

## توظيف اسلوب المكونات الرئيسية

### في التكهن بنماذج بوكس - جينكنز

الهام عبد الكريم حسين\*

د. ظافر رمضان مطر\*

#### المستخلص:

تم في هذا البحث توظيف اسلوب المكونات الرئيسية Principal Components لاغراض السلسل الزمنية في التكهن . لقد تم إجراء التكهن على بيانات سبق أن شخصها الباحث ( Ljung , 1999 ) اذ أمكن الحصول على تكهن ذي مواصفات إحصائية جيدة عند استخدام اسلوب المكونات الرئيسية.

### Employ the Principal Componants Manner in the Forecasting by Box – Jenkins Models

#### ABSTRACT

In this Research, we employ Principal Components manner for the forecasting in the time series , we are making the forecast to a data which are used from the researcher ( Ljung,1999). When we use the principal components,we obtain a good forecasting with a good statistcal specifics

#### المقدمة :

بعد التكهن من المسائل المهمة منذ أمد بعيد وبقي هذا الموضوع محط اهتمام الباحثين في سائر الحقول ، اذ انه يُعد حجر الأساس في تحديد وتحطيط السياسات المستقبلية ، ونظراً لأهميته فان الأساليب المستخدمة في تحسين التكهن

\* استاذ مساعد / كلية علوم الحاسوب والرياضيات

\*\* مدرس مساعد / المعهد التقني / الموصل / قسم الإحصاء والمعلوماتية

تاریخ التسلیم : 2006/ 11 /27 تاریخ القبول : 2006/ 8 /27

تطور بين الحين والأخر ، وبعد أن كان التكهن يعتمد على الطرائق التقليدية مثل : التعميم الاسي المنفرد والمضاعف Single and Double Exponantial و المتوسطات المتحركة Moving Average Smoothing نوعية في التكهن من خلال استخدام الشبكات العصبية Neural Networks والخوارزميات الجينية Genetic Algorithms . وفي هذا البحث فحص لدقة تكهن المكونات الرئيسية المستخلصة من السلسل الزمنية المتعددة وباستخدام نماذج بوكس - جينكنز Box - Jenkens .

#### **هدف البحث :**

إن هدف البحث يتمثل بالتكهن عن طريق توظيف المكونات الرئيسية المستخلصة من السلسل الزمنية المتعددة وباستخدام نماذج بوكس - جينكنز ومقارنة نتائج التكهن مع التكهن الخاص بالبيانات الأصلية وباستخدام نماذج بوكس - جينكنز ، لتشخيص مدى كفاءة توظيف أسلوب المكونات الرئيسية في التكهن .

#### **الجانب النظري :**

##### **1- المكونات الرئيسية : (PC)**

إن فكرة المكونات الرئيسية تعود إلى عام 1901 عندما اقترحها Karl - Pearson بوصفها وسيلة لحل مشكلة تعدد العلاقات الخطية أو اعتمادها طريقة استكشافية Exploration فيمكن الاستفاده منها للتوصل إلى تفسير أو فهم العلاقات المتداخلة بين المتغيرات إلا إن الموضوع لم يأخذ شكله الرياضي أو الإحصائي ألا عندما باشر Kendel بحثه عام 1957 حول هذا الموضوع (الجراح ، 2003) .

إن تحليل المكونات الرئيسية مفيد في تبسيط وصف مجموعة متغيرات على علاقة مترادفة اذ تم معاملة المتغيرات بالتساوي في تحليل المكونات الرئيسية، بعبارة أخرى لا يتم تقسيمها إلى متغيرات معتمدة ومستقلة كما في تحليل الانحدار. إن هذا الأسلوب يمكن اختصاره كطريقة لتحويل المتغيرات الأصلية

