1976) والمتمثل بالتوزيع الشرطي ل (R/M) وبمعامل مجهولة هي φ. [p.p20:4]

$$P(M/R, \phi)$$

حيث ان :

R: مصفوفة من درجة (n*P) وتدعى مصفوفة مؤشر البيانات المفقودة Indicator (Missing Data) وتمثل القيم المشاهدة والمفقودة لجميع المتغيرات Matrix.

M تمثل مصفوفة لها نفس درجة المصفوفة R بحيث تكون عناصر المصفوفة m معرفة كالتالي:

$$m_{ij} = \begin{cases} 1 & \text{if } r_{ij} \text{ obs} \\ 0 & \text{if } r_{ij} \text{ miss} \end{cases}$$

فإذا كان:

$$P(M_m/R, \phi) = P(M_m/\phi) \quad \text{for all } M_m \quad \dots \dots \quad (1.2)$$

حيث ان **M_m** تمثل مصفوفة القيم المفقودة.

Φ المعلمة المجهولة.

فإن البيانات تفقد تماماً بشكل عشوائي (MAR).

اما اذا كان :

$$P(M_m/R, \phi) = P(M_m/R_0, \phi) \quad \text{for all } M_m \quad \dots \dots \quad (2.2)$$

فإن البيانات تفقد بشكل عشوائي (MAR).

اما الحالة التي يعتمد بها التوزيع على القيمة المفقودة وبحسب الصيغة الآتية :

$$P(M_m/M_0 R, \phi) = P(M_m/R_m, \phi) \quad \text{for all } M_m \quad \dots \dots \quad (3.2)$$

حيث ان **R₀** تمثل مؤشر مصفوفة القيم المفقودة.

هنا يمكن القول أن البيانات لا تفقد بشكل عشوائي (Not MAR) عند تحليل هذا النوع من البيانات يجب اخذ توزيع آلية فقدان بنظر العناية .

اما في حالة (MAR) و (MCAR) يمكن ان يهمل توزيع آلية فقدان. [pp235-236:1]

3-2 طرائق تدريب القيم المفقودة

منذ بدء العمل بمعالجة مشكلة البيانات غير التامة في نماذج الإنحدار والباحثين يحاولون جاهدين حل المشكلة بإستخدام اسلوب التعويض عن كل قيمة مفقودة بقيمة تقديرية تعتمد في تدريبها على عدة طرائق منها طريقة اقرب مجاور او التعويض بالمتوسط او التعويضات المتعددة، وأشار الباحثون الى ان تدريب القيم المفقودة يعني زيادة في حجم العينة قيد الدراسة ومن ثم يكون لهذه المعلومات تأثير رئيسي في زيادة كفاءة مقدرات انموذج الإنحدار لكن السؤال الذي يطرح نفسه هو ماذا لو كانت هذه القيمة المقدرة غير مماثلة بشكل كفؤ للقيمة المفقودة فسوف يؤدي ذلك الى زيادة المشكلة وتضليل المعلومات حول تلك المشاهدات بشكل اكبر هو اشبه ما يكون بالمريض الذي يوصف له دواء غير مناسب مما يزيد في معاناته [2]. وفي هذا

المبحث طرائق تعويض القيم المفقودة يمكن ان تقسم الى:

1- طرائق التعويض المفرد *single imputation methods*

2- طرائق التعويض المتعدد *multiple imputation methods*

اذ قمنا باستخدام تحليل المركبات الرئيسية و تحليل المركبات الرئيسية الاحتمالية لمعالجة القيم المفقودة.



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

1.3.2 التقدير باستخدام المتوسط الحسابي *Mean Imputation*

تعتمد هذه الطريقة على استبدال البيانات المفقودة بقيمة المتوسط (*Mean*) المقدر باستخدام المشاهدات غير المفقودة وكما يأتي [1]: [p.p237]:

$$\tilde{X} = \sum_{n_j} X_{obs} / n_j \quad (1)$$

حيث n_j تمثل عدد القيم المشاهدة فعلاً للمتغير X_j .

2.3.2 تقدير البيانات المفقودة باستخدام تحليل الانحدار

تستخدم هذه الطريقة لتقدير القيم التي سيتم تعويضها بدلاً من القيم المفقودة، وذلك من خلال تكوين مصفوفة الإرتباطات الأساسية للمتغيرات ، وكل متغير يتضمن قيمًا مفقودة ، يتم معاملته على انه متغيرتابع من خلال معادلة الانحدار التي يتم تكوينها لكل فقرة تتضمن قيمًا مفقودة، ثم تستخدم المعادلات الناتجة، في الحصول على تقديرات لقيم المفقودة لكل متغير، وبعد ذلك تتم عملية إدخال او تعويض هذه التقديرات في مجموعة البيانات الناقصة التي تتضمن قيمًا مفقودة، والقيم المتباينة بها من معادلة خط الانحدار ، يتم تعويضها بدلاً من القيم المفقودة بكل فقرة . وهكذا تتكرر هذه العملية لكل فقرة تتضمن قيمًا مفقودة. [p.p25: 5]

4.2 طريقة التعويضات المتعددة

Multiple Imputation Method(MI)

يتم في هذه الطريقة استبدال كل قيمة مفقودة بمتوسط مجموعة من القيم المختارة عشوائياً ، ولذلك ينظر اليها على أنها تقدم قيمًا تعويضية باخطاء معيارية غير متحيزة في التحاليل الاحصائية، وهو ما يختلف عن طريقة حساب القيمة التعويضية الواحدة.[p.p26:3]

5.2 تحليل المركبات الرئيسية *(PCA)* (Principal Component Analysis)

