

## المحور السادس: عموميات حول السلاسل الزمنية وتقدير مركباتها

### 1.1 ماهية السلاسل الزمنية:

في أدبيات الإحصاء يمكن التعرف على ثلاثة أنواع مختلفة من البيانات، هي: البيانات التجريبية وبيانات الحصر (المسح) والبيانات الزمنية. وتعتمد الفلسفة الخاصة بالبيانات التجريبية على الأسلوب التجريبي والذي يبدأ بتحديد العوامل الهامة والتي يعتقد الباحث أن لها تأثير معنوي على الظاهرة أو المتغير موضع الدراسة، ثم يتم الحصول على البيانات من خلال تصميم تجربة تعتمد على مبدأ العشوائية تسمح بقياس تأثير أحد أو بعض هذه العوامل على الظاهرة أو المتغير موضع الدراسة في ظل ثبات العوامل الأخرى. وتعتمد الفلسفة الخاصة ببيانات الحصر أو المسح على مبدأ الحصول على البيانات عن طريق حصر أو مسح الوضع القائم للظواهر موضع الدراسة كما هو دون محاولة التحكم في العوامل المختلفة التي قد تؤدي إلى الحالة التي توجد عليها هذه الظواهر. أما البيانات الزمنية فيتم الحصول عليها من خلال رصد البيانات أو القيم التي تعبر عن الظاهرة أو المتغير موضع الدراسة على فترات زمنية متتالية بهدف تحقيق عدة أهداف أهمها اكتشاف نمط التطور التاريخي للظاهرة أو المتغير موضع الدراسة، وكيفية الاستفادة من هذا النمط في التنبؤ بهذه الظاهرة في المستقبل. ويطلق على البيانات الزمنية "السلاسل الزمنية" وهي الموضوع الرئيسي لهذا الكتاب.

**تعريف:** السلسلة الزمنية هي مجموعة من المشاهدات أو القياسات التي تؤخذ على إحدى الظواهر الاقتصادية - الاجتماعية - الطبية - الطبيعية - ..... على فترات زمنية متتابعة عادة ما تكون متساوية الطول.

ويمكن رصد السلاسل الزمنية في شتى أنواع المعرفة وميادين التطبيق المختلفة. ففي الاقتصاد يمكن رصد بيانات الدخل السنوي وقيمة التحويلات الخارجية السنوية والإيداعات ربع السنوية في أحد البنوك وعدد العاطلين الشهري وغيرها من البيانات. وفي علم الاجتماع يمكن رصد عدد الجرائم الأسبوعي وعدد حالات الطلاق أو الزواج السنوي وغيرها. وفي مجال التعليم يمكن رصد السلاسل الزمنية الخاصة بتطور أعداد الطلبة السنوي في مراحل التعليم المختلفة وأعداد المدارس والمدرسين السنوية في الكليات المختلفة. وفي مجال الطب يمكن رصد السلاسل الزمنية الخاصة بتطور الأمراض المختلفة ومدى التزايد أو التناقص في الإصابة بهذه الأمراض مثل التطور التاريخي لنسبة المصابين بالذبحة الصدرية أو الأورام الخبيثة، كما يمكن رصد السلاسل الزمنية الخاصة برسم القلب أو الدماغ. وفي مجال الأرصاد الجوية يمكن رصد السلاسل الزمنية الخاصة بكمية الأمطار الشهرية والسلاسل الزمنية الخاصة بسرعة الرياح ونسبة الرطوبة ودرجات الحرارة وغيرها. وفي مجال البيئة يمكن رصد السلاسل الزمنية الخاصة بتطور نسب التلوث في

الأجواء المحيطة وتطور متوسط الحموضة في مياه الأمطار السنوية ونسب الأوكسوجين المذاب في المياه كمقياس لتلوث المياه. وفي مجال الزراعة يمكن رصد السلاسل الخاصة بتطور الإنتاج السنوي من المحاصيل الزراعية والدخل السنوي الناتج من قطاع الزراعة. وفي مجال الكيمياء يمكن رصد درجة الحرارة التي تؤخذ كل دقيقة من عملية كيميائية معينة، وفي مجال الهندسة يمكن رصد تطور نسب الوحدات المعيبة الشهرية وتطور إنتاجية العامل السنوية في أحد المصانع.

وتختلف السلسلة الزمنية عن البيانات التجريبية وبيانات الحصر في ثلاث نقاط أساسية هي:

1. تؤخذ بيانات السلسلة الزمنية على فترة زمنية طويلة نسبياً يعتقد أنها تؤثر على الظاهرة أو المتغير موضع الدراسة، بينما تؤخذ البيانات التجريبية أو بيانات الحصر (المسح) عند نقطة زمنية معينة أو على الأكثر في فترة زمنية قصيرة يعتقد أنها لا تؤثر بشكل معنوي على الظاهرة أو المتغير موضع الدراسة. وعادة ما تسم هذه البيانات بالبيانات المتقاطعة cross sectional data

2. يتم دراسة السلسلة الزمنية عادة بمعزل عن العوامل الأخرى - بخلاف الزمن - التي قد تؤثر عليها وعن الظواهر الأخرى التي قد ترتبط معها في علاقة إحصائية.

3. عادة ما تكون بيانات أو مشاهدات السلسلة الزمنية مرتبطة ببعضها البعض، ويأخذ الارتباط بين هذه المشاهدات أشكالاً وأنماطاً عديدة تختلف باختلاف طبيعة الظاهرة، ومن ثم فإن ترتيب المشاهدات في السلاسل الزمنية ذو أهمية خاصة، ولذلك فإن معظم الأساليب التي تستخدم في تحليل البيانات التجريبية أو بيانات الحصر لا تكون صالحة لتحليل السلاسل الزمنية، وبالتالي كان لا بد من ابتكار وتطوير أدوات وأساليب خاصة لتحليل السلاسل الزمنية.