إلى متغيرات جديدة غير مرتبطة تسمى المتغيرات الجديدة بالمكونات الرئيسية Principal Components وكل مكون رئيسي هو عبارة عن توفيق خطى Linear Combination عن المتغيرات الأصلية . إن مقاييس كمية المعلومات المنقوله من خلال كل مكون رئيسي هو تباينه ، ولهذا السبب ترتيب المكونات الرئيسية بترتيب تناقص التباين ، لذلك فالملون الرئيسي الأكثر معلوماتية Most Informative هو الأول ، والأقل معلوماتية هو الأخير (إن المتغير الذي تباينه صفر لن يمكن تمييزه من بين

$$\left. \begin{array}{l} \mathbf{Pc}_1 = a_{11}\mathbf{X}_1 + a_{12}\mathbf{X}_2 \\ \mathbf{Pc}_2 = a_{21}\mathbf{X}_1 + a_{22}\mathbf{X}_2 \end{array} \right\} \quad (1)$$

عناصر(أعضاء) المجتمع (Afifi , 1984) ، ويمكن كتابة المكونات الرئيسية الأساسية  $\mathbf{Pc}_j$  لمتغيرين  $(\mathbf{X}_1, \mathbf{X}_2)$  حالة خاصة ، وكل متغير يتكون من  $N$  المشاهدات بالشكل الآتي :-

حيث أن :

- معاملات تختار بحيث تتحقق الشروط الآتية :-

- تباين  $\mathbf{Pc}_1$  اكبر ما يمكن .
- $a_{11}^2 + a_{12}^2 = a_{21}^2 + a_{22}^2 = 1$
- القيم  $\mathbf{Pc}_1, \mathbf{Pc}_2, \dots, \mathbf{Pc}_N$  غير مرتبطة
- وكحالة عامة فان :

$$\left. \begin{array}{l} \mathbf{Pc}_j = a_{1j}\mathbf{X}_1 + a_{2j}\mathbf{X}_2 + \dots + a_{pj}\mathbf{X}_p \\ \mathbf{Pc}_j = \mathbf{X}\mathbf{a}_j \end{array} \right\}, j = 1, 2, \dots, p \quad (2)$$

$a_j$  : المتجه المميز  $\mathbf{Pc}_j$  : المكون الرئيسي الذي تسلسله  $j$  . وبشكل عام يمكن كتابة المكون الرئيسي  $j$  بالتركيب الخطى الآتي :-

$$Pc_j = \sum_{k=1}^P a_{kj} X_k , \quad j = 1, 2, \dots, p \quad (3)$$

-  $a_j$  تختار بحيث تجعل تباين  $Pc_j$  اكبر ما يمكن بتحقيق الشرط التالي :-

$$a_i a_j = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases} \quad (4)$$

الجراح ، 2003 .

## 2- النماذج الحركية : Dynamical Models

يبني النظام الحركي عندما يكون لدينا مخرجات  $y_t$  التي تكون خطية بالاعتماد على القيم الحالية والسابقة لمتغير واحد أو أكثر من المتغيرات المستقلة  $(x_{1t}, x_{2t}, \dots)$  وهذا النظام يفرض إن المشاهدات للسلسل الزمنية المختلفة تحدث عند فترات زمنية فضائية متساوية equally spaced time intervals (Pankratz , 1991 ) والنظام الحركي تمثله نماذج حركية تسمى نماذج بوكس - جنكنز Box - Jenkins Models ( فاندل ، 1992 ) :

### 1- نموذج الانحدار الذاتي Autoregressive Model : AR

يرمز للنموذج بـ (AR) ، والصيغة العامة له :

$$u_t = \varphi_1 u_{t-1} + \varphi_2 u_{t-2} + \dots + \varphi_p u_{t-p} + a_t \quad (5)$$

يطلق على هذه العملية عملية انحدار ذاتي من الرتبة  $p$  ويرمز لها بالرمز

.AR( $p$ )

حيث ان :

$\varphi_1, \varphi_2, \dots, \varphi_p$  : تمثل معلمات النموذج التي تحقق شروط الاستقرارية.

$a_t$  : متغير عشوائي أو ما يسمى بالتشویش Noise نفترض انه يتوزع توزيعا

"طبيعيا" بوسط مقداره صفر وتباين  $\sigma_a^2$  .