المركبات الرئيسية تعد من اكثـر طـرائق التـحليل العـامـلي دـقة وـشـيوـعاً فـي الـبـحـث وـلـهـذـهـ الطـرـيقـةـ مـزاـياـ عـدـةـ مـنـهـاـ آـنـهـاـ تـؤـدـيـ إـلـىـ تـشـبـعـاتـ دـقـيـقـةـ وـتـؤـدـيـ إـلـىـ أـقـلـ قـدرـ مـمـكـنـ مـنـ الـبـوـاـقـيـ كـمـاـ أنـ الـمـصـفـوـفـةـ الـإـرـتـبـاطـيـةـ تـخـتـرـزـ إـلـىـ أـقـلـ عـدـدـ مـنـ الـعـوـاـمـلـ الـمـعـامـدـةـ (ـغـيرـ الـمـرـتـبـةـ)ـ وـهـيـ عـبـارـةـ عـنـ تـرـاكـيبـ خـطـيـةـ *Linear Combination* لـمـتـغـيرـاتـ عـشـوـانـيـةـ ذـاتـ خـصـائـصـ مـعـيـنـةـ تـدـعـىـ بـالـتـبـيـانـاتـ *Variances*ـ وـهـيـ فـيـ النـهـاـيـةـ مـتـجـهـاتـ مـمـيـزةـ *Characteristic Vectors*ـ لـمـصـفـوـفـةـ الـتـغـاـيـيرـ.ـ حـيـثـ أـنـ الـتـبـيـانـاتـ الـمـرـافـقـةـ لـهـذـهـ الـمـرـكـبـاتـ تـتـمـيـزـ بـخـصـائـصـ اـحـصـائـيـةـ.ـ فـيـ التـجـارـبـ الـاـحـصـائـيـةـ تـسـتـخـدـمـ طـرـيقـةـ الـمـرـكـبـاتـ الرـئـيـسـيـةـ لـإـجـادـ الـتـرـاكـيبـ الخـطـيـةـ بـتـبـيـانـ كـبـيرـ وـفـيـ كـثـيرـ مـنـ الـدـرـاسـاتـ عـنـدـمـاـ تـكـونـ الـمـتـغـيرـاتـ الـمـتـاـوـلـةـ فـيـ الـبـحـثـ كـبـيرـةـ جـداـ فـالـطـرـيقـةـ الـمـلـامـنةـ لـنـقـلـيـصـ هـذـاـ عـدـدـ الـكـبـيرـ مـنـ الـمـتـغـيرـاتـ هـوـ اـهـمـ الـتـرـاكـيبـ خـطـيـةـ الـتـيـ لـهـاـ تـبـيـانـاتـ صـغـيرـةـ،ـ وـدـرـاسـةـ الـتـرـاكـيبـ الـتـيـ لـهـاـ تـبـيـانـاتـ كـبـيرـةـ فـقـطـ.ـ وـتـنـطـوـيـ طـرـيقـةـ الـمـرـكـبـاتـ الرـئـيـسـيـةـ عـلـىـ تـحـوـيلـ مـجـمـوعـةـ فـيـ الـمـتـغـيرـاتـ الـمـرـتـبـةـ خـطـيـةـ X 'sـ إـلـىـ مـجـمـوعـةـ جـديـدةـ مـنـ الـمـرـكـبـاتـ الرـئـيـسـيـةـ V 'sـ عـلـىـ هـيـنـةـ تـرـاكـيبـ خـطـيـةـ مشـتـقـةـ مـنـ الـمـتـغـيرـاتـ التـوـضـيـحـيـةـ لـتـحلـ محلـهـاـ،ـ بـحـيثـ تـكـونـ مـؤـهـلـةـ لـتـفـسـيرـ مـعـظـمـ الـتـبـيـانـاتـ الـكـلـيـ لـلـقـيمـ الـأـصـلـيـةـ.

وـقـبـلـ انـ نـنـطـرـقـ إـلـىـ مـاهـيـةـ الـمـرـكـبـاتـ الرـئـيـسـيـةـ لـأـبـدـ لـنـاـ مـنـ التـعرـيفـ بـالـجـذـورـ وـالـمـتـجـهـاتـ الـذـاتـيـةـ (ـالـمـمـيـزةـ)ـ

*Eigen Values and Eigen Vectors*ـ،ـ فـلـوـ فـرـضـنـاـ الـمـصـفـوـفـةـ X ـ درـجـتهاـ q ـ وـحـصـلـنـاـ عـلـىـ مـتـجـهـ

عمـودـيـ غـيرـ صـفـريـ b_i ـ عـدـ عـاـنـصـرـهـ q ـ وـقـيـمةـ غـيرـ مـتـجـهـ هيـ λ_i ـ فـانـ:-

$$Xb_i = \lambda_i b_i \quad \dots \quad (1.2)$$

حيـثـ قـيـمـ λ_i ـ الـتـيـ تـحـقـقـ هـذـهـ الـمـعـادـلـةـ تـسـمـيـ بـالـجـذـورـ الـمـمـيـزةـ لـلـمـصـفـوـفـةـ X ـ،ـ اـمـاـ الـمـتـجـهـاتـ b_i ـ الـتـيـ تـنـاظـرـ هـذـهـ الـجـذـورـ فـسـمـيـ بـالـمـتـجـهـاتـ الـمـمـيـزةـ لـلـمـصـفـوـفـةـ X ـ.ـ مـنـ الـمـعـادـلـةـ (1.2)ـ:

$$[X - \lambda_i I][b_i] = 0 \quad \dots \quad (2.2)$$

حيـثـ انـ I ـ مـصـفـوـفـةـ الـوـحدـةـ.



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

فإذا كانت المصفوفة $[X - \lambda_i I]$ غير احادية، فيمكن ايجاد \underline{b}_i بضرب المعادلة (1.2) ضرباً قبلياً في معكوسه هذه المصفوفة، وفي هذه الحالة تكون \underline{b}_i متوجهاً صفرياً وهو ما يتعارض مع كون \underline{b}_i متوجهاً غير صفرى، لذلك فإن الشرط اللازم لإيجاد المتوجه \underline{b}_i ان تكون المصفوفة $[X - \lambda_i I]$ احادية، أي ان قيمة محددها يساوي صفرأ.

$$|X - \lambda_i I| = 0 \quad \dots \quad (3.2)$$

وتسمى المعادلة (3.2) بالمعادلة المميزة *Characteristic Equation* للمصفوفة X وبحلها يمكن ايجاد قيم λ_i ، وباستخدام المعادلة (2.2) يمكن ايجاد المتجهات المميزة المناظرة لتلك الجذور بحيث تكون هذه المتجهات متعامدة *Orthogonal* فيما بينها.

ولو كان لدينا q من المتغيرات العشوائية x_1, x_2, \dots, x_q بمتوسط مجتمع $\underline{\mu} = \underline{0}$ ومصفوفة التباين المشتركة Σ أي ان $X \sim N_q(\underline{0}, \Sigma)$ ونفترض ان المصفوفة S تمثل تقديرأً لمصفوفة التباين المشتركة للمجتمع بدرجة حرية $n = N - 1$ وتكون متماثلة حقيقة معرفة موجبة ($q.s.d$) او شبه موجبة ($q.s.d'$) فأهل خواص الجذور والمتجهات المميزة للمصفوفة S هي:

1. جميع الجذور المميزة للمصفوفة S تكون موجبة او غير سالبة وقد يكون بعضها متساوياً أي ان:

$$\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_q > 0 \quad \dots \quad (4.2)$$

2. نفترض ان المتجهات المميزة المناظرة للجذور المميزة هي $\underline{b}_1^*, \underline{b}_2^*, \dots, \underline{b}_q^*$ على الترتيب، وتكون المتجهات المميزة المتعامدة المعدلة *Normalised* للمصفوفة S هي $\underline{b}_1, \underline{b}_2, \dots, \underline{b}_q$ بحيث ان:

$$\underline{b}_i' \underline{b}_j = \begin{cases} 0 & \text{if } i \neq j \\ 1 & \text{if } i = j \end{cases} \quad i, j = 1, \dots, q \quad \dots \quad (5.2)$$

وان خاصية التعامل لها دور كبير في عملية تحليل المكونات الرئيسية المتعاقبة الى مجموع التباين الكلي للمتغيرات.