وقد خصص الإحصاء مجالاً منفرداً لتحليل البيانات الزمنية يعرف بمجال لسلاسل الزمنية والذي تطور تطوراً هائلاً في العقود الثلاثة الأخيرة من القرن العشرين بسبب المنهجية الحديثة التي قدمها العالمان بوكس G.E.Box جينكنز Jenkins ... في سنة 1976 والتي يمكن اعتبارها بحق البداية الحقيقية لتحليل الحديث للسلاسل الزمنية والسبب الحقيقي وراء الففقات العلمية الهائلة التي حدثت في هذا المجال. وللمزيد من التفاصيل حول أنواع البيانات الإحصائية والفروق الأساسية بينهم يمكن للقارئ الرجوع إلى شعراوي وإسماعيل (2002).

وتعرض السلسلة الزمنية عادة في صورة جدول أو خط أو منحنى بياني يعرف الخط التاريخي أو المنحنى الزمني time series plot كما في الأمثلة الآتية:

مثال (1): يوضح الجدول الآتي حجم الإنتاج السنوي للبتروك بالميون متر مكعب في إحدى الدول من

سنة 1990 إلى سنة 1997:

السنة	1990	1991	1992	1993	1994	1995	1996	1997
حجم الإنتاج	5210	5820	5655	7800	8100	8010	9200	9335

ويمكن عرض هذه البيانات في شكل خط بياني (تاريخي) في شكل (1):

**شكل (1):** الخط البياني (التاريخي) لبيانات المثل (1)

**مثال (2):** يوضح الجدول الآتي تطور قيمة الإيداعات ربع السنوية بالمليون دولار في أحد البنوك في

سنتي 1998 و 1999:

السنة	الموسم (الفصل)	الإيداعات
1998	1	42
	2	46
	3	50
	4	56
1999	1	45
	2	49
	3	54
	4	60

ويمكن عرض هذه البيانات في شكل (2)

**شكل (2):** العرض البياني لبيانات المثل (2)

## 1.2 أنواع السلاسل الزمنية:

عند دراسة السلاسل الزمنية لبعض الظواهر قد يكون من الممكن أخذ قياسات أو قراءات عند كل لحظة زمنية ويقال لهذه السلاسل بأنها سلاسل متصلة continuous، ومن أمثلة هذه السلاسل درجات الحرارة ورسم القلب ورسم الدماغ. أما معظم السلاسل الزمنية التي تنشأ في الواقع فتتكون من قراءات أو مشاهدات مأخوذة عند فترات زمنية محددة مسبقاً. وقد تكون هذه الفترات دقائق أو ساعات أو أيام أو أسابيع أو شهور أو سنوات. وتعرف هذه السلاسل بالسلاسل المتقطعة discrete time series بغض النظر عن طبيعة الظاهرة أو المتغير موضع الدراسة، أمثلة هذه السلاسل الدخل القومي السنوي وسعر الإقفال اليومي لأحد الأسهم في بورصة الأوراق المالية وعدد الحوادث الأسبوعية التي تحدث على أحد الطرق وعدد خريجي إحدى الكليات السنوي وكمية الأمطار الشهرية والسلاسل الزمنية المتقطعة السلاسل التي سنتعامل معها فقط في هذا الكتاب، أي أننا سنفترض دائماً أن السلسلة متاحة فقط عند نقاط زمنية متقطعة تبعد عن بعضها فجوات زمنية متساوية الطول.

وفي الواقع يمكن الحصول على السلسلة الزمنية المتقطعة بمعاينة سلسلة زمنية متصلة وذلك بأن يتم رصد أو تسجيل القراءات فقط عند نقاط زمنية محدّدة متساوية الأبعاد، كما يمكن الحصول على السلسلة

الزمنية المتقطعة بتراكم متغير معين خلال فترة زمنية مثل كمية الأمطار التي عادة ما تتراكم خلال يوم أو شهر مثلاً أو الناتج السنوي من أحد المحاصيل الزراعية والاهتمام الأساسي لهذا الكتاب هو كيفية بناء النماذج للسلاسل الزمنية المتقطعة واستخدام هذه النماذج في التنبؤ بالمشاهدات المستقبلية.

### 1.3 أهداف دراسة السلاسل الزمنية:

تدرس السلاسل الزمنية عادة لتحقيق عدد من الأهداف. وقد يكون أول أهداف هذه الدراسة هو استخدام السلسلة الزمنية لوصف وتصوير المعلومات المتاحة عن فترة زمنية توضح تطور الظاهرة المدروسة أي وصف الملامح والسمات الرئيسية للسلسلة. ويساعد وصف السلسلة إلى حد كبير في تحديد النموذج الذي يمكن أن يكون مناسباً لتحقيق الأهداف الأخرى والتعرف على حركات الصعود والهبوط في السلسلة الزمنية والتعرف على المكونات الرئيسية مثل الاتجاه العام والتغيرات الموسمية كما سنرى في نهاية هذا الباب. أما الهدف الثاني من دراسة السلاسل الزمنية فهو التفسير، ويقصد به توضيح وشرح التغيرات التي تحدث في الظاهرة باستخدام السلاسل الزمنية الأخرى التي ترتبط بها أو باستخدام عوامل البيئة المحيطة بالظاهرة ومثال ذلك تفسير التغيرات التي تحدث في سلسلة المبيعات الخاصة بإحدى السلع باستخدام السلسلة الخاصة بتغيرات أسعار هذه السلعة أو بمعرفة القرارات الاقتصادية التي اتخذت وكانت لها علاقة مباشرة على التطور التاريخي للظاهرة أو تفسير التغيرات التي تحدث في سلسلة عدد الحوادث التي تحدث على طريق جدة/ مكة المكرمة بالسلسلة الزمنية لعدد الحجاج السنوي أو السلسلة الزمنية لعدد المعتمرين الشهري أو الإجراءات الأمنية التي اتخذت للحد من هذه الحوادث وربط التغيرات التي تحدث في السلسلة موضع الدراسة بالتغيرات التي تحدث في السلاسل والعوامل المحيطة من شأنه فهم آلية عمل السلسلة وتفسير الأنماط والتغيرات المنتظمة وغير المنتظمة التي تتعرض لها الظاهرة موضع الدراسة ومدى تأثير كل منها عليها. والهدف الثالث من دراسة السلاسل الزمنية هو الرقابة والتحكم، فقد تستخدم الخرائط الزمنية في مراقبة جودة الإنتاج وذلك من أجل التحكم في مستوى كفاءة العملية الإنتاجية وذلك باتخاذ القرارات المناسبة من وقف العملية الإنتاجية وتعديل مسارها أو استمرارها.