## 2- نموذج المتوسطات المتحركة MA : Moving Average Model

يرمز للنموذج بـ (MA) ويعبر عنه رياضياً بالشكل الآتي:

$$u_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \cdots - \theta_q a_{t-q} \quad (6)$$

$\theta_1, \theta_2, \dots, \theta_q$  : معلمات نموذج المتوسطات المتحركة تكون مستقلة بعضها عن البعض الآخر ولها توزيع طبيعي بوسط حسابي صفر وتبالين  $\sigma_a^2$ . ويسمى هذه النموذج بنموذج المتوسطات المتحركة من الرتبة  $q$  ويرمز له بـ  $MA(q)$ .

## 3- نموذج الانحدار الذاتي والمتوسطات المتحركة

### Autoregressive Moving Average Model

الصيغة العامة للنموذج الذي يرمز له بالرمز ARMA(p,q)

$$u_t = a_t + (\phi_1 + \theta_1)a_{t-1} + \phi_1(\phi_1 - \theta_1)a_{t-2} + \phi_1^2(\phi_1 + \theta_1)a_{t-3} + \phi_1^3(\phi_1 + \theta_1)a_{t-4} + \cdots + \phi_1^t(\phi_1 + \theta_1)a_0 \quad (7)$$

$\theta_i, \phi_j$  : معلمات النموذج . وقد تم توظيف الطريقة التالية لإيجاد النموذج النهائي المعتمد في التكهن : (Ladalla, 2000)

$$\mathbf{X}_t \mathbf{P} = \mathbf{W}_t \quad (8)$$

حيث ان :

$\mathbf{W}_t$  : مصفوفة المكونات الرئيسية ذات بعد  $k^*k$  حيث ان :  $k = 1, 2, \dots$

$\mathbf{X}_t$  : مصفوفة لمتغيرات عشوائية ذات بعد  $k^*k$  وان  $k = 1, 2, \dots$

$\mathbf{P}$  : مصفوفة المتجهات المميزة . Matrix of eigen Vectors

ومن المعادلة (8) يمكن الحصول على البيانات الأصلية  $X_t$  :

$$\mathbf{X}_t = \mathbf{W}_t \mathbf{P}^T \quad (9)$$

حيث ان :

.  $\mathbf{P}^T$  : مبدلة المصفوفة  $\mathbf{P}$ ,  
ولغرض التبسيط ، نفترض انه لدينا النموذج الاتي :

$$W_{j,t} = \varphi_{jt} W_{j,t-1} + a_{j,t} \quad j = 1, 2, \dots, k \quad (10)$$

حيث ان :

$W_{j,t}$  : تتبع نموذجاً حركيًّا معيناً .

: معلمة النموذج الحركي المحدد .  $\varphi_{jt}$

$a_{j,t}$  : الخطأ العشوائي نفترض انه يتوزع توزيعاً "طبيعياً" بوسط حسابي صفر و بتباين مقداره  $\sigma_j^2$  .

ومن المعادلة (8) و (10) نحصل على :

$$\mathbf{X}_t = \varphi_1 \mathbf{X}_{t-1} + \mathbf{a}_t \quad (11)$$

حيث ان :

$\varphi_1$  : تمثل معلمة النموذج وهي على شكل مصفوفة تمثل بالمعادلة الآتية :

$$\varphi_1 = \mathbf{p} \lambda_i \mathbf{p}^T \quad (12)$$

وان :

$$\lambda = \text{diag}\{\varphi_{1,1}, \varphi_{2,1}, \dots, \varphi_{k,1}\} \quad (13)$$

وان :

$$\begin{aligned} a_t &\sim N(0, \Sigma), \\ \Sigma &= \mathbf{p} \mathbf{D} \mathbf{p}^T \\ \mathbf{D} &= \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_k^2) \end{aligned} \quad (14)$$

وبمعرفة النموذج الذي تتبعه السلسلة يمكن التكهن بفترات قادمة ومعرفة مدى كفاءته بالاعتماد على مؤشرات إحصائية يحددها الباحث .