3. توجد المصفوفة T بحيث ان:

$$TST = D \quad \dots \quad (6.2)$$

حيث ان:

D : مصفوفة قطرية عناصر القطر فيها تمثل الجذور المميزة للمصفوفة S .

T : مصفوفة متعامدة، اعمدتها تمثل المتجهات المميزة المتعامدة المناظرة للجذور المميزة للمصفوفة X

وبامعان النظر بالمعادلة (6.2) نستطيع ان نميز:

$$\underline{b}_i' S \underline{b}_j = \begin{cases} 0 & \text{if } i \neq j \\ \lambda_i & \text{if } i = j \end{cases} \quad i, j = 1, \dots, q \quad \dots \quad (7.2)$$

المكونة الرئيسية الاولى V_1 للمتغيرات الاصلية x_1, x_2, \dots, x_q هي عبارة عن تركيب خطى حيث ان:

$$V_1 = b_{11}X_1 + b_{21}X_2 + \dots + b_{q1}X_q = \underline{b}_1' \underline{X} \quad \dots \quad (8.2)$$

حيث ان \underline{b}_1 يمثل المتجه المميز المناظر للجذر المميز λ_1 .

وطالما افترضنا ان $X \sim N_q(\underline{0}, S)$ فإن:

$$V_1 \sim N_q(0, \underline{b}_1' S \underline{b}_1) \quad \dots \quad (9.2)$$



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

وطالما ان $\underline{b}_1' S \underline{b}_1 = \lambda_1$ نستطيع القول ان:

$$V_1 \sim N_q(0, \lambda_1)$$

...(10.2)

أي ان الجذر المميز الاكبر للمصفوفة S يستخدم لنقدير التباين الاعظم للمكونة الرئيسية الاولى، والتجه المميز \underline{b}_1 يستخدم لنقدير المعاملات للمكونة الرئيسية الاولى. وبالطريقة نفسها تكون المكونة الرئيسية الثانية:

$$V_2 \sim N_q(0, \lambda_2)$$

... (11.2)

وبذلك نستطيع التعميم:

$$\underline{V} = \Gamma' \mathbf{X}$$

... (12.2)

اما عن التباين المشترك بين V_1, V_2 , فهو:

$$cov(V_1, V_2) = E(V_1, V_2) - E V_1 E V_2$$

... (13.2)

$$= E \underline{a}_1 \underline{X} \dot{\underline{X}} \underline{a}_2$$

$$= \underline{b}_1 E(\underline{X} \dot{\underline{X}}) \underline{b}_2$$

$$= \underline{b}_1 S \underline{b}_2$$

$= zero$

أي ان الارتباط بين المكونة الرئيسية الاولى والمكونة الرئيسية الثانية يساوي صفراء.

ان اهمية الجذور المميزة هي انها تعد وسيلة لقياس الابعاد الموضوعة في تلك البيانات طالما ان:

$$\sum_{i=1}^q \lambda_i = tr(S)$$

... (14.2)

$$\prod_{i=1}^q \lambda_i = |S|$$

... (15.2)

لهذه الخاصية اهمية كبيرة في تفسير المكونات الرئيسية، حيث ان المكونة الرئيسية V_i تكون خطية ومستقلة عن المكونة الرئيسية V_j والجذور المميزة للمصفوفة S λ_i, λ_j تمثل التباينات للمكونات الرئيسية V_i, V_j على الترتيب، لذلك ومن المعادلة (14.2):

$$\sum_{i=1}^q \lambda_i = \sum_{i=1}^q Var(V_i)$$

... (16.2)

وان الاصغرية النسبية للمكونة الرئيسية (jth) في وصف النموذج تقاس نسبتها الى مجموع التباين، أي ان:

$$\frac{Var(V_i)}{\sum_{i=1}^q Var(V_i)} = \frac{\lambda_i}{tr(S)} = \frac{\lambda_i}{\sum_{i=1}^q \lambda_i}$$

... (17.2)

في حالة كون المتغيرات المدروسة لها وحدات قياس مختلفة ففي هذه الحالة يصار الى تحويل المتغيرات الى الصيغة القياسية اولاً، وفي هذه الحالة فأن معاملات المركبات الرئيسية (b_{ij}) هي قيم المتجهات المميزة لمصفوفة الارتباط للمتغيرات القياسية. وطالما ان مصفوفة الارتباط متماثلة حقيقة موجبة ($q.d$) فأن جميع الجذور المميزة لها تكون موجبة، وكذلك:



**[PCA] معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية
و خرائط التنظيم الذاتي [SOM]**

$$\text{tr}(R) = \sum_{i=1}^q \lambda_i^* = q \quad \dots (18.2)$$

$$|R| = \prod_{i=1}^q \lambda_i^* \quad \dots (19.2)$$

حيث ان $q, \dots, \lambda_i^*, i = 1, \dots, n$ الجذور المميزة للمصفوفة R ، والأهمية النسبية للمكونة الرئيسية (V_i) في وصف النموذج تقاس بـ :

$$\frac{\text{Var}(V_i)}{\sum_{i=1}^q \text{Var}(V_i)} = \frac{\lambda_i^*}{\sum_{i=1}^q \lambda_i^*} = \frac{\lambda_i^*}{q} \quad \dots (20.2)$$

وإذا كانت بعض الجذور المميزة لمصفوفة الارتباط متساوية، فالمحاور المناظرة لهذه الجذور لها الطول نفسه، وإذا كانت جميع الجذور المميزة متساوية فإن القطع الناقص Ellipsoid يصبح كروي [p.p26:6].

وان تحليل المركبات الرئيسية (Principal Component Analysis) هي مثال على تقنيات اختزال الأبعاد حيث وظيفتها هو ايجاد رسم الخرائط D من ابعاد الفضاء الاصلي الى K من ابعاد الفضاء الجزيئي حيث $K < D$. فضلا عن اختزال الأبعاد وضغط البيانات. حيث تحليل المكونات الرئيسية اقتربت من قبل العالم JOLLIFFE عام 1986.

وعلى نطاق واسع تستخدم تحليل المركبات الرئيسية في تطبيقات أخرى مثل تصور البيانات، معالجة الصور، التعرف على الانماط والتنبؤ بالسلسل الزمنية.