أما أهم أهداف دراسة السلاسل الزمنية على الإطلاق فهو التنبؤ بالمشاهدات المستقبلية والذي عادة ما يمثل الهدف النهائي من تحليل السلاسل الزمنية. وهذا الهدف هو أوضح الأهداف وأكثرها شعبية بالنسبة لدارس الإحصاء أو مستخدمه والذي من أجله كتبت عشرات الكتب العالمية والآلاف من الأبحاث المتخصصة. فتحليل السلاسل الزمنية يبدأ عادة بالتعرف على النمط المناسب لشرح آلية تطور هذه السلسلة واستكمال هذا النمط مستقبلاً. والفرض الأساسي في أساليب التنبؤ المستخدمة هو أن هذا النمط الذي تم التعرف عليه سيستمر في المستقبل القريب، وتجدر الإشارة إلى أنه لا يمكن لأي أسلوب تنبؤ أن يعطي

نتائج جيدة إذا لم يستمر هذا النمط، ولذلك فإنه ينصح دائماً بالتنبؤ بالقيم المستقبلية القريبة وتحديثها بمجرد الحصول على أي مشاهدة جديدة.

#### 1.4 قياس أخطاء التنبؤ:

عادة ما تدرس السلسلة الزمنية بغرض اكتشاف نمط التطور التاريخي للظاهرة واستغلال هذا النمط في التنبؤ بالقيم المستقبلية. وأي تنبؤ مستقبلي لأي ظاهرة لابد أن يحتوي على قدر معين من عدم التأكد، ويمكن ترجمة هذه الحقيقة بإدراج مركبة خطأ هي error component في نموذج التنبؤ. ومركبة الخطأ هي المركبة غير النمطية التي تعبر عن العوامل التي لا يمكن شرحها باستخدام التغيرات النمطية أو المنتظمة في السلسلة. وكلما كانت هذه المركبة صغيرة زادت قدرتنا على التنبؤ والعكس صحيح. إذا افترضنا أن قيمة

الظاهرة موضع الدراسة عند الزمن  $t$  هي  $y_1$  وأن التنبؤ بالظاهرة عند الزمن  $t$  هو  $\hat{y}_1$ ، فإن الخطأ في

$$e_1 = y_1 - \hat{y}_1 \quad ; \quad t = 1, 2, \dots, n$$

التنبؤ عند الزمن  $t$  يعرف كالتالي: حيث يرمز  $n$  إلى طول السلسلة أي عدد المشاهدات.

وفحص أخطاء التنبؤ المتتالية، يوضح مدى ملاءمة أسلوب التنبؤ المستخدم، فكما هو معروف من دراسة الانحدار أن أسلوب التنبؤ الملائم لابد أن ينتج أخطاءً تتصف بطابع العشوائية، أي أخطاء خالية من أي تغيرات منتظمة - كما في شكل (3) - بالإضافة إلى بعض الشروط الأخرى. وإذا كانت هذه الأخطاء محتملة بحيث يمكن اعتبار أسلوب التنبؤ ملائم فإنه يجب قياس حجم هذه الأخطاء لتقدير دقة التنبؤ.

#### شكل (3): أخطاء عشوائية

ولقد عرف الفكر الإحصائي طرقاً عديدة لقياس حجم الأخطاء أهمها ما يلي:

1- مجموع الأخطاء sum of errors ويرمز له عادة بالرمز SE ويعرف على الصورة الآتية:

$$SE = \sum_{t=1}^n e_1 = \sum_{t=1}^n (y_1 - \hat{y}_1)$$

وهذا المقياس لا يفيد كثيراً، حيث أنه من المعروف أنه إذا كانت الأخطاء عشوائية فإن هذا المجموع عادة ما يكون قريباً جداً من الصفر بغض النظر عن حجم هذه الأخطاء.

2- متوسط الانحرافات المطلقة mean absolute deviation والذي يرمز له عادة بالرمز MAD ويعرف

$$MAD = \frac{1}{n} \sum_{t=1}^n |e_1| = \sum_{t=1}^n |y_1 - \hat{y}_1|$$

على الصورة الآتية: وبالرغم من معقولية هذا المقياس إلا أنه لا يستخدم كثيراً في مجالات السلاسل الزمنية نظراً لصعوبة خصائصه الإحصائية.