### الجانب التطبيقي :

في هذا الجانب أُستخدمت بيانات مجفف الشعر (Ljung , 1999) والية العمل في هذا المجفف، هي تدوير الهواء خلال أنبوبة ، بحيث يسخن في الداخل وتقاس درجة حرارة الهواء بواسطة مزدوج حراري Thermocouple عند مخرج الأنبوبة ، ان المدخلات في هذه العملية تمثل القدرة على جهاز التسخين التي هي عبارة عن شبكة أسلاك مقاومة Resistor Wires مماثلة ببنقاط الفولتيّة المطبقة على السخان والتي تتولد كمتسلسلة عشوائيّة ثنائية تتخلّى من مستوى واحد الى آخر باحتمال 0.2 ويرمز لها بالرمز  $x$  أما المخرجات فتمثل قياساً لدرجة حرارة بخار الهواء عند مخرج الأنبوبة وتنتمي المعاينة خلال فترة 0.08 ثانية ويرمز لها بالرمز  $y$  ( حياوي ، 2006 ) ، ان حجم البيانات المعتمدة في هذا البحث هي 505 مشاهدة ، منها 500 مشاهدة استخدمت لبناء النموذج ، و 5 مشاهدات استخدمت لمقارنتها مع قيم التكهّن التي تم التوصل اليها حسب الطريقة المذكورة أعلاه.

وباعتماد الطريقة المذكورة انفاً في التكهّن وُجد بأنَّ :

1- بعد ايجاد المكونات الرئيسيّة للمتغيرين  $y, x$  وُجد ان سلسلة المكون الرئيسي الاول  $u_t$  تتبع نموذج (1) AR(1) وحسب المعادلة الآتية اعتماداً على اليات اسلوب بوكس - جنكز :

$$u_t = -1.9122 + 0.563 u_{t-1} + a_t \quad (15)$$

$$a_t \sim N(0, 1.307)$$

2- النموذج المناسب للسلسلة  $v_t$  أي المكون الرئيسي الثاني هو AR(5) :

$$v_t = 0.260 + 1.343 v_{t-1} - 0.037 v_{t-2} - 0.440 v_{t-3} - 0.169 v_{t-4} + 0.242 v_{t-5} + b \quad (16)$$

$$b_t \sim N(0, 0.0391)$$

وان معلمات النموذج  $\varphi_i$  تحقق الشرط الآتي :

5

$$\sum_{i=1}^5 \varphi_i < 1 \quad (17)$$

4- عند تحديد النموذج المناسب لكل مكون رئيسي على حدة فانه يمكن إعادة كتابة نموذج متعدد متغيرات بالشكل الآتي :

$$\mathbf{W}_t = \gamma + \lambda_1 \mathbf{W}_{t-1} - \lambda_2 \mathbf{W}_{t-2} - \lambda_3 \mathbf{W}_{t-3} - \lambda_4 \mathbf{W}_{t-4} - \lambda_5 \mathbf{W}_{t-5} + \mathbf{a}_t \quad (18)$$

حيث ان :

$\gamma$  : تمثل مصفوفة الثوابت وهي :

$$\gamma^T = (\gamma_1 \ \gamma_2)^T = (-1.9122 \quad 0.260)^T \quad (19)$$

$$\lambda = \begin{pmatrix} \lambda_1 & 0 & 0 & 0 & 0 \\ 0 & \lambda_2 & 0 & 0 & 0 \\ 0 & 0 & \lambda_3 & 0 & 0 \\ 0 & 0 & 0 & \lambda_4 & 0 \\ 0 & 0 & 0 & 0 & \lambda_5 \end{pmatrix} \quad (20)$$