وان الصيغ الأكثر شيوعا من تحليل المركبات الرئيسية (Principal Component Analysis) تعرف بصيغة تباين الحد الأعلى وتعرف Principal Component Analysis ب أنها الإسقاط المتعامد للبيانات على فضاء الأبعاد الخطية القليلة ، الفضاء الجزيئي الرئيس، بحيث يتم تكبير تباين البيانات ويتم الحفاظ على الحد الأعلى من المعلومات (information) وهذا مقترح من قبل HOTOLLING عام 1995 ويمكن ان نظهر ان الاسقاط الامثل ل K من ابعاد الفضاء الجزيئي هو ان نختار k من المتجهات الذاتية $\{W_j, j=1, \dots, k\}$ من مصفوفة البيانات المشتركة:

$$S = \frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})(x_n - \bar{x})^T$$

وان التحول الخطى من متجه المشاهدات x_n الى الفضاء الجزيئي الرئيس يعرف بواسطة المتجهات الذاتية z_n ليكون الناتج كما في المعادلة (21.2)

$$z_n = W^T (x_n - \mu) \quad (21.2)$$

حيث Z_n تسمى Z-scors المعيارية هي مجموعة نقاط Z لمتجه المشاهدات و K عدد الاعمدة للمصفوفة W حيث K تؤدي الى المتجهات الذاتية ل S و μ هو متوسط المشاهدات . الخاصية المكملة ل Principal Component Analysis هو ايجاد التمثيل الخطى ل k من الأبعاد للبيانات مثل إعادة بناء الخطأ التربيعي للبيانات كما في المعادلة الآتية :

$$\hat{x}_n = W z_n + \mu \quad (22.2)$$

تم تصغيرها [pp13:8].



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

2-5-1 تحليل المركبات الرئيسية في تقدير القيم المفقودة component Analysis With missing data

تستخدم خوارزمية التعويض (imputation algorithm) في تحليل المركبات الرئيسية لتقدير القيم المفقودة، حيث انه في تحليل المركبات الرئيسية (الكلاسيكية) التقليدية (Principal Component Analysis) ليس هناك طريقة واضحة للتعامل مع القيم المفقودة ، وقام بوصفها كل من (Riko, Ilne, Jolliffe, 2010). وان خوارزمية التعويض هي عبارة عن اجراءات متكررة حيث تكون احد البدائل بين تعويض القيم المفقودة في البيانات، T_{mis} وتطبيق تحليل المركبات الرئيسية القياسية لمصفوفة البيانات الكاملة.

ويتم حساب القيم الاولية للعناصر المفقودة T_{mis} بحساب الوسط الحسابي الخاص بكل صف من صفوف المصفوفة T ، وكذلك يتم تحديث متوسط المشاهدات \bar{t} في كل تكرار. ولخصت نتائج الخوارزمية مما ادى الى خوارزمية 3.1.4.2 [pp16:8].

2-5-2 خوارزمية التعويض لتحليل المركبات الرئيسية

The imputation algorithm for Principal Component Analysis يتم تحديد المعطى من بيانات T غير التامة مع العناصر المشاهدة T_{obs} والعناصر المفقودة T_{mis} .

1-تعريف العناصر المفقودة T_{mis} واعطاوها قيم اولية وذلك بحساب المتوسط لكل صف من صفوف مصفوفة المشاهدات T_{obs} .

$$T_{mis} \leftarrow mean(T_{obs})$$

حيث T_{mis} العناصر المفقودة من المصفوفة T ، T_{obs} العناصر المشاهدة للمصفوفة T .
وهذا ادى الى حساب البيانات التامة T_{imp} .

2- يتم تحديث متوسط المشاهدات \bar{t} لكل صف من صفوف المصفوفة T_{imp} .

$$\mu \leftarrow mean(T_{imp})$$

3- ايجاد الحل λ من المركبات الرئيسية للمصفوفة W باستخدام البيانات التامة.
4- يتم تحديث العناصر المفقودة كما يلي:

$$T_{mis} \leftarrow WW^T(T_{imp} - \bar{t}) + \bar{t}$$

5- يتم التحقق من وجود تقارب اما $Z = W^T(T_{imp} - \bar{t})$ او T_{imp} اذا كان معيار التقارب ليس له عودة الى الخطوة 2. [pp17:8].

2-6 خريطة التنظيم الذاتي (SOM)

هي احدى انواع الشبكات العصبية الاصطناعية التي تعتمد على مبدأ التعليم غير المراقب وتستخدم في مجالات متعددة ذكر منها التصنيف وتقليل او تخفيض الأبعاد. وتسمى خارطة التنظيم الذاتي (SOM) بشبكة كوهنون العصبية نسبة الى الباحث الفنلندي البروفيسور (Teuvo kohonen) الذي صممها في عام (1982) حيث انه اشتهر بعمله ومساهماته في استخدام الحاسوب والشبكات العصبية الاصطناعية. وان الخلايا العصبية في خريطة التنظيم الذاتي (SOM) عادةً ماتسمى وحدات خريطة او نماذج، وبالتالي يمكن ان ينظر اليها على انها عينات ممثلة للبيانات. و ان كل وحدة خريطة ترتبط مع متوجه إشارة (reference vector)، ويتم رسم الخريطة لكل بيانات المتوجه لوحدة الخريطة التي تمتلك متوجه اشارة ويكون معظم تشابهها لبيانات المتوجه نفسه. متوجه الاشارة W_i هي المعدلات الموزونة الموضعية للبيانات المرتبطة مع وحدة الخريطة التي تعطى في الاصل لفضاء البيانات .



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

حيث تستخدم خريطة التنظيم الذاتي (SOM) لصنع الأبعاد القليلة ، وعادة ثنائية الأبعاد وتمثيل وتصوير البيانات ذات الأبعاد العالية. وتضع خريطة التنظيم الذاتي شرط الطوبولوجيا للمحافظة على رسم الخرائط من فضاء البيانات الأصلية إلى وحدات الخريطة، وذلك لتشكيل شبكة ثنائية الأبعاد وهذا يوفر الوسائل لتصوير البيانات على سطح مستو (on a plane)، حيث تم ملائمتها ورسم خرائط التنظيم الذاتي SOM من نوع البيانات الاعتباطية والتي تكون مترادفة وكذلك يتم تعريف المسافات الزوجية وهذا مقترن من قبل [pp18:8]2002 (kohonen and somervuo).

1.6.2 خوارزمية خريطة التنظيم الذاتي

Self-Organizing Map(algorithm) (SOM)

تستخدم خريطة التنظيم الذاتي (SOM) مع متوجه ثانى الأبعاد من الوحدات ومن ثم خريطة التنظيم الذاتي (SOM) تحديد برسم فضاء البيانات المدخلة لمستوى ثانى الأبعاد . حيث انه لكل وحدة خريطة w_i يكون لديها متوجه اشارة (reference) معلمى (نموذج متوجه) $w_i \in R^d$ حيث ان: d : هو الأبعاد للبيانات .

w_i : متوجه اشارة يستخدم للإشارة الى وحدات ونموذج المتجهات الإبدالية.

حيث $T \in R^{N*D}$ يكون تدريب (training) مصفوفة البيانات مع عينات N من الأبعاد. وان كل بيانات المتوجه t_n يجب مقارنتها مع كل متجهات الاشارة w_i . ويتم استخدام المسافة الأقلية (Euclidean distance) والوحدة مع اصغر مسافة اقلية كما موضح في المعادلة (32.2) :

$$w_{c(t_n)} = \arg \min_i \|t_n - w_i\| \quad (32.2)$$

وتشير المعادلة (32.2) اعلاه الى افضل وحدة مطابقة لمتجه المشاهدات t_n .