3- متوسط مربعات الأخطاء mean squared error ويرمز له عادة بالرمز MSE ويعرف على الصورة

الآتية:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 = \frac{1}{n} \sum_{t=1}^n (y_1 - \hat{y}_1)^2$$

ويلاحظ أن طريقة المربعات الصغرى least squares method المعروفة في مجالات الانحدار والسلاسل الزمنية تعتمد على تصغير مجموع مربعات الأخطاء SSE أو تصغير متوسط مربعات الأخطاء MSE وذلك لأن المقام  $n$  والذي يمثل عدد الوحدات الزمنية المتاحة (عدد المشاهدات) هو مقدار ثابت وبصفة عامة يمكن القول بأن خصائص هذا المقياس الإحصائية أسهل كثيراً من خصائص متوسط الأخطاء المطلقة MAD

4- متوسط الأخطاء النسبية المطلقة mean absolute percentage error والذي يرمز له عادة بالرمز

MAPE ويعرف على الصورة التالية:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_1 - \hat{y}_1}{y_1} \right| = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_1}{y_1} \right|$$

ويتميز هذا المقياس عن كل المقاييس بأنه مقياس نسبي، أي لا يعتمد على الوحدات المستخدمة ولكن خصائصه الإحصائية أصعب من خصائص متوسط مربعات الأخطاء  $MSE$  ولذلك فإن هذا المقياس عادة ما يستخدم في الدراسات الوصفية التي لا تستدعي القيام باستدلالات إحصائية.

### 1.5 اختيار أسلوب التنبؤ المناسب:

من أهم عناصر تحليل السلاسل الزمنية اختيار أسلوب التنبؤ المناسب. واختيار أسلوب التنبؤ المناسب ليس بالعمل الهين وإنما هو عمل صعب وشاق ويحتاج من الإحصائي ومتخذ القرارات التحلي بالصبر وعدم اليأس بالإضافة إلى مقومات العمل الأساسية من علم وخبرة ومهارة. ويعتمد الإحصائي أو متخذ القرارات بصفة عامة في اختياره لأسلوب التنبؤ المناسب على بعض المعايير أو العوامل العامة أهمها ما يلي:

1. تصغير حجم أخطاء التنبؤ أول هذه المعايير التي يجب أن يضعها الإحصائي أو متخذ القرارات نصب عينيه عند اختياره أسلوب التنبؤ، ومن ثم نموذج التنبؤ المناسب، وعادة ما يقاس حجم هذه الأخطاء بأحد المقاييس الثلاثة التي سبق ذكرها (MAD- MSE- MAPE).
2. نوعية التنبؤ المطلوب، فإذا كان تنبؤ النقطة point forecast هو المطلوب من الدراسة، فإن استخدام أحد الأساليب أو النماذج التقليدية البسيطة قد يكون كافياً لتحقيق هذا الهدف. وفي الكثير من

الدراسات قد يكون تنبؤ الفترة forecast interval هام وكذلك اختبارات الفروض، وفي مثل هذه الحالات لابد من استخدام أسلوب تنبؤ حديث أكثر دقة وتنظيمًا مثل أسلوب بوكس وجينكز.

3. عدد المشاهدات المتاحة، فإذا كان عدد المشاهدات صغيرًا فإن استخدام أحد الأساليب الحديثة ليس له ما يبرره ويفضل استخدام أحد الأساليب التقليدية.

4. تكاليف أسلوب التنبؤ ومدى توافر البرامج الإحصائية ذات الصلة.

5. سهولة العمليات الإحصائية والحسابية الضرورية وفهم أسلوب التنبؤ المستخدم.

6. مدى تحقق الفروض النظرية التي يعتمد عليها أسلوب أو نموذج التنبؤ المناسب وهو أهم المعايير التي يجب أن تؤخذ في الاعتبار عند اختيار مثل هذا الأسلوب.

مما سبق يتضح للقارئ بأن أفضل أسلوب للتنبؤ ليس بالضرورة هو الأسلوب الذي يحقق أعلى دقة أو أصغر حجم أخطاء ممكن، فقد يستخدم أحد الأساليب بسبب نوعية التنبؤ المطلوب، وقد يستخدم أسلوب آخر بسبب صغر عدد المشاهدات المتاحة، وقد يستخدم أسلوبًا ثالثًا بسبب انخفاض تكاليفه، وقد يستخدم أسلوب رابع بسبب سهولة عملياته الإحصائية والحسابية، وقد يستخدم أسلوبًا خامسًا لأن الفروض النظرية التي يعتمد عليها تتوافق مع بيانات السلسلة المتاحة. وعادة ما يعتمد أسلوب التنبؤ المستخدم على قدرة الإحصائي أو متخذ القرارات في تحقيق التوازن لكل هذه المعايير. وبصفة عامة يمكن القول بأن طريقة التنبؤ التي يجب استخدامها هي أسهل وأبسط طريقة يمكن تنفيذها في الزمن المتاح والتي تفي باحتياجات وظروف التنبؤ بأقل تكاليف ممكنة، وللمزيد من التفاصيل حول قياس الأخطاء ومعايير التنبؤ يمكن للقارئ

الرجوع إلى (Bowerman and O'Connell (1987) أو إلى (Gaynor Kirkpatrick and (1994)

## 1.6 طرق التنبؤ:

يمكن تجميع طرق التنبؤ الكمية المعروفة في أدبيات السلاسل الزمنية في أسلوبين أساسيين هما.

أ- أسلوب الانحدار regression approach, ويعتمد هذا الأسلوب على تحديد المتغيرات الأخرى التي قد ترتبط بعلاقة سببية بالظاهرة أو المتغير موضع الدراسة الذي يراد التنبؤ به والذي عادة ما يعرف بالمتغير التابع dependent variable - ثم تحديد النموذج الإحصائي أو العلاقة الدالية الملائمة التي توضح الكيفية التي يرتبط بها هذا المتغير بالمتغيرات الأخرى والتي تأخذ في العرف الإحصائي أسماء عديدة مثل المتغيرات المستقلة independent variables أو المتغيرات المفسرة regressors أو المتغيرات المنبئة predictors. وباستخدام هذا النموذج يمكن التنبؤ بالمتغير التابع موضع الدراسة في المستقبل إذا أمكن تحديد أو معرفة القيم المستقبلية للمتغيرات المفسرة. وتعرف النماذج التي تندرج تحت مظلة هذا الأسلوب أحيانًا بالنماذج السببية causal models ويستخدم هذا الأسلوب في كافة أنواع المعرفة ومجالات التطبيق