$\lambda$  : مصفوفة قطرية تمثل معلمات النموذج للمكونات الرئيسية وهي :

$$\lambda_1 = \text{diag}(0.563 \quad 1.343)$$

$$\lambda_2 = \text{diag}(0 \quad 0.037)$$

$$\lambda_3 = \text{diag}(0 \quad 0.44)$$

$$\lambda_4 = \text{diag}(0 \quad 0.169)$$

$$\lambda_5 = \text{diag}(0 \quad 0.242)$$

$$\mathbf{a}_t \sim N(\mathbf{0} \quad \Sigma)$$

حيث ان :

$$\Sigma = \mathbf{pDp}^T \quad (21)$$

$$\mathbf{D} = \text{diag}(\sigma_1^2 \quad \sigma_2^2) \\ = \text{diag}(1.307 \quad 0.0391)$$

ويمكن كتابة النموذج النهائي من خلال المتغيرات الأصلية بالشكل الاتي :

$$X_t = \delta + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \varphi_3 X_{t-3} + \varphi_4 X_{t-4} + \varphi_5 X_{t-5} + a_t \quad (22)$$

وحيث ان :

$$P = \begin{pmatrix} -0.9935 & -0.1143 \\ -0.1143 & 0.9935 \end{pmatrix} \quad (23)$$

عليه يمكن الحصول على  $\varphi_i$  بالاعتماد على  $P$  حسب المعادلة (12) وكما ياتي :

$$\varphi_1 = P \lambda_1 P^T = \begin{pmatrix} 0.6620 & -0.0783 \\ & 1.3340 \end{pmatrix}, \quad \varphi_2 = P \lambda_2 P^T = \begin{pmatrix} 0.0004 & -0.0034 \\ & 0.0296 \end{pmatrix}$$

$$\varphi_3 = P \lambda_3 P^T = \begin{pmatrix} 0.0057 & -0.0499 \\ 0.4343 & \end{pmatrix}, \quad \varphi_4 = P \lambda_4 P^T = \begin{pmatrix} 0.002 & -0.0192 \\ & 0.1668 \end{pmatrix}$$

$$\varphi_5 = P \lambda_5 P^T = \begin{pmatrix} 0.0032 & -0.0275 \\ 0.2388 & \end{pmatrix}$$

ومن المعادلة (14) نحصل على  $\Sigma$  كالتالي :

$$\Sigma = \begin{pmatrix} 1.290 & 0.1439 \\ 0.1439 & 0.0557 \end{pmatrix}$$

ومن المعادلة التالية نحصل على  $\delta$  كالتالي :

$$\delta = \mathbf{P} \gamma^T = \begin{pmatrix} 1.8698 \\ 0.4767 \end{pmatrix}$$

$$\begin{aligned} \mathbf{X}_t = & \begin{bmatrix} 1.8698 \\ 0.4767 \end{bmatrix} + \begin{bmatrix} 0.6620 & -0.0783 \\ 1.3340 & \end{bmatrix} \mathbf{X}_{t-1} + \begin{bmatrix} 0.0004 & -0.0034 \\ 0.0296 & \end{bmatrix} \mathbf{X}_{t-2} \\ & + \begin{bmatrix} 0.0057 & -0.0499 \\ 0.4343 & \end{bmatrix} \mathbf{X}_{t-3} + \begin{bmatrix} 0.002 & -0.0192 \\ 0.1668 & \end{bmatrix} \mathbf{X}_{t-4} + \begin{bmatrix} 0.0032 & -0.0275 \\ 0.2388 & \end{bmatrix} \\ & \mathbf{X}_{t-5} + \begin{bmatrix} \mathbf{a}_t \\ \mathbf{b}_t \end{bmatrix} \end{aligned} \quad (24)$$

ما سبق يصبح النموذج النهائي بالشكل الآتي :

ان النموذج أعلاه يمثل نموذج متعدد متغيرات حركي Multivariate Dynamical Model. بعد تحويل البيانات الاصلية الى المكونات الرئيسية حسب الطريقة المذكورة انفاً ومن خلال دالة الارتباط الذاتي Autocorrelation Function ودالة الارتباط الجزئي Partial Autocorrelation Function وُجد ان السلسلة تتبع نموذج AR(5) ومن هذا النموذج يمكن التكهن لخمس فترات قادمة للمكونات الرئيسية بالنسبة للمخرجات التي تمثل المكون الرئيسي الثاني  $v_t$  كالاتي مع حدود الثقة العليا والدنيا بمستوى ثقة 95% :