حيث ان التدريب (learning) يبدأ بواسطة تهيئة متجهات الاشارة (reference vectors) $w_i(\tau = 0)$ حيث $\tau = 0$ تشير الى متغير الوقت المتقطع (discrete-time) وتمثل المقياس الزمني للتدريب .

ويتم تحديث متجهات الاشارة باستخدام المعادلة الآتية:

$$w_i(\tau + 1) = w_i(\tau) + h_{ci}(\tau)(x(\tau) - w_i(\tau)) \quad (33.2)$$

حيث $h_{ci}(\tau)$ هي الدالة المجاورة التي تُعرف على طول الشبكة لوحدات الخريطة . حيث تستخدم على نطاق واسع دالة جاؤس المجاورة (Gaussian neighborhood function) كما في المعادلة الآتية:

$$h_{ci} = \alpha(\tau) \cdot \exp \left\{ -\frac{\|r_c - r_i\|^2}{2} \right\} \quad (34.2)$$

حيث $\|r_c - r_i\|^2$ هي المسافة بين افضل وحدة مطابقة r_c ووحدة i في الصفر.

$\alpha(\tau) < 1$ هو نسبة التعلم ذات القيمة العددية و $\sigma(\tau)$ معلمة القطر.

ومن الضروري للتقارب ان $h_{ci} \rightarrow 0$ عندما $\tau \rightarrow \infty$ وعادة $\alpha(\tau)$ و $\sigma(\tau)$ كلاهما يأخذ بالتناقص بصورة تدريجية (monotonically).

حيث تؤخذ الاوزان بعين الاعتبار اثناء تحديث متجهات الاشارة لكل البيانات او لمجموعة من البيانات في وقت واحد ووفقاً لذلك يتم تحديث قاعدة w_i كما موضح في المعادلة (35.2) :

$$w_i = \frac{\sum_n h_{ni} t_n}{\sum_j h_{nj}} \quad (35.2)$$



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسيّة [PCA] و خرائط التنظيم الذاتي [SOM]

حيث n : هي مؤشر لكل متجهات البيانات التي تمتلك أفضل الوحدات المطابقة التي تقبل $b_{ni} > 0$ [pp61:9].

2.6.2 خريطة التنظيم الذاتي في تقدير القيم المفقودة

تم استخدام *Self-Organizing Map with missing values* خريطة التنظيم الذاتي لحساب القيمة المفقودة مع انواع كثيرة مثل بيانات المسح التي قام بها (Fessant and Cottrell 2002 و Wany 2003)، والبيانات الاقتصادية والاجتماعية التي قام بها (Midenet Cottrell 2007، و آخرون Gaubert 1996)، والبيانات الصناعية التي قام بها (Rustum 2007، and letrémy 2009، و آخرون Merlin 2010)، (and Adeloye 2007، Sorjamaa 2007، و آخرون Sorjamaa 2010). وان حساب القيم المفقودة في البيانات اعلاه يكون وفق ما اقترحه (and Adeloye 2007، Sorjamaa 2007، and letrémy 2007) حيث انه يتم حساب أفضل الوحدات المطابقة لمتجهات البيانات مع القيم المفقودة كما موضح في المعادلة (36.2) التالية:

$$w_{C xn} = \arg \min_i \|t_n - w_i\| = \sum_{k \text{ s.t } I_{nk}} (t_{nk} - w_{ik})^2 \quad (36.2)$$

اي انه يتم حساب المسافة فقط باستخدام المركبات الموجدة في المتوجه t_n . وكذلك يتم تجاهل القيم المفقودة اثناء تحديث متجهات الإشارة. وبعد التدريب، يتم التعويض عن القيم المفقودة وفقا لأفضل الوحدات المطابقة المناظرة لمتجهات البيانات، وهذا مقترن من قبل Cottrell and letrémy عام 2007.

المبحث الثالث / الجانب التجريبي

3- المقدمة (Introduction)

ان عملية المحاكاة هي تمثيل او تقليد الواقع الحقيقي باستخدام نماذج معينة، وكثيراً ما نجد في الواقع الحقيقي عمليات معقدة الفهم والتحليل، لذا من الأفضل ان نوصف هذه العمليات بصورة مشابهة للصورة الحقيقية بنماذج معينة، ففهم النموذج سيحقق قدرًا من الادراك للعملية الاصلية او الواقع الحقيقي من خلال نماذج المحاكاة . هذا وان درجة المشابهة بين أي تجربة محاكاة والواقع الحقيقي تعتمد على مدى مطابقة او مشابهة نموذج المحاكاة للواقع الحقيقي. وقد اعتمد اسلوب المحاكاة (Simulation) لتطبيق الطرائق المدروسة في الجانب النظري لمحاكاة أكبر عدد ممكن من الحالات التي من الممكن أن تواجهنا في الواقع العملي وللحصول على نظرة أكثر شمولية . وتظرا للسرعة التي قد توفرها الحاسوبات الإلكترونية والبرامج من حزم جاهزة وبرمجية مما ادى بالباحثين الى اعتمادها في محاكاة نماذجهم بسبب الصعوبة في البرهان الرياضي والنطري وكذلك توفر الامكانية في مقارنة أكثر من طريقة في الوقت نفسه ومعرفة أي من الطرائق هي الأفضل.

فضلاً عما ذكر انفا فإن المحاكاة توفر مرونة في التعامل وسهولة في تكرار تجارب من الصعوبة تكرارها في الواقع العملي وكذلك وضع افتراضات من ناحية التباين وحجوم عينات مختلفة . تم استعمال بعض الدوال الجاهزة والصيغ البرمجية في برنامج الـ Matlab 2015a (Matlab 2015a) في توليد البيانات وبناء نماذج المحاكاة لغرض المقارنة بين الطرائق باختلاف أحجام العينات والتباينات ولاكثر من نسبة للفقدان في قيم المتغير المستقل X_2 .



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] وخرائط التنظيم الذاتي [SOM]

Simulation Model

2-3 الأنموذج المستعمل في المحاكاة

تم استخدام نموذج انحدار خطى متعدد

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$

وبنسب فقدان (10%, 20%, 30%, 40%).

حيث المتغير X_2 يحتوى على قيم مفقودة والخطوات الآتية تبين سير الخوارزمية لكل طريقة.

PCA

3-خطوات طريقة تحليل المركبات الرئيسية :

1-حساب مصفوفة التباين والتباين المشترك ذات الابعاد $N \times N$ لمصفوفة انحرافات المتغير X ذو الابعاد $N \times P$.

2-استخراج المتجهات المميزة المرافقه للكل جذر مميز وحذف المتجهات التي ليس لها تأثير، عدد المتجهات الكلية $N \times K$ وبعد الحذف $N > K$ ، إذ أن $K < N$.