الخاصة الاقتصادية والاجتماعية والبيئية منها حيث يسمح هذا الأسلوب بتقييم أثر المتغيرات المتضمنة والتي عادة ما تعكس أثر الأنظمة والسياسات والقرارات المختلفة، فعلى سبيل المثال قد نستطيع تفسير السلسلة الخاصة بقيمة المبيعات اليومية لإحدى السلع جزئياً بواسطة سلسلة أسعار هذه السلعة والسلاسل الخاصة بالدخل الفردي وأسعار السلع البديلة. وهذا الأسلوب بالرغم من شعبيته يعاني من بعض العيوب أهما ما يلي:

- 1- صعوبة تحديد المتغيرات المفسرة التي ترتبط بالمتغير التابع أو الظاهرة موضع الدراسة.
  - 2- تطبيق هذا الأسلوب يتطلب توافر بيانات تاريخية تفصيلية عن جميع المتغيرات المفسرة والقدرة على معرفة قيم هذه المتغيرات - أو على الأقل التنبؤ بها- عند الأزمنة التي يراد التنبؤ بالظاهرة عندها.
  - 3- يفترض عدم الارتباط بين مشاهدات المتغير أو الظاهرة موضع التنبؤ، وهو فرض غير واقعي ولا يتفق مع مفهوم السلسلة الزمنية باعتبارها مجموعة من المشاهدات المرتبطة وعادة ما يؤدي هذا الفرض غير الواقعي إلى تنبؤات غير موثوق بها.
- وعادة ما يتوافر لدى الباحث مشاهدات تاريخية عن المتغير موضع الدراسة فقط ويريد التنبؤ بالمشاهدات المستقبلية لهذا المتغير بالاعتماد فقط على هذه المشاهدات. في مثل هذه الحالات يستخدم الأسلوب الثاني للتنبؤ التالي.

ب - تحليل السلاسل الزمنية time series analysis والذي يضم تحت مظلته ما يعرف بنماذج السلاسل الزمنية، ويعتمد هذا الأسلوب على تحليل البيانات التاريخية التي أخذت عن الظاهرة أو المتغير موضع الدراسة وذلك بغرض تحديد نمط البيانات. بعد ذلك - وبافتراض أن هذا النمط سيستمر في المستقبل - يستكمل هذا النمط لإعطاء التنبؤات المطلوبة. فعلى سبيل المثال إذا كان الهدف من الدراسة التنبؤ بعدد الحجاج السنوي فقد يستطيع الباحث تفسير سلوك هذا المتغير جزئياً بواسطة عدد السكان في الدول الإسلامية ومتوسط دخل الفرد في هذه البلاد ومتوسط التكاليف المطلوبة لأداء هذه الفريضة، ولكن جزء كبير من تطور عدد الحجاج قد يعود إلى بعض العوامل الأخرى التي لا يمكن أخذها في الاعتبار بسهولة مثل الازدحام الديني وحالة الطقس وغيرها من العوامل التي يكون من الصعب أو المستحيل إدراجها في النماذج السببية بسهولة. وفي هذه الحالة قد يفضل دراسة التطور التاريخي لعدد الحجاج السنوي بمعزل عن جميع العوامل المفسرة الأخرى واكتشاف الكيفية التي يتطور بها عدد الحجاج واستخدام أحدها نماذج السلاسل الزمنية لاستكمال هذه السلسلة في المستقبل.

وأسلوب السلاسل الزمنية والذي يضم ما يعرف بنماذج أو طرق السلاسل الزمنية هو محور الاهتمام الرئيسي لهذا الكتاب، ولن نتعرض للنماذج السببية بأي حال من الأحوال. والسؤال الآن هو كيف يمكن

التنبؤ بالظاهرة أو المتغير موضع الدراسة باستخدام أسلوب السلاسل الزمنية دون اللجوء إلى أي متغيرات أخرى مفسرة؟ للإجابة عن هذا السؤال يمكن القول بأن أدبيات السلاسل الزمنية قد عرفت العديد من الطرق ونماذج السلاسل الزمنية والتي يمكن تقسيمها إلى ثلاثة أنواع رئيسية هي:

- النماذج المحددة (غير العشوائية) deterministic models
  - والطرق الحسية ad hoc methods
  - ونماذج السلاسل الزمنية العشوائية stochastic time series models
- ونقدم فيما يلي عرضاً سريعاً لهذه الطرق والنماذج.

### 1.6.1 النماذج المحددة Deterministic Models

نعرف من دراستنا في علم الإحصاء أن نموذج المتوسط mean model يمكن التعبير عنه في الصورة العامة

$$y_1 = E(y_1) + \varepsilon_1$$

حيث  $\varepsilon_1$  متغيرات عشوائية غير مرتبطة توقعها الصفر وتباينها ثابت ويقال أن هذا النموذج محدد deterministic أو غير عشوائي nonstochastic إذا أمكن التعبير عن  $E(y_1)$  كدالة رياضية مباشرة في الزمن  $t$  ولتكن  $f(t, \beta)$  حيث يرمز المتجه  $\beta$  إلى معالم هذه الدالة الرياضية. وفي هذه الحالة يمكن التعبير عن مشاهدات السلسلة الزمنية  $y_1$  على الصورة:

$$y_1 = f(t, \beta) + \varepsilon_1 ; t = 1, 2, \dots, n \quad (1.6.2)$$

ويعني هذا أن المشاهدات المستقبلية للسلسلة يمكن التعبير عنها على الصورة:

$$y_h = f(h, \beta) ; h = t + 1, t + 2, \dots$$

أي أن هذه النماذج تفترض أن المشاهدات المستقبلية للسلسلة تأخذ شكلاً رياضياً محدداً، أي غير عشوائي

وتعتمد النماذج المحددة (1.6.2) على فرضيين أساسيين. الفرض الأول أن الدالة  $f(t, \beta)$  دالة رياضية محددة ليس لها طابع العشوائية، والفرض الثاني أن  $\varepsilon_1$  متغيرات عشوائية غير مرتبطة توقعها الصفر وتباينها ثابت وتؤدي هذه الفروض إلى أن المتغيرات  $y_1, y_2, \dots, y_n$  تكون متغيرات عشوائية غير مرتبطة، ومن أمثلة الدوال الرياضية التي تستخدم في هذه النماذج كثيرات الحدود والدوال الأسية والدوال المتثلثية، وفيما يلي عرضاً مبسطاً لكثيرات الحدود والدوال الأسية.