الجدول (1) : نتائج التكهن للمكون الرئيسي الثاني v

period	forecast	lower	upper	actual
501	5.1268	4.7391	5.5146	5.2672
502	4.8749	4.2255	5.5244	4.7262
503	4.7145	3.7702	5.6588	4.4229
504	4.5777	3.3837	5.7717	4.1221
505	4.4953	3.1306	5.86	3.8504

وبالاعتماد على المعادلة (9) ومن خلال والتي الارتباط الذاتي والارتباط الجزئي وُجِد ان السلسلة الأصلية تتبع نموذج AR(3) ومنه يمكن الحصول على نتائج التكهن لقيم الأصلية بالنسبة لـ  $y$  :

الجدول (2) : نتائج التكهن لقيم الأصلية لـ  $y$ 

period	forecast	lower	upper	actual
501	5.51	5.31	5.71	5.48
502	5.35	4.88	5.81	5.14
503	5.22	4.48	5.96	4.84
504	5.13	4.14	6.12	4.54
505	5.07	3.88	6.26	4.26

الاستنتاجات :

1- من ملاحظة نتائج التكهن في الجدول (1) وبالاعتماد على المكونات الرئيسية ، ان التكهن كان جيداً ولاسيما في الفترات الأولى من حيث الاقتراب الكبير لقيم التكهن من القيم الأصلية، وبنفس الوقت تتحقق الشروط الإحصائية أي ضمن حدود الثقة .

2- كذلك من ملاحظة نتائج التكهن في الجدول (2) وبالاعتماد على القيم الأصلية ، ان التكهن كان جيداً ولاسيما لأول فترتين زمنيتين، وبنفس الوقت تتحقق الشروط الإحصائية لجودة التكهن .

3- نستنتج مما ذكر في النقطتين أعلاه ان أسلوب المكونات الرئيسية قدم إمكانية جيدة في التكهن ومن ثم يمكن الاعتماد عليه في هذا المجال .

**الوصيات :**

"بناء" على النتائج التي حصلنا عليها يمكن ان نوصي بمحاولة تقدير نموذج دالة التحويل Transfer Function Model عن طريق تطبيق اسلوب المكونات الرئيسية التي بينت انها تختصر الكثير من المعالجات والمشاكل التي يمكن ان يواجهها الباحث في التحليل الإحصائي والتي تتطلب الكثير من الوقت والجهد .

**المصادر :**

- 1- الجراح ، ريم علي (2003) : "تحليل المكونات الاساسية باستخدام الشبكات العصبية الاصطناعية مع تطبيق " ، اطروحة دكتوراه غير منشورة ، كلية علوم الحاسوب والرياضيات ، جامعة الموصل .
- 2- حياوي ، هيام عبد المجيد ، (2006) : " تشخيص النظم الحركية الخطية التصادفية من خلال علاقتها مع الزمن " ، اطروحة دكتوراه غير منشورة ، كلية علوم الحاسوب والرياضيات ، جامعة الموصل .
- 3- فاندل ، والتر (1992) : " السلسل الزمنية من الوجهة التطبيقية ونماذج بوكس - جنكنز " ، ترجمة عبد المرضي حامد عزام ، دار المريخ للنشر ، الرياض ، المملكة العربية السعودية .
- 4- Afifi, A. A and Clart Virginia (1984). "Computer – Aided Multivariate Analysis " .
- 5- Ladalla, N., Josef (2000). "Multivariate Time Series Analaysis in Principal Components Space", The 32<sup>nd</sup> Symposium on interface: computing science and statistic, New Orleans, Louisiana .
- 6- Ljung , L. (1999). "System Identification – Theory for the User " , 2<sup>nd</sup> . ed. , Prentic Hall , Upper Saddle River , N.J.London , UK .
- 7- Pankratz , Alan , (1991). "Forecasting with Dynamic Regression Models " , Depaw University , Greencastle , Indiana .