3-حساب z ذات الابعاد $K \times P$ من المعادلة $(W'W)^{-1}W'(X - \mu)$ ، إذ أن μ تمثل الوسط الحسابي الخاص بكل صف من صفوف المصفوفة X .

4-حساب مصفوفة المتجهات المميزة W من جديد من المعادلة $.XZ'(Z'Z)^{-1}$.

5-تكرار الخطوتين 3 و 4 لحين الوصول لحالة الاستقرارية.

6-حساب القيم المفقودة وكل عمود من X من المعادلة $.X_P = WZ_P + \mu$.

3-خطوات طريقة تحليل المركبات الرئيسية الاحتمالية :PPCA

- نفس الخطوات المتبعة في طريقة PCA لكن الفرق بدخول حد الخطأ العشوائي في الخطوة السادسة على تقدير القيمة المفقودة.

3-خطوات طريقة خريطة التنظيم الذاتي :SOM

1-فرض متجه اوزان اولى m يتم توليده من البيانات المدروسة وبالابعاد $N \times 1$.

2-حساب المسافات لكل قيمة من قيم m مع كل قيمة المتغير المعتمد X (هنا يتم اخذ فقط المتجه الذي يحتوى على مشكلة فقدان، أي متجه بطول N) وكما في المعادلة:

$$d(i) = \| m(i) - X \| = \sqrt{\sum_{j=1}^N (m(i) - X(j))^2}$$

1- يتم اختيار أقل قيمة من المسافات المستخرجة في الخطوة 2.

2-فرض قيم أولية لكل من نسبة التعلم $\eta(0)$ ومعلمة القطر $\sigma(0)$ وعدد تكرارات التجربة $r_{max}=1000$.

$$\eta(0) = 0.01, \sigma(0) > 0$$

3-تحديث الأوزان وفق المعادلة:

$$m_{(i)}^{(r)} = m_{(i)}^{(r-1)} + \eta(r) h^{(r-1)}(i, i_n) (X(i) - m_{(in)}^{(r-1)})$$

إذ أن:

$$- \eta(r) = \eta(0) e^{(-\frac{r}{r_{max}})}.$$



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

- $\sigma(r) = \sigma(0) e^{(-\frac{r \log(\sigma(0))}{r_{max}})}$.
- $h(r) = e^{(-\frac{dw_{(i)}^2}{2\sigma^2(r)})}$, where $dm(i) = \|m(i) - m(\min)\|$.

4- يتم اختيار ادنى قيمة من المتوجه m .

5- يتم اعادة الخطوتين 5 و 6 الى ان تصل عدد الخطوات الى r_{max} .

6- يتم اعتماد القيمة $m(i)$ بدل القيمة $(i) X$ المفقودة.

3-5-تحليل نتائج المحاكاة

متوسط مربعات الخطأ عند التعويض بدل المشاهدات المفقودة :

1- حجم عينة 3000

من الجدول المرقم (1-3) نلاحظ في حالة متوسط مربعات الخطأ L_X انه في حالة فقدان البيانات بنسبة (10%) 40%, 30%, 20% افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي SOM تليها طريقة تحليل المركبات الرئيسية PCA عند التباين (1,2,3).

اما في حالة متوسط مربعات الخطأ L_Y نلاحظ ايضاً انه في حالة فقدان البيانات بنسبة (10%) 20%, 30% افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي SOM تليها طريقة تحليل المركبات الرئيسية PCA عند التباين (1,2,3).

اما عند النسبة (30%) افضل طريقة هي طريقة خرائط التنظيم الذاتي SOM تليها طريقة تحليل المركبات الرئيسية PCA عند التباين (1,2) اما عند التباين (3) فان افضل طريقة هي طريقة تحليل المركبات الرئيسية PCA تليها طريقة خرائط التنظيم الذاتي SOM.

اما عند النسبة (40%) افضل طريقة هي طريقة خرائط التنظيم الذاتي SOM تليها طريقة تحليل المركبات الرئيسية PCA عند التباين (1,3) اما عند التباين (2) فان افضل طريقة هي طريقة تحليل المركبات الرئيسية PCA تليها طريقة خرائط التنظيم الذاتي SOM.

2- حجم عينة 4000

من نتائج الجدول المرقم (2-3) في حالة متوسط مربعات الخطأ L_X نلاحظ انه في حالة فقدان البيانات بنسبة (10%) 40%, 30%, 20% افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي SOM تليها طريقة تحليل المركبات الرئيسية PCA عند التباين (1,2,3).

اما في حالة متوسط مربعات الخطأ L_Y نلاحظ انه في حالة فقدان البيانات بنسبة (20%) 40%, 30% افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي SOM تليها طريقة تحليل المركبات الرئيسية PCA عند التباين (1,2,3).

اما عند النسبة (20%) فان افضل طريقة عند التباين (1) طريقة تحليل المركبات الرئيسية PCA ومن ثم هي طريقة خرائط التنظيم الذاتي SOM ، اما عند التباين (2,3) فان افضل طريقة هي طريقة خرائط التنظيم الذاتي SOM تليها طريقة تحليل المركبات الرئيسية PCA.

اما عند النسبة (40%) فان افضل طريقة في حالة التباين (1,3) هي طريقة خرائط التنظيم الذاتي SOM ومن ثم طريقة تحليل المركبات الرئيسية PCA ، اما في حالة التباين (2) فان افضل طريقة هي طريقة تحليل المركبات الرئيسية PCA تليها طريقة خرائط التنظيم الذاتي SOM.

3- حجم عينة 5000

من نتائج الجدول المرقم (3-3) في حالة متوسط مربعات الخطأ L_X نلاحظ انه في حالة فقدان البيانات بنسبة (10%) 40%, 30%, 20% ان افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي SOM ومن ثم طريقة تحليل المركبات الرئيسية PCA عند التباين (1,2,3).



**معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA]
و خرائط التنظيم الذاتي [SOM]**

اما في حالة متوسط مربعات الخطأ \bar{Y} نلاحظ انه في حالة فقدان البيانات بنسبة (10%) ان افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي SOM ومن ثم طريقة تحليل المركبات الرئيسية PCA عند التباين (1,2,3).

اما عند النسبة 20% اظهرت النتائج ان افضل طريقة لمعالجة القيم هي طريقة خرائط التنظيم الذاتي SOM ومن ثم طريقة تحليل المركبات الرئيسية PCA عند التباين (1)، اما عند التباين (3,2) فان افضل طريقة هي طريقة خرائط التنظيم الذاتي SOM ومن ثم طريقة تحليل المركبات الرئيسية PCA.

اما عند النسبة (40%) اظهرت النتائج ان افضل طريقة هي طريقة خرائط التنظيم الذاتي SOM ومن ثم طريقة تحليل المركبات الرئيسية PCA عند التباين (1,3)، اما عند التباين (2) فان افضل طريقة هي طريقة تحليل المركبات الرئيسية PCA تليها طريقة خرائط التنظيم الذاتي SOM.