**كثيرات الحدود Polynomials:**

ويفترض هنا أن الدالة  $f(t)$  أي متوسط الظاهرة تأخذ إحدى صور كثيرات الحدود في الزمن  $t$  وتعتبر الصورة الخطية أهم هذه الصور وتعرف على الشكل الآتي:

$$E(y)_1 = f(t) = \beta_0 + \beta_1 t$$

وتكون هذه الدالة ملائمة إذا أمكن تمثيل متوسط الظاهرة بواسطة خط مستقيم وذلك بعد توقيع مشاهدات السلسلة على ورقة الرسم البياني كما في شكل (4).

وتفترض كثيرة الحدود الخطية أن متوسط الظاهرة يتزايد بمعدل ثابت  $\beta_1$  كما في الشكل (4.a) أو يتناقص بمعدل ثابت  $\beta_1$  كما في الشكل (4.b)

ويمكن إيجاد تقديري المربعات الصغرى  $\hat{\beta}_1, \hat{\beta}_2$  لمعلمتي النموذج  $\beta_0, \beta_1$  بإجراء انحدار السلسلة  $y_1$  على الزمن  $t$ ، ومن ثم يمكن التنبؤ بالمشاهدات المستقبلية باستخدام النموذج المقدر الآتي:  $\hat{y}_1 = \hat{\beta}_1 + \hat{\beta}_2 t$

وفي بعض الأحيان قد يكون الشكل الخطي غير ملائم لتمثيل متوسط الظاهرة أو الدالة  $f(t)$  ومن الأفضل تمثيل هذا المتوسط بكثيرة حدود من الدرجة الثانية كما في الشكل (5) والتي تأخذ الصورة الآتية:

$$E(y_1) = f(t) = \beta_0 + \beta_1 t + \beta_2 t^2$$

وتستخدم طريقة المربعات الصغرى العادية لإيجاد التقديرات  $\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2$  وذلك بإجراء الانحدار الخطي المتعدد لقيم السلسلة  $y_1$  على المتغيرين  $t, t^2$ . وسنوضح هذا بالتفصيل عند قياس الاتجاه العام باستخدام تحليل الانحدار.

**شكل (5):** كثيرة حدود من الدرجة الثانية

## النمو الأسي Exponential Growth

في بعض الأحيان قد يفضل تمثيل متوسط الظاهرة موضع الدراسة في شكل دالة أسية - كما في الشكل (6)- على الصورة:

$$E(y_1) = f(t) = ce^{rt} \quad (1.6.3)$$

حيث  $c$  و  $r$  مقداران ثابتان يمثلان معلمتي النموذج.

**شكل (6): النمو الأسي**

ويفترض النموذج الأسي أن متوسط الظاهرة ينمو بنسبة ثابتة وذلك لأن من (1.6.3):

$$\frac{E(y_1)}{E(y_{t-1})} = \frac{ce^{rt}}{ce^{r(t-1)}} = e^r$$

حيث  $e^r$  ثابت لا يعتمد على الزمن، ويعني هذا أن:  $E(y_1) = e^r E(y_{t-1})$

ويمكن تحويل الصورة (1.6.3) إلى الصورة الخطية بأخذ اللوغاريتمات الطبيعية للطرفين كما يلي:

$$\ln f(t) = \ln c + rt \quad \text{أي } f^*(t) = c^* + rt \quad \text{حيث: } c^* = \ln c ; f^*(t) = \ln f(t)$$

وبالتالي يمكن إجراء انحدار لوغاريتم البيانات الأصلية على الزمن  $t$  وإيجاد تقديري المربعات الصغرى

للمعلمتين  $r, c^*$  ومن ثم يمكن إيجاد تقدير الثابت  $c$  من العلاقة:  $c = e^{c^*}$

ومن ثم يمكن التنبؤ بالملاحظات المستقبلية باستخدام النموذج المقدر الآتي:  $\hat{y}_1 = \hat{c} e^{\hat{r}t}$

وتعاني الطرق أو النماذج المحددة في تحليل السلاسل الزمنية من العديد من العيوب أهمها:

1- تركز هذه الطرق على المنطق الرياضي في محاولة لإيجاد دالة رياضية جيدة ممكن أن تستخدم في

توفيق البيانات أكثر من اهتمامها بمحاولة استكشاف الخصائص الإحصائية الهامة للسلسلة وأهمها

نمط الارتباط الموجود بين مشاهدات السلسلة، فهذه النماذج لا تصف خصائص السلسلة الإحصائية

ولكنها مجرد نماذج تنتج المشاهدات  $y_1, y_2, \dots, y_n$

2- تفترض هذه الطرق أن التطور طويل الأجل في السلسلة يكون نمطي أو منتظم الشكل وممكن التنبؤ

به بشكل كبير.

3- وتفترض أيضاً هذه الطرق عدم وجود ارتباط بين مشاهدات السلسلة، وهذا الفرض من النادر أن

يكون متحققاً في مجالات التطبيق المختلفة. بسبب كل هذه العيوب فإن هذه الطرق عادة ما تؤدي

إلى تنبؤات غير دقيقة من الناحية الإحصائية.