الجدول رقم (1) يبين النتائج في حالة حجم العينة (n = 3000)

Sigma = 3		Sigma = 2		Sigma = 1		الفقدان	المعيار
SOM	PCA	SOM	PCA	SOM	PCA		
21.24477	26.58473	21.09917	26.36360	21.24401	26.38033	0.1	RMSEX
28.16595	28.16641	21.88156	21.88246	19.88270	19.88280		RMSEY
2.36730	2.36715	2.35502	2.35586	2.35080	2.35083		Bo
-0.00456	-0.00474	0.00301	0.00306	0.00084	0.00082		B1
0.00169	0.00190	-0.00008	-0.00066	0.00014	0.00013		B2
29.79074	35.76747	30.01972	36.09015	30.13491	35.75867		RMSEX
27.67983	27.68110	21.66396	21.66519	20.06740	20.06834	0.2	RMSEY
2.39569	2.39340	2.40591	2.40600	2.34318	2.34384		Bo
0.00194	0.00201	0.00263	0.00286	0.00107	0.00109		B1
-0.00151	-0.00008	-0.00088	-0.00112	0.00014	-0.00028		B2
36.71944	42.66059	36.76631	42.35509	36.73772	42.30932	0.3	RMSEX
27.68745	27.68696	21.82236	21.82245	20.37860	20.37903		RMSEY
2.41812	2.41663	2.40888	2.40805	2.35616	2.35590		Bo
-0.00328	-0.00287	-0.00476	-0.00490	0.00082	0.00116		B1
-0.00226	-0.00152	0.00008	0.00069	-0.00124	-0.00130		B2
42.38401	47.16254	42.53275	46.86629	42.38895	47.04983	0.4	RMSEX
28.14414	28.14417	21.57942	21.57918	20.01201	20.01242		RMSEY
2.39970	2.39927	2.41302	2.41196	2.36721	2.36736		Bo
0.00067	0.00009	0.00287	0.00196	-0.00067	-0.00045		B1
0.00054	0.00133	0.00094	0.00233	-0.00038	-0.00063		B2



**[PCA] معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية
[SOM] و خرائط التنظيم الذاتي**

الجدول رقم(2-3) بين النتائج في حالة حجم العينة (n = 4000)

Sigma = 3		Sigma = 2		Sigma = 1		الفقدان	المعيار
SOM	PCA	SOM	PCA	SOM	PCA		
24.57884	30.69848	24.52659	30.59508	24.49072	30.36183	0.1	RMSEX
32.00823	32.00837	25.11177	25.11215	22.96421	22.96430		RMSEY
2.40522	2.40574	2.40821	2.40858	2.36458	2.36458		Bo
0.00597	0.00582	-0.00047	-0.00048	-0.00309	-0.00314		B1
0.00128	0.00107	0.00021	-0.00001	0.00054	0.00056		B2
34.57605	41.38934	34.73819	41.28692	34.66773	41.48269	0.2	RMSEX
31.93115	31.93130	25.08366	25.08367	22.88088	22.88030		RMSEY
2.40034	2.40071	2.39065	2.39024	2.36451	2.36331		Bo
0.00024	-0.00018	0.00361	0.00392	0.00028	0.00038		B1
0.00190	0.00196	-0.00149	-0.00144	-0.00122	-0.00050		B2
42.43562	48.97716	42.35003	48.92284	42.55899	48.74211	0.3	RMSEX
32.05088	32.05202	25.33456	25.33508	23.15350	23.15358		RMSEY
2.42730	2.42791	2.39841	2.40027	2.35741	2.35814		Bo
-0.00286	-0.00304	0.00034	0.00009	0.00110	0.00111		B1
0.00076	0.00051	0.00195	0.00088	0.00047	-0.00002		B2
48.83821	54.54682	49.08363	54.47800	48.84881	54.37116	0.4	RMSEX
32.61679	32.61734	25.08913	25.08839	22.84751	22.84795		RMSEY
2.41983	2.42074	2.40121	2.40213	2.36341	2.36289		Bo
-0.00010	-0.00076	-0.00178	-0.00192	0.00016	0.00090		B1
0.00174	0.00164	0.00082	0.00032	-0.00159	-0.00183		B2

الجدول رقم (3-3) بين النتائج في حالة حجم العينة (n = 5000)

Sigma = 3		Sigma = 2		Sigma = 1		الفقدان	المعيار
SOM	PCA	SOM	PCA	SOM	PCA		
27.29256	34.26899	27.42381	33.87566	27.40306	34.20887	0.1	RMSEX
36.16747	36.16795	27.83088	27.83088	25.71035	25.71012		RMSEY
2.41382	2.41235	2.40860	2.40900	2.36273	2.36159		Bo
0.00185	0.00200	0.00207	0.00212	-0.00328	-0.00330		B1
-0.00232	-0.00144	-0.00023	-0.00052	-0.00048	0.00029		B2
38.73983	46.32366	38.60847	46.48456	38.66675	46.28463	0.2	RMSEX
35.89933	35.89943	28.09282	28.09294	25.95932	25.95980		RMSEY
2.41071	2.41158	2.41829	2.42015	2.36797	2.36794		Bo
-0.00223	-0.00212	-0.00113	-0.00106	-0.00257	-0.00264		B1
0.00001	-0.00063	0.00102	-0.00027	0.00026	0.00034		B2
47.29509	54.41269	47.42364	54.44474	47.43532	54.55176	0.3	RMSEX
36.08338	36.08542	27.66990	27.67030	25.66001	25.66034		RMSEY
2.40946	2.40794	2.40478	2.40413	2.36982	2.37012		Bo
-0.00060	-0.00022	-0.00074	-0.00098	-0.00276	-0.00322		B1
-0.00181	-0.00112	0.00012	0.00074	0.00132	0.00148		B2
54.66361	61.07873	54.71910	60.82617	54.77897	60.57682	0.4	RMSEX
36.42409	36.42350	28.41217	28.41302	26.30715	26.30779		RMSEY
2.40234	2.40239	2.40462	2.40652	2.35767	2.35682		Bo
0.00162	0.00278	0.00079	0.00042	0.00306	0.00327		B1
-0.00192	-0.00288	0.00197	0.00099	-0.00091	-0.00052		B2



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

المبحث الرابع / الاستنتاجات والتوصيات

4- الاستنتاجات:

بعد تنفيذ تجارب المحاكاة وما تم عرضه من النتائج والتحليل في الجانب التجريبي أستنتج الباحث ما يأتي :-

1-1-4 في حال جذر متوسط مربعات الخطأ X

1- اظهرت النتائج ان في جميع تجارب المحاكاة وعند حجم العينات (3000,4000,5000) ونسبة الفقدان (10%,20%,30%,40%) افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي تليةها طريقة تحليل المركبات الرئيسية (PCA) عند التباين (1,2,3) .