وبالرغم من الانتقادات التي توجه إلى هذه الطرق فإن لها باع طويل في موضوعات التنبؤ ومازالت

تستخدم بكثرة في كافة مجالات التطبيق في البلاد النامية خاصة في الاقتصاد والإدارة والبيئة لأنها وسائل

بسيطة وغير مكلفة ولا تحتاج إلى خبرات أو مهارات خاصة من قبل الباحثين أو الدارسين أو متخذي القرارات.

## 1.6.2 الطرق الحسية Ad Hoc Methods:

ذكرنا أن طرق التنبؤ المحددة تعتمد على التعبير عن قيمة السلسلة عند الزمن  $t$  أي  $y_1$  كدالة رياضية مباشرة في الزمن. وهذا الاتجاه له عيوبه كما ذكرنا وأهمها أنه يفترض عدم وجود علاقة بين مشاهدات السلسلة  $y_1, y_2, \dots, y_n$ , الاتجاه الثاني في التنبؤ يعتمد على التعبير عن تنبؤ السلسلة عند الزمن  $t$  بدلالة حاضر السلسلة  $y_1$  وماضي السلسلة  $y_1, y_2, \dots, y_{t-1}$ . فإذا افترضنا أن  $t$  تمثل نقطة أصل معينة وأننا نريد التنبؤ بقيمة السلسلة بعد  $k$  من الفترات الزمنية فإن الاتجاه الثاني يفترض العلاقة الدالية الآتية:

$$\hat{y}_{t+k} = f(y_1, y_2, \dots, y_{t-1}, y_t) \quad (1.6.4)$$

ويوجد العديد من الطرق والنماذج التي تنتمي بشكل أو بآخر للصورة (1.6.4) وتعتمد على الحس الإنساني أكثر من اعتمادها على أسلوب إحصائي منظم. ومن أمثلة ذلك طريقة التنبؤ السطحي وتنبؤ التغير الثابت وطريقة المتوسطات المتحركة البسيطة وطريقة التمهيد الأسّي، وفيما يلي نقدم عرضاً مبسطاً لهذه الطرق.

### التنبؤ السطحي Naive Forecasting:

تستخدم طريقة التنبؤ السطحي قيمة المشاهدة الحالية كتنبؤ مباشر للمشاهدة التالية، أي أن:

$$\hat{y}_{t+1} = y_t \quad (1.6.5)$$

والنموذج (1.6.5) يكون ملائماً عندما تكون قيم السلسلة ثابتة بشكل تقريبي على الفترة الزمنية موضع الدراسة، ويحدث هذا عندما يغلب على السلسلة الزمنية محل الدراسة الطابع غير النمطي (غير المنتظم) أي عندما تتغير السلسلة بشكل عشوائي كبير لا يتبع نمطاً أو نظاماً أو اتجاهاً معيناً يمكن معه التنبؤ بقيمة السلسلة في الفترة الزمنية التالية، وتعتبر أسعار الأوراق المالية في البورصة أشهر مثال على هذا النوع من السلاسل الزمنية.

والجدير بالذكر أن النموذج السطحي يعطي تنبؤات متحيزة إلى أسفل إذا كانت السلسلة تتزايد باستمرار وذلك لأن التنبؤ  $\hat{y}_1$  يكون دائماً أقل من القيمة،  $y_1$  والعكس صحيح، أي أن هذا النموذج يعطي تنبؤات متحيزة إلى أعلى إذا كانت السلسلة تتناقص باستمرار لأن التنبؤ  $\hat{y}_1$  يكون أكبر من القيمة  $y_1$ ، ولذلك لا ينصح باستخدام طريقة التنبؤ السطحي في مثل هذه الحالات.

### تنبؤ التغير الثابت Constant Change Forecasting:

في الكثير من التطبيقات خاصة الاقتصادية منها تتميز بعض السلاسل بثبات في التغيرات المتتالية،

فإذا افترضنا أن  $t$  تمثل نقطة أصل معينة فإن التغير السابق في السلسلة يكون:  $\Delta y_t = y_t - y_{t-1}$

وإذا كانت  $\hat{y}_{t+1}$  تمثل التنبؤ بقيمة السلسلة الزمنية، فإن التغير القادم في السلسلة يقدر كالتالي:

$$\hat{\Delta}y_{t+1} = \hat{y}_{t+1} - y_t$$

وبمساواة التغير السابق  $\Delta y_t$ ، بالتغير اللاحق  $\hat{\Delta}y_{t+1}$  نصل إلى:  $\hat{y}_{t+1} - y_t = y_t - y_{t-1}$

ومن ثم نصل إلى النموذج الآتي:

$$\hat{y}_{t+1} = y_t + (y_t - y_{t-1}) \quad (1.6.6)$$

أي أن التنبؤ في الفترة الزمنية القادمة يساوي القيمة الحاضرة  $y_t$  بالتغير الذي مضافا إليه قيمة التغير

الذي حدث في الفترة السابقة  $\Delta y_t$ .

### المتوسطات المتحركة البسيطة Simple Moving Averages:

يعتمد النموذج السطحي على القيمة الحالية  $y_t$  فقط للتنبؤ بالقيمة التالية  $y_{t+1}$ ، بينما يعتمد تنبؤ

التغير الثابت على أحدث قيمتين  $y_t, y_{t-1}$  للتنبؤ بالقيمة التالية  $y_{t-1} \dots y_{t-1}$  أما طريقة المتوسطات المتحركة

البسيطة فتستخدم أحدث  $k$  قيمة للسلسلة للتنبؤ بالقيمة التالية أي تستخدم القيم

$y_t, y_{t-1}, y_{t-2}, \dots, y_{t-(k-2)}$  وذلك بأخذ متوسط هذه القيم كما يلي:

$$\hat{y}_{t+1} = \frac{1}{k} [y_t + y_{t-1} + \dots + y_{t-(k-2)} + y_{t-(k-1)}] ; t = k, k+1, \dots, n \quad (1.6.7)$$

$$\hat{y}_{t+2} = \frac{1}{k} [y_{t+1} + y_t + y_{t-1} + \dots + y_{t-(k-2)}] \quad \text{وهذا يعني أن:}$$

أي أنه لإيجاد المتوسط المتحرك البسيط  $\hat{y}_{t+2}$  نستخدم نفس القيم التي استخدمت في حساب المتوسط

السابق له مباشرة  $\hat{y}_{t+1}$  بعد إحلال القيمة الأحدث  $y_{t+1}$  مكان القيمة الأقدم  $y_{t-(k-1)}$  وهذا معنى

التحرك أي أن المتوسط يتم تحديثه دائما بحذف المشاهدة الأقدم ووضع بدلاً منها المشاهدة التالية. فعلى

سبيل المثال إذا كانت  $k = 3$  فإنه يمكن تكوين  $(n - 3)$  متوسط متحرك بسيط مناظر لقيم السلسلة

المتاحة كما يلي:

$$\hat{y}_4 = \frac{1}{3} [y_3 + y_2 + y_1]$$

$$\hat{y}_5 = \frac{1}{3} [y_4 + y_3 + y_2]$$

$$\hat{y}_6 = \frac{1}{3} [y_5 + y_4 + y_3]$$

⋮

$$\hat{y}_n = \frac{1}{3} [y_{n-1} + y_{n-2} + y_{n-3}]$$

واختيار العدد الصحيح  $k$  يعتمد على رأي الباحث وخبرته العملية وهو أحد المشاكل التي تواجه مستخدم طريقة المتوسطات المتحركة البسيطة. ودقة التنبؤ تعتمد على اختيار العدد الملائم ولذلك يمكن اختيار هذا العدد بطريقة التجربة والخطأ، حيث تحسب جميع التنبؤات التي تناظر كل قيمة من قيم  $k$  الممكنة ( $k = 2, 3, \dots, n - 1$ ) وحساب الأخطاء ومن ثم حساب أحد المعايير الهامة لقياس حجم الأخطاء - وليكن متوسط مربعات الأخطاء المناظر لكل قيمة من قيم  $k$  واختيار قيمة  $k$  التي تناظر أصغر قيمة لهذا المعيار. وبالرغم من المشاكل التي قد تواجه الباحث عند اختيار قيمة  $k$  الملائمة إلا أن العيب الرئيسي لطريقة المتوسطات المتحركة البسيطة هو إعطاء أوزان متساوية لكل المشاهدات المستخدمة في حساب المتوسط فإذا كانت  $k = 8$  مثلاً فإن الوزن الذي يعطى للقيمة الحديثة  $y_t$  يساوي الوزن الذي يعطى للقيمة الأقدم  $y_{t-7}$ . وهذا عادة ما يتعارض مع خصائص السلاسل الزمنية حيث نميل إلى إعطاء المشاهدات الأحدث أوزاناً أكبر. ولذلك يفضل استخدام طريقة المتوسطات المتحركة البسيطة عندما يغلب الطابع العشوائي على بيانات السلسلة.

**مثال (3):** الجدول الآتي يوضح قيمة المبيعات السنوية من إحدى السلع بملايين الدولارات في الفترة من

السنة 1990 إلى سنة 1998:

السنة	1990	1991	1992	1993	1994	1995	1996	1997	1998
قيمة المبيعات	9	11	10	12	11	9	13	11	9

a. استخدام طريقة المتوسطات المتحركة البسيطة في إيجاد جميع التنبؤات الممكنة مرة باستخدام

$k = 2$  ومرة باستخدام  $k = 3$  وأوجد متوسط مربعات الأخطاء المناظرة في كل حالة.

b. تتبأ بقيمة المبيعات في سنة 1999.

**الحل:**

		$K$			
		2		3	
السنة	$y_t$	$\hat{y}_t$	$e_1^2$	$\hat{y}_t$	$e_1^2$
1990	9	-	-	-	-
1991	11	-	-	-	-
1992	10	$\frac{1}{2}[9 + 11] = 10$	0	-	-
1993	12	$\frac{1}{2}[10 + 11] = 10.5$	252.	$\frac{1}{3}[10 + 1 + 9] = 10$	4

1994	11	$\frac{1}{2}[12 + 10] = 11$	0	$\frac{1}{3}[12 + 10 + 11] = 11$	0
1995	9	$\frac{1}{2}[11 + 12] = 11.5$	6.25	$\frac{1}{3}[11 + 12 + 10] = 11$	4
1996	13	$\frac{1}{2}[9 + 11] = 10$	9	$\frac{1}{3}[9 + 11 + 12] = 10.67$	5.429
1997	11	$\frac{1}{2}[13 + 9] = 11$	0	$\frac{1}{3}[13 + 9 + 11] = 11$	0
1998	9	$\frac{1}{2}[11 + 13] = 12$	9	$\frac{1}{3}[11 + 13 + 9] = 11$	4
1199	؟	$0\frac{1}{2}[9 + 11] = 12$	-	$\frac{1}{3}[9 + 13 + 11] = 11$	-

a. إذا كانت  $k = 2$  :  $MSE = \frac{2}{7}[0 + 2.25 + 0 + 6.25 + 9 + 0 + 9] = 3.786$

إذا كانت  $k = 3$  :  $MSE = \frac{1}{3}[4 + 0 + 4 + 5 + 5.429 + 0 + 4] = 2.905$

b. ويمكن القول بأن قيمة  $k = 3$  أفضل من قيمة  $k = 2$  في التنبؤ لأن متوسط مربعات الأخطاء

المناظر أقل ومن ثم فإن:  $\hat{y}_{10} = \frac{1}{3}[y_9 + y_8 + y_7] = \frac{1}{3}[9 + 11 + 13] = 11$