2- اظهرت النتائج ان طريقة تحليل المركبات الرئيسية (PCA) اسوأ طريقة لتقدير القيم المفقودة في نتائج المحاكاة.

1-1-4 في حالة جذر متوسط مربعات الخطأ Y

1- عند حجم عينة 3000

اظهرت نتائج المحاكاة انه في حالة فقدان البيانات بنسبة(10%,20%) افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي SOM تليةها طريقة تحليل المركبات الرئيسية PCA عند التباين (1,2,3).

اما عند النسبة(30%) افضل طريقة هي طريقة خرائط التنظيم الذاتي SOM ثم طريقة تحليل المركبات الرئيسية PCA عند التباين (1,2,1)اما عند التباين(3) فان افضل طريقة هي طريقة تحليل المركبات الرئيسية PCA وثم طريقة خرائط التنظيم الذاتي SOM .

2- عند حجم عينة 4000

اظهرت نتائج المحاكاة انه في حالة فقدان البيانات بنسبة(10%,30%) افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي تليةها طريقة تحليل المركبات الرئيسية PCA عند التباين (3,2,1). اما عند النسبة(20%) فان افضل طريقة عند التباين (1) طريقة تحليل المركبات الرئيسية PCA تليةها طريقة خرائط التنظيم الذاتي SOM ،اما عند التباين(2,3) فان افضل طريقة خرائط التنظيم الذاتي SOM تليةها طريقة تحليل المركبات الرئيسية PCA .

اما عند النسبة (40%) فان افضل طريقة في حالة التباين (1,3) هي طريقة خرائط التنظيم الذاتي SOM تليةها طريقة تحليل المركبات الرئيسية PCA ،اما في حالة التباين (2) فان افضل طريقة هي طريقة تحليل المركبات الرئيسية PCA تليةها طريقة خرائط التنظيم الذاتي SOM .

3- عند حجم عينة 5000

اظهرت نتائج المحاكاة انه في حالة فقدان البيانات بنسبة(10%,30%) (ان افضل طريقة لمعالجة القيم المفقودة هي طريقة خرائط التنظيم الذاتي SOM تليةها طريقة تحليل المركبات الرئيسية PCA عند التباين (3,2,1)).

اما عند النسبة 20% اظهرت النتائج ان افضل طريقة لمعالجة القيم المفقودة طريقة تحليل المركبات الرئيسية PCA عند التباين(1)، اما عند التباين (3,2) فان افضل طريقة هي طريقة خرائط التنظيم الذاتي SOM تليةها طريقة تحليل المركبات الرئيسية PCA .

اما عند النسبة(40%) اظهرت النتائج ان افضل طريقة هي طريقة خرائط التنظيم الذاتي SOM تليةها طريقة تحليل المركبات الرئيسية PCA عند التباين (1,3),اما عند التباين (2) فان افضل طريقة هي طريقة تحليل المركبات الرئيسية PCA تليةها طريقة خرائط التنظيم الذاتي SOM .



معالجة القيم المفقودة باستعمال طريقة تحليل المركبات الرئيسية [PCA] و خرائط التنظيم الذاتي [SOM]

2- التوصيات:

في دراسات قادمة نقترح استعمال ما يلي :-

- 1- اسلوب بيز في طريقة تحليل المركبات الرئيسية لمعالجة القيم المفقودة .
- 2- طريقة تحليل المركبات الرئيسية (PCA) لمعالجة القيم المفقودة لما تبديه من كفاءة في تقدير القيم المفقودة.
- 3- طريقة خرائط التنظيم الذاتي لمعالجة القيم المفقودة .
- 4- الخرائط المولدة الطوبوغرافية لمعالجة القيم المفقودة.

3- المصادر:

- 1- حسين، علي ناصر، 2012، "تقدير القيم المفقودة لمتغير الاستجابة في نموذج الانحدار الخطى المتعدد"، مجلة العلوم الاقتصادية، العدد 30، المجلد الثامن، قسم الاحصاء، كلية الادارة والاقتصاد، جامعة بغداد.
- 2- حمزة، سعد كاظم، 2009، مقارنة بعض الطرائق الليبية في تقدير نماذج الانحدار اللامعجمي بوجود بيانات تامة وغير تامة" ، رسالة ماجستير علوم في الاحصاء، كلية الادارة والاقتصاد، جامعة بغداد.
- 3- الرحيل، راتب صابيل الخضر والدراسة، رياض احمد صالح، "اثر طريقتي التعامل مع القيم المفقودة وطريقة تقدير القدرة على دقة تقدير معلم الفقرات والأفراد" ، المجلة الدولية المتخصصة، العدد(6)، المجلد(3)، 2014،الأردن.
- 4- عبد الرزاق، علي صلاح، 2015، "تقدير القيم المفقودة في انموذج البيانات المزدوجة مع تطبيق عملي" ، رسالة ماجستير علوم في الاحصاء، كلية الادارة والاقتصاد، جامعة بغداد.
- 5- عز الدين ، منها و حافظ، ندى محمد ، 2006 ، "دليل تكوين المؤشرات المركبة " ، الإداره العامة لجودة البيانات ، مركز المعلومات ودعم اتخاذ القرار ، مجلس الوزراء ، العراق.
- 6- العلوى، لقاء على محمد، 2003، "مقارنة مقدرات التباين المشترك الحصينة في تحليل المركبات الرئيسية" ، اطروحة دكتورا فسفقة في الاحصاء، كلية الادارة والاقتصاد، جامعة بغداد.
- 7 - كشمر، ختام سوادي، 2005 ، "الطرق المختلفة لتقدير القيم المفقودة لأغراض احتساب الرقم القياسي لأسعار المستهلك" ، بحث دبلوم في الاحصاء، كلية الادارة والاقتصاد ، جامعة بغداد .

8 - Tapani Raiko,D.Sc. (Tech.) and Krista Laugus .D.Sc.(Tech.),2012,"Missing Value Imputation using SubSpace Methods With Application on Survey Data",Masters Thesis ,Department of information and computer science , school of science, alto university.



Processing of missing values in survey data using Principal Component Analysis and probabilistic Principal Component Analysis methods

Abstract:

The idea of carrying out research on incomplete data came from the circumstances of our dear country and the horrors of war, which resulted in the missing of many important data and in all aspects of economic, natural, health, scientific life, etc.,. The reasons for the missing are different, including what is outside the will of the concerned or be the will of the concerned, which is planned for that because of the cost or risk or because of the lack of possibilities for inspection. The missing data in this study were processed using Principal Component Analysis and self-organizing map methods using simulation. The variables of child health and variables affecting children's health were taken into account: breastfeeding and maternal health. The maternal health variable contained missing value and was processed in Matlab2015a using Methods Principal Component Analysis and probabilistic Principal Component Analysis of where the missing values were processed and then the methods were compared using the root of the mean error squares. The best method to process the missing values Was the PCA method.

Key words: Missing Data Problem, Methods of estimating missing values, Principal Component Analysis, self-organizing Map.